



# GI-Edition



## Lecture Notes in Informatics

C. Hoffmann, A. Stein, E. Gallmann,  
J. Dörr, C. Krupitzer, H. Floto (Hrsg.)

## Informatik in der Land-, Forst- und Ernährungswirtschaft

Fokus: Biodiversität fördern durch digitale  
Landwirtschaft

Referate der 44. GIL-Jahrestagung  
27. - 28. Februar 2024

Stuttgart-Hohenheim

C. Hoffmann et al. (Hrsg.):  
Biodiversität fördern durch digitale Landwirtschaft



GESELLSCHAFT  
FÜR INFORMATIK







Christa Hoffmann, Anthony Stein, Eva Gallmann,  
Jörg Dörr, Christian Krupitzer, Helga Floto (Hrsg.)

## **Informatik in der Land-, Forst- und Ernährungswirtschaft**

**Fokus:**  
**Biodiversität fördern durch digitale Landwirtschaft:**  
**Welchen Beitrag leisten KI und Co?**

**Referate der 44. GIL-Jahrestagung**  
**27.-28. Februar 2024**  
**Stuttgart-Hohenheim, Germany**

Gesellschaft für Informatik e.V. (GI)

**Lecture Notes in Informatics (LNI) - Proceedings**

Series of the Gesellschaft für Informatik (GI)

Volume P-344

ISBN 978-3-88579-738-8

ISSN 1617-5468

**Volume Editors**

Dr. Christa Hoffmann  
oeconos GmbH  
73265 Dettingen, Germany  
Email: christa.hoffmann@oeconos.de

Jun.-Prof. Dr. Anthony Stein  
Universität Hohenheim & Computational Science Hub (CSH)  
70599 Stuttgart, Germany  
Email: anthony.stein@uni-hohenheim.de

apl. Prof. Dr. Eva Gallmann  
Universität Hohenheim  
70599 Stuttgart, Germany  
Email: eva.gallmann@uni-hohenheim.de

Prof. Dr.-Ing. Jörg Dörr  
RPTU Kaiserslautern-Landau & Fraunhofer IESE  
67653 Kaiserslautern  
Email: Joerg.Doerr@iese.fraunhofer.de

Jun.-Prof. Dr. Christian Krupitzer  
Universität Hohenheim & Computational Science Hub (CSH)  
70599 Stuttgart, Germany  
Email: christian.krupitzer@uni-hohenheim.de

Helga Floto  
GIL-Geschäftsführung  
73730 Esslingen, Germany  
Email: gil.floto@gmail.com

**Series Editorial Board**

Andreas Oberweis, KIT Karlsruhe,  
(Chairman, andreas.oberweis@kit.edu)  
Torsten Brinda, Universität Duisburg-Essen, Germany  
Dieter Fellner, Technische Universität Darmstadt, Germany  
Ulrich Frank, Universität Duisburg-Essen, Germany  
Barbara Hammer, Universität Bielefeld, Germany  
Falk Schreiber, Universität Konstanz, Germany  
Wolfgang Karl, KIT Karlsruhe, Germany  
Michael Koch, Universität der Bundeswehr München, Germany  
Heiko Roßnagel, Fraunhofer IAO Stuttgart, Germany  
Kurt Schneider, Universität Hannover, Germany  
Andreas Thor, HFT Leipzig, Germany  
Ingo Timm, Universität Trier, Germany  
Karin Vosseberg, Hochschule Bremerhaven, Germany  
Maria Wimmer, Universität Koblenz-Landau, Germany

**Dissertations**

Rüdiger Reischuk, Universität Lübeck, Germany

**Thematics**


Agnes Koschmider, Universität Kiel, Germany

**Seminars**

Judith Michael, RWTH Aachen, Germany

© Gesellschaft für Informatik, Bonn 2024

printed by Köllen Druck+Verlag GmbH, Bonn



*This book is licensed under a Creative Commons BY-SA 4.0 licence.*



## Vorwort

Die 44. Jahrestagung der Gesellschaft für Informatik in der Land-, Forst- und Ernährungswirtschaft (GIL) steht im Jahr 2024 unter dem Leitthema „**Biodiversität fördern durch digitale Landwirtschaft: Welchen Beitrag leisten KI und Co?**“. Sie findet statt in einer Zeit, in der tagelange Bauernproteste die Unzufriedenheit der Landwirte über zunehmende Auflagen, Bestrebungen zur Streichung von Subventionen, mangelnde Planungssicherheit und fehlende Wertschätzung auf die Straße bringen. Die Herausforderungen, die die Agrarwirtschaft zu bewältigen hat, sind vielfältig und komplex. Der Erhalt und die Förderung der Biodiversität stellen dabei mit einer der dringlichsten Aufgaben unserer Zeit dar. Initiativen wie „Rettet die Bienen“ oder ähnliche verdeutlichen dies.

In diesem Kontext steht die diesjährige Jahrestagung unter der Fragestellung, inwieweit die digitale Landwirtschaft einen Beitrag im Spannungsfeld zwischen notwendiger Produktivität sowie Erhalt und Wiederaufbau der Biodiversität leisten kann. Die Tagung dient als Plattform für den Austausch von Ideen, Erfahrungen und Erkenntnissen zwischen Wissenschaft, Praxis und Politik aus der Land-, Forst- und Ernährungswirtschaft sowie aus dem Bereich der Informatik. Die vielfältigen Themen der Tagungsbeiträge zeigen, dass Interdisziplinarität im Diskurs und in der wissenschaftlichen Zusammenarbeit zwischen den unterschiedlichen Fächern entscheidend ist, um innovative Lösungsansätze zu entwickeln, die eine nachhaltige Landwirtschaft fördern. Der vorliegende Tagungsband präsentiert eine Vielzahl von wissenschaftlichen und referierten Beiträgen, die das breite Spektrum dieser gesellschaftlich äußerst relevanten Thematik mit einem Fokus auf den Einsatz und der Bewertung digitaler Technologien beleuchten. Dazu gehören heute vermehrt KI-gestützte Systeme, welchen ein enormes Potential für das Monitoring und den Erhalt der Artenvielfalt durch gezielte Optimierung der landwirtschaftlichen Produktionsprozesse zugeschrieben wird. Aber auch Aspekte rechtlicher Rahmenbedingungen und hinsichtlich der Nutzer-Technik Schnittstelle werden diskutiert. Neben den Sessions zu diversen Themen der Digitalisierung des Agrar- und Ernährungssystems widmet sich die 44. Jahrestagung in diesem Jahr zudem mit einer Special Session dem essentiellen Aspekt der Aus- und Weiterbildung von digitalen Kompetenzen in der Landwirtschaft.

Der vorliegende Tagungsband enthält 62 wissenschaftliche Beiträge, die aus 101 eingereichten Abstracts nach einem zwei- bzw. dreistufigen Begutachtungsverfahren (peer review) hervorgegangen sind. Von den 62 Beiträgen fallen 13 Beiträge in die bereits im letzten Jahr eingeführte Kategorie Long Paper, die einer zusätzlichen dritten Begutachtungsphase unterzogen wurden. Unser Dank gilt allen, die sich aktiv an der Vorbereitung und Durchführung der Tagung mit großem Engagement beteiligt haben. Abschließend danken wir allen Sponsoren für Ihre finanzielle Unterstützung.

Stuttgart-Hohenheim, im Februar 2024


Dr. Christa Hoffmann, oeconos GmbH, 1. Vorsitzende der GIL  
Jun.-Prof. Dr. Anthony Stein, Universität Hohenheim, 2. Vorsitzender der GIL  
Helga Floto, GIL-Geschäftsführung  
apl. Prof. Dr. Eva Gallmann, Universität Hohenheim, Local Chair  
Jun.-Prof. Dr. Christian Krupitzer, Universität Hohenheim, Proceedings Chair  
Prof. Dr. Jörg Dörr, RPTU Kaiserslautern-Landau und Fraunhofer IESE, Program Chair

**Wir danken der Landwirtschaftlichen Rentenbank für  
die freundliche Unterstützung.**



**rentenbank**

**Wir danken den folgenden Unternehmen und Institutionen  
für die Unterstützung der Tagung (PREMIUM).**



**Baden-Württemberg**  
MINISTERIUM FÜR ERNÄHRUNG, LÄNDLICHEN RAUM  
UND VERBRAUCHERSCHUTZ

**Wir danken den folgenden Unternehmen und Institutionen für die Unterstützung der Tagung (SUPPORTER).**





PRECISION MADE SMART

onesmartspray.com

## Maximale Herbizideinsparungen, ohne Kompromisse in der Unkrautkontrolle.

**Präzision**

- Kameras
- LED Beleuchtung
- Steuergeräte
- Connectivity Unit

**Digitale Anwendungen**

- Digitale Karten: Applikation & Unkrautbedeckung
- Dokumentation & Berichterstattung
- Live-Ansicht

**Agronomische Intelligenz**

- Maßgeschneiderte Herbizidempfehlungen
- Intelligente Sensitivitätslevel
- Agronomischer & technischer Kundensupport

**xarvio**  
Digital Farming Solutions

**ode**  
ONE SMART SPRAY

A Joint Venture of



**BOSCH**  
Invented for life



**BASF**  
We create chemistry

# Übernehmen Sie die Kontrolle über Ihr digitales Ökosystem

[syntax.com](http://syntax.com)

 **SYNTAX**

xarvio

# FIELD MANAGER

Einfach effizienter Pflanzen anbauen

Die führende digitale Lösung zur feld- und feldzonen-spezifischen Optimierung der Pflanzenproduktion.



- ✓ Kinderleichte Erstellung variabler Applikationskarten
- ✓ + 27 €/ha höherer Deckungsbeitrag
- ✓ Über 25 Jahre erprobte und ausgereifte Risikomodelle
- ✓ Schlagspezifische Anwendungsempfehlungen

Mehr Infos unter:



(+49) 800 505 28 27  
(Mo–Fr: 8 bis 17 Uhr)  
germany@xarvio.info  
www.xarvio.de



## **Organisationsteam**

|                               |   |
|-------------------------------|---|
| General Co-Chairs :           | Christa Hoffmann, oeconos GmbH,<br>1. Vorsitzende der GIL<br>Anthony Stein, Universität Hohenheim,<br>2. Vorsitzender der GIL |
| Management and Finance Chair: | Helga Floto, GIL-Geschäftsführung   |
| Sponsoring Chair:             | Hans W. Griepentrog, Universität Hohenheim  |
| Local Chair:                  | Eva Gallmann, Universität Hohenheim   |
| Proceedings Chair:            | Christian Krupitzer, Universität Hohenheim  |
| Program Chair:                | Jörg Dörr, RPTU Kaiserslautern  |
| Special Session Chair:        | Jan Rebehn, Landratsamt Waldshut  |

## Programmkomitee

|                           |  |
|---------------------------|--|
| Thomas Anken              | Agroscope, Ettenhausen                   |
| Sonoko Bellingrath-Kimura | ZALF, Müncheberg                         |
| Frank Beneke              | Georg-August-Universität Göttingen       |
| Nadja Benni               | Agroscope, Ettenhausen                   |
| Ansgar Bernardi           | DFKI, Kaiserslautern                     |
| Heinz Bernhardt           | Technische Universität München, Freising |
| Carsten Berns             | RPTU, Kaiserslautern                     |
| Karsten Borchard          | Christian-Albrechts-Universität, Kiel    |
| Sebastian Bosse           | Fraunhofer HHI, Berlin                   |
| Michael Clasen            | Hochschule Hannover                      |
| Marianne Cockburn         | Agroscope, Ettenhausen                   |
| Markus Frank              | HfWU Nürtingen                           |
| Andreas Gabriel           | LfL, Ruhstorf a.d. Rott                  |
| Eva Gallmann              | Universität Hohenheim, Stuttgart         |
| Markus Gandorfer          | LfL, Freisingen                          |
| Hans W. Griepentrog       | Universität Hohenheim, Stuttgart         |
| Andreas Heiß              | Hochschule Geissenheim                   |
| Joachim Hertzberg         | Universität Osnabrück                    |
| Constanze Hofacker        | act GmbH Kiel                            |
| Marina Höhne              | ATB, Potsdam                             |
| Timo Korthals             | Claas, Dissen                            |
| Christian Krupitzer       | Universität Hohenheim, Stuttgart         |
| Daniel Martini            | KTBL, Darmstadt                          |
| Andreas Meyer-Aurich      | ATB, Potsdam                             |
| Victoria Motsch           | FH Oberösterreich, Wels                  |
| Henning Müller            | Agrotech Valley Forum e.V., Bohmte       |
| Matthias Nachtmann        | BASF, Limburgerhof                       |
| Patrick Noack             | Hochschule Weihenstephan-Triesdorf       |
| Dimitrios Paraforos       | Hochschule Geissenheim                   |
| Johanna Pfeiffer          | LfL, Ruhstorf an der Rott                |
| Heinrich Prankl           | Josephinum, Wieselburg                   |
| Guido Recke               | Hochschule Osnabrück                     |
| Olivia Spykman            | LfL, Ruhstorf a.d. Rott                  |
| Thilo Steckel             | CLAAS, Dissen                            |
| Stefan Stiene             | Hochschule Osnabrück                     |
| Ralph Stoop               | Agroscope, Ettenhausen                   |
| Barbara Sturm             | ATB Potsdam                              |
| Heiko Tapken              | Hochschule Osnabrück                     |
| Torben Toeniges           | CLAAS, Diessen                           |
| Christian Troost          | Universität Hohenheim, Stuttgart         |
| Dieter von Hörsten        | JKI, Braunschweig                        |
| Uta Wilkens               | Ruhr-Universität Bochum                  |
| Philipp Wree              | Fraunhofer IGD, Rostock                  |
| Andreas Wübbecke          | Fachhochschule Südwestfalen, Soest       |

## Long Paper

|  |     |
|--|-----|
| <b>Mengisti Berihu Girmay, Samuel Obeng, Felix Möhrle</b><br><i>Explainable AI: Leaf-based medicinal plant classification using knowledge distillation</i> .....   | 23  |
| <b>Santiago Focke Martinez, Isaak Ihorst, Thomas Wiemann, Felix Zeiß</b><br><i>Towards on-line monitoring and route re-planning in arable crop harvest</i> .....   | 35  |
| <b>Klaus Gennen</b><br><i>Haftung beim Einsatz von KI-Systemen im Agrarsektor</i> .....  | 47  |
| <b>Michael Gerstenberger, Mykyta Kovalenko, David Przewozny, Jannes Magnusson, Eike Gassen, Jakub Pawlak, Jochen Hirth, Laura von Hirschhausen, Detlef Runde, Anna Hilsmann, Peter Eisert, Sebastian Bosse</b><br><i>Automatisierte Frucht- und Pflanzenerkennung in Apfelplantagen durch künstliche Intelligenz</i> ..... | 59  |
| <b>Andreas Gilson, Mareike Weule, Jonathan Hansen, Lukas Meyer, Fabian Keil, Oliver Scholz, Annika Killer, Patrick Noack, Marc Stamminger, Ute Schmid</b><br><i>CherryGraph: Encoding digital twins of cherry trees into a knowledge graph based on topology</i> .....   | 71  |
| <b>Hakan Guerler, Hilke Risius, Richard Albrecht, Julian Rosenbaum, Christin Röpert, Frank Lienig, Eckart Kramer</b><br><i>Analyse des Product Carbon Footprints im Produktions- und Verarbeitungsprozess von Topinambur (<i>Helianthus tuberosus</i> L.)</i> .....  | 83  |
| <b>Mortesa Hussaini, Max Voigt, Anthony Stein</b><br><i>Adaptive real-time crop row detection through enhancing a traditional computer vision approach</i> .....   | 95  |
| <b>Lucas Johannsen, Sebastian Ramm, Yves Reckleben, Stephan Doerfel</b><br><i>Exploring AI for interpolation of combine harvester yield data</i> .....   | 107 |
| <b>Niklas Kruse, Paul Wachter, Julius Schöning</b><br><i>Compliance of agricultural AI systems – app-based legal verification throughout the development</i> .....   | 119 |
| <b>Alexander Kühnemund, Guido Recke</b><br><i>Non-behavioral variables on the acceptance of AI-based camera systems</i> .....  | 131 |
| <b>Shanghai Liu, Anna Hedström, Deepak Hanike Basavegowda, Cornelia Weltzien, Marina M.-C. Höhne</b><br><i>Explainable AI in grassland monitoring: Enhancing model performance and domain adaptability</i> .....   | 143 |

**Konstantin Nahrstedt, Tobias Reuter, Felix Wierling, Dieter Trautz, Thomas Jarmer**  
*UAV-gestütztes Spot-Spraying zur schwellwertbasierten Beikrautregulierung im Mais*  
..... 155

**Jan-Hendrik Witte, Jorge Marx Gómez**  
*Image-based activity monitoring of pigs*..... 167

## Short Paper

**Alexander Aue, Andrea Ackermann, Norbert Röder**  
*Converting data organised for visual perception into machine-readable formats* ..... 179

**Alexander Aue, Andrea Ackermann, Norbert Röder**  
*Innovative form generator for recording complex support programmes*..... 185

**Christoph Bader, Jörn Stumpfenhausen, Heinz Bernhardt**  
*Akzeptanzprognose zur Einführung eines Energie- managementsystems in automatisierten Milchviehställen in Bayern – „CowEnergySystem“* ..... 191

**Deepak H. Basavegowda, Marina M.-C. Höhne, Cornelia Weltzien**  
*Deep Learning-based UAV-assisted grassland monitoring to facilitate Eco-scheme 5 realization* ..... 197

**Justus Bracke, Marcel Storch, Janis Bald, Thomas Jarmer**  
*Comparison of UAV- and mowing machine-mounted LiDAR for grassland canopy height estimation*..... 203

**Juan A. Chiavassa, Martin Kraft, Patrick Noack, Simon Walther, Ameli Kirse, Christoph Scherber**  
*The FAIR-Device – an AI image recognition-based non-lethal and generalist monitoring system for insect biodiversity in agriculture* ..... 209

**Hauke Delfs, Annabell Cankaya, Anne Feiler, Markus Frank, Verena Klinger, Gabriel Baum, Christian Bauer**  
*Digitale Experimentierfelder zur Vernetzung in Technik und Wissen für eine digitale Landwirtschaft auf Zukunftsbetrieben in Baden-Württemberg* ..... 215

**Daniel Eberz-Eder, Franz Kuntke, Christian Reuter, Ansgar Bernardi, Ahmad Kadi, Gerwin Brill, Daniel Martini, Benno Kleinhenz**  
*Hybrid-Cloud-Infrastrukturen – Edge Computing und KI-basierte Anwendungen in der Landwirtschaft für resiliente und effektive Produktions- und Biodiversitätsmaßnahmen*  
..... 221

|   |     |
|---|-----|
| <b>Benedikt Fischer, Pascal Gauweiler, Benedikt Hofmann, Robin Gruna, Thomas Längle, Jürgen Beyerer</b><br><i>A comparative study of RGB and multispectral imaging for weed detection in precision agriculture .....</i>  | 227 |
| <b>Adriana Förchner, Anita Kapun, Eva Gallmann</b><br><i>Praxistest zum Einsatz von UHF-RFID-Transponderohrmarken in der Ferkelaufzucht .....</i>   | 233 |
| <b>Adriana Förchner, Lisa Aumann, Hansjörg Nußbaum</b><br><i>Brunstüberwachung nur digital? Vergleichende Bewertung von Brunsterkennungssystemen in der Milchviehhaltung.....</i>   | 239 |
| <b>Josef Franko, Sivaparvathi Mannem, Simon Maike, Ting Sheng Lee, Rolf Becker, Bettina Weber</b><br><i>Visual servoing in 3D to enhance full farming in occluded vegetable sceneries .....</i>   | 245 |
| <b>Christoph Friedrich, Johannes Löw, Insa Otte, Steven Hill, Sebastian Förtsch, Jakob Schwalb-Willmann, Ursula Gessner, Christoph Schierghofer, Sina Truckenbrodt, Eric Schonert, Thomas Piernicke, Denise Assmann, Christopher Conrad, Michael Thiel</b><br><i>A multi-talented datacube: integrating, processing and presenting big geodata for the agricultural end user.....</i> | 251 |
| <b>Manuel Geil, Jan-Henrik Helmig, Julian Jour, Bodo Mistele, Jens Peters, Katharina Stahl, Andreas Wübbeke</b><br><i>Automatisierte Unterscheidung von Feldarbeit und Straßenfahrt für Landmaschinen mit Hilfe von unüberwachten KI-Methoden.....</i>  | 257 |
| <b>Manuel Geil, Jan-Henrik Helmig, Julian Jour, Bodo Mistele, Jens Peters, Katharina Stahl, Andreas Wübbeke</b><br><i>Transformation von Maschinendaten als Eingabe für maschinelle Lernverfahren zur Klassifikation von landwirtschaftlichen Arbeitsgängen.....</i>  | 263 |
| <b>Mengisti Berihu Girmay, Felix Möhrle, Jens Henningsen</b><br><i>Exploring explainability formats to aid decision-making in dairy farming systems ....</i>  | 269 |
| <b>Sven Götz, Alexander Kühnemund, Johannes Schmidt-Mosig</b><br><i>Möglichkeiten der Analyse und Interpretation der visuellen Darstellung von Tierpositionen im Zeitverlauf.....</i>   | 275 |
| <b>Julian Hagert, Benjamin Striller, Tobias Földner, Andreas Hecker, Bernd Turkowski, Jennifer Schwardt, Thomas Herlitzius, Gerhard Fettweis</b><br><i>Adaptive Mesh-Netzwerke zur Steigerung der Konnektivität von Landmaschinen.....</i>  | 281 |

|  |     |
|--|-----|
| <b>Ingo-Leonard Haußmann, Lukas Petrich, Georg Lohrmann, Volker Schmidt, Albert Stoll</b><br><i>Bilddatenakquisition zur Entwicklung eines Machine-Learning-Detektors für Grünlandunkräuter.....</i>                                   | 287 |
| <b>Jonathan Henrich, Christian Post, Thomas Kneib, Ramin Yahyapour, Sven Bingert, Imke Traulsen</b><br><i>Entwicklung eines vielfältigen und anspruchsvollen Benchmark-Datensatzes für die Detektion von Schweinen in Bildern.....</i> | 293 |
| <b>Björn-Gerrit Hülle, Stefan Böttinger</b><br><i>Entwicklung eines Algorithmus zur automatischen Belegung von freibelegbaren Bedienelementen auf der Armlehne eines Ackerschleppers via ISOBUS.....</i>                               | 299 |
| <b>Christoph Jörges, Sandra Dotzler, Silke Migdall, Heike Bach</b><br><i>Learning from hyperspectral remote sensing data for machine learning algorithms in earth science .....</i>  | 305 |
| <b>Miriam Kennade, Laura Schmitz, Carla Ollier, Marcus Mergenthaler</b><br><i>Digitalisierung als Beitrag zur Verbesserung des Tierwohls - die Sicht von Tierhaltenden in der Landwirtschaft.....</i>                                  | 311 |
| <b>Dennis Köpp, Hendrik Bertram, Bruno Kezeya, Petra Zerhusen-Blecher, Tanja Schäfer, Mehmet Gültas, Marcus Mergenthaler</b><br><i>„LeguDash“ – ein Prototyp eines Dashboards für mehr Transparenz am Leguminosenmarkt .....</i>       | 317 |
| <b>Hubert Linseisen, Ioannis Manakos, Eleftherios Katsikis, Anastasios Delopoulos</b><br><i>Assimilation von satellitenbasierten Reflexionsmessungen in einem Informationssystem für einen modernen Hopfenbaubetrieb .....</i>         | 323 |
| <b>Simon Maike, Farooq Abbas, Ting Sheng Lee, Marvin Kühnast, Bettina Weber, Rolf Becker, Josef Franko</b><br><i>Predictive task scheduler and ERP system for automated vegetable cultivation in an outdoor environment.....</i>       | 329 |
| <b>Christoph Manss, Viktor Martel, Roman Weisgerber</b><br><i>Assessment of ground conditions in grassland on a mower with artificial intelligence.....</i>  | 335 |
| <b>Emir Memic, Jonas Fröbl, Simone Graeff-Hönninger</b><br><i>Combining a crop growth model with satellite images to get better insight in wheat growth.....</i>   | 341 |



|  |     |
|--|-----|
| <b>Alma Moroder, Sonoko Bellingrath-Kimura, Karl Reimand, Jochen Kantelhardt, Andreas Meyer-Aurich</b><br><i>Assessing the contribution of digital technologies to agroecological principles in the European context.....</i>  | 347 |
| <b>Michael Paulus, Clara Körner</b><br><i>Ausbildungsorganisatorische Perspektiven auf die Wissensvermittlung zur Digitalisierung im dualen System.....</i>  | 353 |
| <b>Marie Sophie Peters, Torben Rahn, Steffi Fock, Yves Reckleben, Holger Schulze</b><br><i>Entwicklung eines digitalen Zertifikatsystems zur Dokumentation landwirtschaftlicher Klima- und Umweltschutzmaßnahmen am Beispiel der Kartoffel-Wertschöpfungskette .....</i> | 359 |
| <b>Sara Anna Pfaff, Johannes Munz</b><br><i>Verbindung von Wissenschaft und Praxis: WiLaDi.....</i>  | 365 |
| <b>Björn Poss, Nikos Tsoulas, Andreas Heiß, Dimitrios S. Paraforos</b><br><i>Vergleich zwischen luft- und bodengeführten Laser-Scannern zur Bestimmung der Laubwandhöhe im Weinbau.....</i>  | 371 |
| <b>Sandra Post, Ingmar Schröter, Eric Bönecke, Jörg Rühlmann, Falk Böttcher, Denise Assmann, Eckart Kramer</b><br><i>Dreidimensionale Bodenfeuchtemodellierung auf Schlagebene .....</i>   | 377 |
| <b>Maren Pukrop, Simon Pukrop, Thomas Jarmer</b><br><i>Weed detection with YOLOv8-seg in UAV-imagery.....</i>  | 383 |
| <b>Giovanni Antonio Puliga, Jobst Gödeke, Dieter von Hörsten, Jens Karl Wegener</b><br><i>Development of an index to estimate potential risk of slug damage .....</i>  | 389 |
| <b>Hendrik Schwager, Jorrit Köhl, Holger Schulze</b><br><i>Datennutzungsstrategien von Ackerbaubetrieben – Wofür Landwirte ihre Daten nutzen .....</i>   | 395 |
| <b>Oliver Schöttker, Astrid Sturm, Frank Wätzold</b><br><i>Virtuelles Zäunen und ökologische Wirkungen von Weidebewirtschaftung: Prototyp einer App zur Information der Öffentlichkeit.....</i>  | 401 |
| <b>Julia Senge, Ellen Mielinger, Marie Catherine Wendt, Ramona Weinrich, Christian Krupitzer</b><br><i>A crowdsensing-based smartphone app for optimal food storage and real-time best-before dates.....</i>   | 407 |
| <b>Christian Sponagel, Felix Witte, Enno Bahrs</b><br><i>Ökonomische Bewertung und Vergleich von Pflanzenschutzverfahren mit Fokus auf Herbizidreduktion durch Digitalisierung am Beispiel des Zuckerrübenanbaus .....</i>   | 413 |

|  |     |
|--|-----|
| <b>Leonie Steinherr, Miguel Belo, Rodja Trappe, Dafne Acosta-Ortiz, Amanda Birkmann, Tsvetelina Krachunova, Ralf Bloch</b><br><i>Organic sugar beet (<i>Beta vulgaris L.</i>) cultivation using the field robot Uckerbot as a system for sustainable farming .....</i> | 419 |
| <b>Ralph L. Stoop, Markus Sax, Thomas Anken</b><br><i>Verteilung und Zusammensetzung von Abfall in ländlichen Gebieten .....</i>   | 425 |
| <b>Beat Vinzent, Franz-Xaver Maidl, Markus Gandorfer</b><br><i>Teilflächenspezifische Aussaat von Körnermais: Potenziale und Limitationen .....</i>  | 431 |
| <b>Paul Wachter, Niklas Kruse, Julius Schöning</b><br><i>Synthetic fields, real gains - Enhancing smart agriculture through hybrid datasets ...</i>  | 437 |
| <b>Bettina Weber, Sahil Chande, Simon Maike, Maarten Verbunt, Ting Sheng Lee, Rolf Becker, Josef Franko</b><br><i>Robotic process control for multi-vegetable micro spot-farming using digital twin simulation .....</i>   | 443 |
| <b>Jan Lukas Wenzel, Christopher Conrad, Julia Pöhlitz</b><br><i>Soil moisture simulations for a sustainable irrigation management .....</i>   | 449 |
| <b>Clemens Westerkamp, Christian Thünemann, Marco Schaarschmidt</b><br><i>Model for the calculation of soil compaction on agricultural land .....</i>  | 455 |
| <b>Jayan Wijesingha, Damian Schulze-Brüninghoff, Michael Wachendorf</b><br><i>Mapping invasive Lupine on grasslands using UAV images and deep learning .....</i>   | 461 |
| <b>Martin Wutke, Anne Holzhauer, Ulrich Hartmann, Marc-Alexander Lieboldt, Imke Traulsen</b><br><i>Implementierung eines Noisy-Student-Ansatzes zur Verbesserung der automatischen Detektionsleistung bei Ferkeln .....</i>  | 467 |

## Keynote

|  |     |
|--|-----|
| <b>Markus Frank</b><br><i>Digitale Landwirtschaft und der Erhalt von Artenvielfalt – gibt es einen Zusammenhang? .....</i> | 473 |
|--|-----|

## Explainable AI: Leaf-based medicinal plant classification using knowledge distillation

Mengisti Berihu Girmay<sup>1</sup>, Samuel Obeng<sup>1</sup> and Felix Möhrle<sup>1</sup>

**Abstract:** Medicinal plants are used in a variety of ways in the pharmaceutical industry in many parts of the world to obtain medicines. They are traditionally used especially in developing countries, where they provide cost-effective treatments. However, accurate identification of medicinal plants can be challenging. This study uses a deep neural network and knowledge distillation approach based on a dataset of 4,026 images of 8 species of leaf-based Ethiopian medicinal plants. Knowledge from a ResNet50 teacher model was applied to a lightweight 2-layer student model. The student model, optimized for efficiency, achieved 96.91% accuracy and came close to the 98.98% accuracy of the teacher model on unseen test data. The training was built on optimization strategies, including oversampling, data augmentation, and learning rate adjustment. To understand the model's decisions, LIME (Local Interpretable Model-agnostic Explanations) and degree Grad-CAM (Gradient-weighted Class Activation Mapping) post-hoc explanation techniques were used to highlight influential image regions that contributed to classification.

**Keywords:** knowledge distillation, convolutional neural network, explainable AI, resource efficiency

### 1 Introduction

According to the World Health Organization, approximately 70% of the world's population relies on plants for their primary health needs, with an estimated 35,000 to 70,000 species being used as remedies [Ma12]. In developing countries like Ethiopia, medicinal plants are often prescribed to patients by traditional practitioners who have inherited their knowledge from previous generations. This knowledge is often not well documented, resulting in the identification of medicinal plants often being based largely on expert opinion [Du19; BFL22]. To facilitate identification, academic research is advancing automatic recognition of plants by means of their leaves, fruits, and stems using computer vision applications [KE20].

Leaves, in particular, play a crucial role in plant identification because they have a stable structure, are easily accessible, and have a long lifespan [Wu21]. Recent research leverages methods for automatic leaf identification using deep learning methods that rely mainly on surface features such as color, shape, and texture to extract deep features of leaves for identification [AH 20]. Advanced techniques, such as residual linking or batch

---

<sup>1</sup> RPTU Kaiserslautern-Landau, Digital Farming, Erwin-Schrödinger-Str., 67663 Kaiserslautern, mengisti.berihu@rptu.de, obeng@rptu.de, felix.moehrle@cs.rptu.de

normalization, facilitate the training of deep neural networks with hundreds of thousands of parameters on powerful GPUs to make computation more efficient. However, the computational complexity and memory-intensive networks make them difficult to deploy in resource-constrained mobile devices such as smartphones and tablets [SAZ21; De09; DY19].

In this study, we used deep learning and knowledge distillation to identify 8 species of Ethiopian medicinal plants from images taken with a 64-megapixel mobile phone camera. The images were taken outdoors. We ensured that the images have a white background to remove unnecessary background noise. We simplified a complex ResNet50 teacher model using PyTorch in a Jupyter notebook to a two-layer version student model suitable for mobile devices. This student model, which replicates the results of the teacher model, was augmented with explainable AI techniques such as LIME and Grad-CAM to highlight the influential regions in the input images that drive the model's decisions.

## 2 Related Work

Traditional methods for leaf-based plant classification often require domain expertise in feature engineering and selection, e.g. based on their colors, shapes, and textures. While these methods have been effective to some extent, they have certain limitations in handling complex and diverse datasets. The emergence of deep learning and neural network techniques, such as convolutional neural networks (CNNs), has led to significant advancements by automating the feature extraction process and achieving higher accuracy [Ra21; Ma22]. In recent years, CNNs have become vital tools for image classification tasks in computer vision. Different CNN architectures like GoogleNet, AlexNet, and ResNet50 have demonstrated good accuracy on diverse applications including leaf-based plant classification [Ch22; MA21]. In [Ku20], ResNet34 is used for plant disease identification with 15,200 images achieving about 99.4% accuracy. [RVD23] introduced the PDICNet model by utilizing ResNet50 for feature extraction like color and textures attaining accuracies of 99.73% and 99.68% and F1 scores of 99.78% and 99.71% on the publicly available datasets plant village and rice plant respectively.

Meanwhile, ResNet50 introduced the advanced concept of skip connections, also known as residual connections. These connections allow information to skip layers in the network, enabling the training of much deeper architectures. ResNet50's residual connections mitigate the vanishing gradient problem that hinders optimization of very deep networks. For large datasets and complex tasks, ResNet50 can achieve better performance [SK19] than counterparts, like GoogleNet, due to its deeper architecture capturing richer features. ResNet50 has also become popular for transfer learning, as its pretrained weights provide generalized feature extraction capabilities that transfer well to new tasks.

A key challenge with any large architectural deep learning models, like ResNet50, is that their immense scale leads to high computational requirements. One solution is to use knowledge distillation [HVD15], as illustrated in Figure 1, where a smaller student model is trained to mimic the representations learned by the larger teacher model through soft target outputs. This allows compressing the complex teacher model into a highly efficient student model with only marginal losses in accuracy [BCN06]. Multiple approaches exist for knowledge transfer, including response-based techniques that focus on mimicking final class probabilities, feature-based techniques that align intermediate representations, and relation-based techniques that utilize relationships between layers [Go21]. For the interpretability of models, explainable AI (XAI) methods can be used, such as LIME [RSG16] and Grad-CAM [Se17], which offer visual explanations that provide transparency into model reasoning. They highlight influential input regions that led to specific predictions. Overall, the combination of state-of-the-art CNNs, knowledge distillation for efficiency, and XAI for transparency is a promising direction to advance deep learning for real-world deployment in applications like plant classification and agricultural systems.




Fig. 1: General overview of knowledge distillation [Go21]

### 3 Materials and Methods

#### 3.1 Dataset description

The dataset used in this work contains images of Ethiopian medicinal plants with a total of 4,026 samples of 8 different medicinal plant species. The different classes for the leaf images named “agam”, “birbira”, “embis”, “endawela”, “gulo”, “qetetit”, “sama”, and “shinet” can be seen in Figure 2. The data is randomly divided into a training set, validation set, and test set, with a ratio of 60% : 20% : 20%. All images were resized to 224 x 224 pixels.



Fig. 2: Sample images from the medicinal plant dataset: agam, birbira, embis, edawela, gulo, qetetit, sama, shinet

To improve generalization of the model, we implemented data augmentation techniques such as random flipping, rotating, and color jitter to simulate the variability of image capture in the real world. Different plant sizes and focal planes are simulated through affine transformations and blurring, while greyscale conversion encourages the model to favor structural features over colors. In addition, oversampling of minority classes balances an unbalanced class distribution so that all medicinal plant types are evenly represented and model accuracy is improved.

The model architecture used in this work is based on ResNet50, a deep CNN that offers advantages in solving complex tasks [Çi21]. Rather than building a neural network from scratch, a pre-trained model is utilized as a basis for transfer learning. Therefore, the accumulation of a model that has been pre-trained can be exploited rather than a model that has no prior knowledge about images.

### 3.2 Feature extraction from leaf images

As the leaf images propagate through the network, the early convolutional layers detect primitive visual patterns like edges and blobs by learning filters that activate on these low-level features [Hi15]. Middle layers combine these into more complex features like vein patterns, leaf tips, lobes, and bases. The final convolution layers synthesize all the lower representations into full leaf representations before the fully connected layers. The ResNet50's multi-layer architecture with five stages of convolutional blocks and skip connections progressively captures higher-level leaf features. By fine-tuning only, the classification head and retaining the pre-trained blocks, the model efficiently extracts generic leaf features. This transfer learning approach utilizes existing knowledge of visual attributes to effectively classify the target leaf classes.

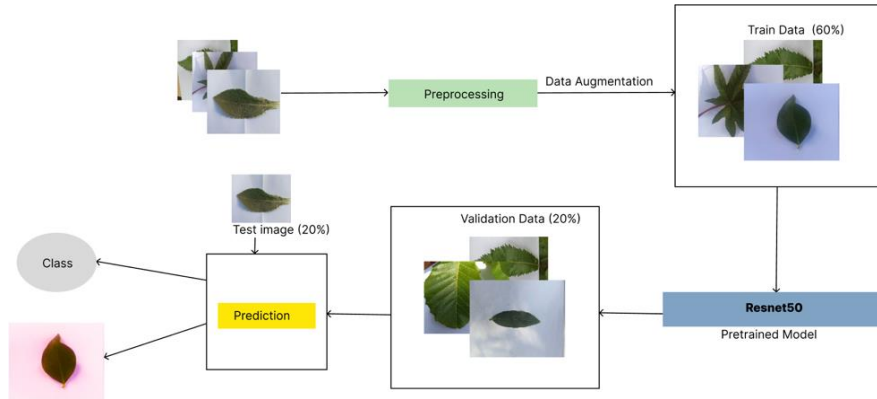


Fig. 3: Teacher model prediction process

Figure 3 illustrates the machine learning process, which starts with the standardization of images through pre-processing techniques and then feeds them into the ResNet50 model. The data is split into 60% training, 20% validation, and 20% test data. In the training phase, the ResNet50 is fine-tuned to classify eight medicinal plant leaves, with validation used to adjust the hyperparameters and testing used to evaluate model accuracy. Finally, the knowledge from the trained ResNet50 (teacher model) is transferred by knowledge distillation to a smaller, specialized student model to improve its performance. The student matches the teacher model's outputs instead of ground truth labels, gaining insights beyond the classification class.

### 3.3 The student model

The student model, based on a pre-trained ResNet50 backbone, uses frozen layers for feature extraction and adds two fully connected layers (FC1 and FC2) for classification. FC1 with reduced units and dropout regularization helps to compress high dimensional features and prevent overfitting. This model processes images through the ResNet50 layer and the added layers and outputs probabilities for 8 leaf classes (one for each medicinal plant) as shown in Figure 4. To summarize, the student architecture is designed to retain the teacher's effective feature learning while using knowledge distillation and a simplified classifier head to compress the model.

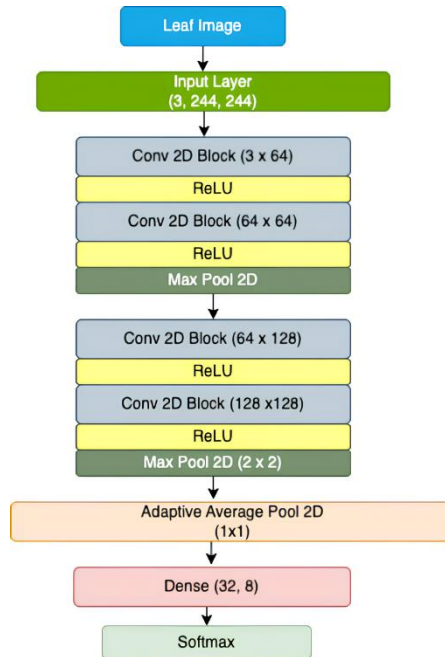


Fig. 4: The student model

### 3.4 Knowledge distillation approach

In this research, we used response-based knowledge distillation by training a student model with the teacher model's probability outputs instead of standard labels. We used the teacher model's output to train the student model. Throughout the training, the student model learned to match the soft targets generated by the teacher model, allowing it to capture the knowledge embedded in the teacher's predictions. This approach helped the student model to learn from the teacher's decision-making process and thus improve its performance. To evaluate the reasoning underlying the predictions, we used LIME and Grad-CAM visualizations to highlight the influential areas in the images that affect the model's decisions, ensuring that relevant features are prioritized over biases in the dataset.

## 4 Results and Evaluation

### 4.1 Training convergence analysis

The optimization of deep learning models like the teacher and student CNNs involves an iterative training process. Visualizing the training and validation loss curves provides insights into how well the models converge over successive epochs. Smoothly decreasing losses and increasing accuracy indicate successful optimization.



The teacher model displays reasonably steady convergence over 100 epochs. However, some instability can be seen in Figure 5 through fluctuations in the loss plots and a 1-3% gap between training and validation accuracy. This suggests some overfitting. Incorporating techniques like learning rate scheduling and oversampling helped smooth out these fluctuations. The controlled decay of the learning rate accelerated convergence while oversampling balanced underrepresented classes. This enabled the teacher to reach 99% validation accuracy, but further improvements in stability are possible which can be observed in Figure 6.

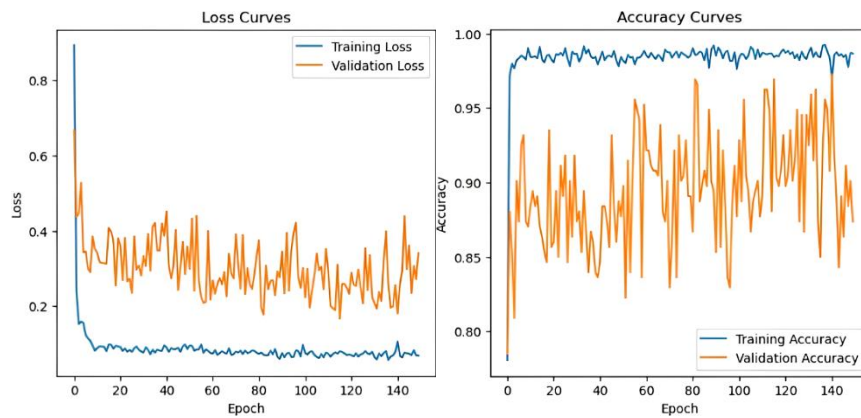


Fig. 5: Loss and accuracy curves of training loop having an imbalanced dataset and of the teacher model without a learning rate scheduler




Fig. 6: Loss and accuracy curves of training loop with a learning rate scheduler and oversampling

Similar to the teacher model, the student model also showed a high variance during training, which was due to an imbalance of classes. The lower number of examples for some classes led to an unstable fit. This was reflected in strong fluctuations in validation loss between 0.36-0.44 and a high difference of 5-15% between training and validation

accuracy, indicating overfitting. To address the class imbalance, the same techniques were used as in the teacher model above, which resulted in better stability of the optimization due to oversampling. The smoother loss curves, the rapid achievement of 99% validation accuracy and the minimal overfitting confirm the positive effects of these techniques.

## 4.2 Model explainability analysis

The need for interpretability in deep learning is crucial, as the models are opaque and do not reveal how the predictions are made. This problem is addressed by techniques such as LIME and Grad-CAM, which ensure that the models base their decisions on meaningful patterns and not on random anomalies in the datasets. LIME highlights influential super pixels in the input image that provided supporting evidence for the predicted class. For the class “agam” prediction, shown in Figure 7, the highlighted leaf shape, venation, and margin agreed with “agam” morphology, indicating the model relied on proper taxonomic markers rather than biases. This aligns with domain knowledge and increases trust. Similarly, for other species, LIME reveals the models focused on relevant shape, color, and texture patterns rather than using the whole image uniformly. The explanations improve transparency by showing which input features led to particular outputs.

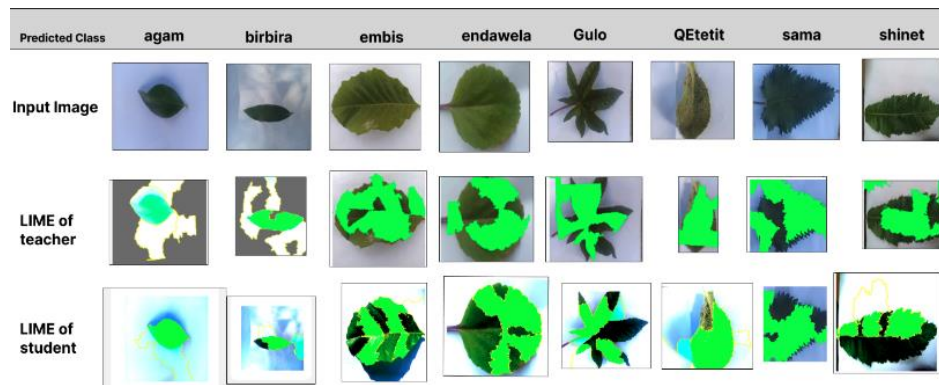


Fig. 7: LIME explainability of teacher and student model where green indicates important features

The Grad-CAM heatmap, shown in Figure 8, highlights important regions for the model’s prediction through color intensity. The regions in deep red indicate the image areas that had the highest activation in the target layer. These deep red regions corresponded to features that strongly influenced the model’s output. The light blue regions in the heatmap had very low activation in the target layer. Thus, the deep red highlights are the most important regions that Grad-CAM identified as contributing most to the model’s prediction.

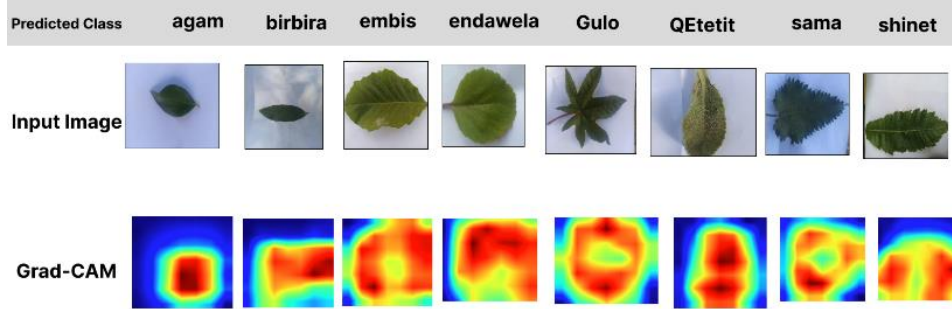


Fig. 8: Grad-CAM explainability of student model where red indicates important features

In summary, the interpretability analysis provides confidence that both models learned robust representations consistent with human botanical knowledge. The explanations align with morphology and reveal no evidence of exploiting dataset shortcuts or biases. This verification of appropriate reasoning enhances overall trust in the high-performing teacher and student models.

### 4.3 Test performance on unseen test dataset

On unseen test data, both models demonstrated adequate generalization capabilities. The teacher model achieved a test accuracy of 98.98%, while the student achieved 96.91%, as shown in Table 1. The student model was able to maintain the teacher's performance and identified each of the eight medicinal plants using unseen test data with a high confidence level between 91.73% and 99.16%, as shown in Table 2. For new samples, each model made confident predictions, demonstrating strong transferred learning. The student model maintained generalization, as evidenced by similar test metrics.

| Metric    | Teacher Model | Student Model |
|-----------|---------------|---------------|
| Accuracy  | 98.98%        | 96.91%        |
| Loss      | 0.0823        | 0.0794        |
| F1-Score  | 0.99          | 0.99          |
| Precision | 0.99          | 0.99          |
| Recall    | 0.99          | 0.99          |

Tab. 1: Comparison of teacher and student model on the test dataset

| Actual Label | Predicted Label | Confidence (%) |
|--------------|-----------------|----------------|
| Embis        | Embis           | 95.11          |
| Sama         | Sama            | 97.24          |
| Gulo         | Gulo            | 99.16          |
| Birbira      | Birbira         | 91.73          |
| Endawela     | Endawela        | 96.04          |
| Shinet       | Shinet          | 98.76          |
| Qetetit      | Qetetit         | 98.81          |
| Agam         | Agam            | 97.06          |

Tab. 2: Test dataset for a batch using the student model

#### 4.4 Mobile application implementation

The “Med Classifier” mobile app, developed with React Native, demonstrates the practical application of a student model derived from knowledge distillation and trained in PyTorch for easy deployment on mobile devices, as shown in Figure 9. It allows users to identify medicinal plants by analyzing images and provides confidence scores and LIME interpretations for each classification.

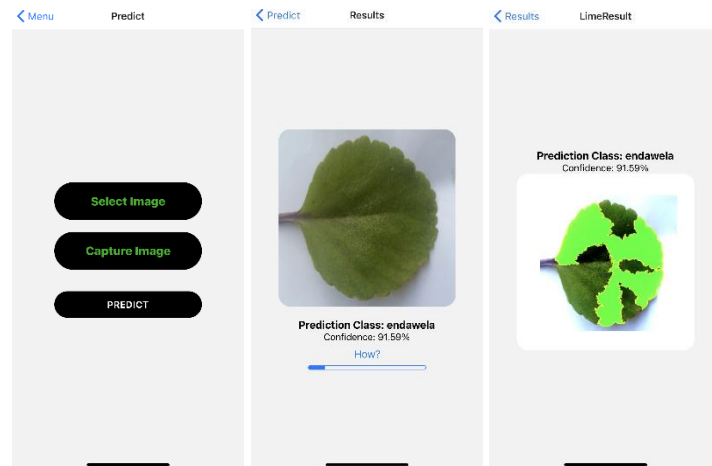


Fig. 9: Mobile application for identifying medicinal plants: image selection/capture (left), prediction results (center), LIME explainability (right)

## 5 Conclusion

This study presents a medicinal plant classification method based on leaf images that comprises two models: a ResNet50-based teacher model and a lightweight student model. For the training data, the teacher model achieved 99.71% accuracy, while the student model achieved 99.0% accuracy. For the unseen test data, the accuracy was 98.98% for the teacher, and 96.91% for the student, despite its lower complexity. Training optimizations, including learning rate planning and oversampling, address challenges such as data imbalance and improve model performance and stability. Explainability analysis using LIME and GRAD-CAM confirms that both models rely on relevant botanical features for classification, ensuring that decisions are based on meaningful attributes rather than the bias of the dataset, strengthening their reliability and consistency with human expertise. In essence, the study underscores the potential of knowledge distillation in crafting efficient models like the student, which can be seamlessly integrated into practical applications like mobile applications, ensuring both accuracy and user trust.

**Acknowledgements:** The research was conducted within the scope of Sustainable Embedded AI and funded by Carl Zeiss.

### Bibliography

- [Ma12] Mamedov, N.: Medicinal plants studies: history, challenges and prospective. *Med Aromat Plants*, vol. 1, no. 8, S. e133, 2012.
- [Du19] Duong-Trung, N. et al.: A combination of transfer learning and deep learning for medicinal plant classification.: *Proc. of the 4th Int. Conf. on Intelligent Information Technology*, S. 83-90, 2019.
- [BFL22] Berihu, M.; Fang, J.; Lu, S.: Automatic Classification of Medicinal Plants of Leaf Images Based on Convolutional Neural Network.: *CCF Conf. on Big Data*, S. 108-116, 2022.
- [KE20] Kayhan, G.; Ergün, E.: Medicinal and aromatic plants identification using machine learning methods. *Balkan Journal of Electrical and Computer Engineering*, vol. 8, no. 1, S. 81-87, 2020.
- [Wu21] Wu, L. et al.: Rare and Endangered Plant Leaf Identification Method Based on Transfer Learning and Knowledge Distillation. *Int. Journal of Agricultural and Environmental Information Systems (IJAEIS)*, vol. 12, no. 4, S. 1-24, 2021.
- [SAZ21] Sarfraz, F.; Arani, E.; Zonooz, B.: Knowledge distillation beyond model compression. In (Unknown Ed.): *25th Int. Conf. on Pattern Recognition (ICPR)*, S. 6136-6143, 2021.
- [De09] Deng, J. et al.: Imagenet: A large-scale hierarchical image database.: *IEEE Conf. on computer vision and pattern recognition*, S. 248-255, 2009.
- [DY19] Dong, X.; Yang, Y.: Teacher supervises students how to learn from partially labeled images for facial landmark detection. In (Unknown Ed.): *Proc. of the IEEE/CVF Int. Conf. on Computer Vision*, S. 783-792, 2019.

- 
- [Ra21] Rasekh, M. et al.: Classification and identification of essential oils from herbs and fruits based on a MOS electronic-nose technology. *Chemosensors*, vol. 9, no. 6, S. 142, 2021.
- [Ma22] Malik, O. A. et al.: Automated Real-Time Identification of Medicinal Plants Species in Natural Environment Using Deep Learning Models - A Case Study from Borneo Region. *Plants*, vol. 11, no. 15, S. 1952, 2022
- [Ch22] Chen, H.-C. et al.: AlexNet convolutional neural network for disease detection and classification of tomato leaf. *Electronics*, vol. 11, no. 6, S. 951, 2022.
- [MA21] Mascarenhas, S.; Agarwal, M.: A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification.: 2021 Int. conf. on disruptive technologies for multi-disciplinary research and applications (CENTCON), S. 96-99, 2021.
- [Ku20] Kumar, V. et al.: Resnet-based approach for detection and classification of plant leaf diseases.: 2020 Int. Conf. on electronics and sustainable communication systems (ICESC), S. 495-502, 2020
- [RVD23] Reddy, S. R. G.; Varma, G. P. S.; Davuluri, R. L.: Resnet-based modified red deer optimization with DLCNN classifier for plant disease identification and classification. *Computers and Electrical Engineering*, vol. 105, S. 108492, 2023
- [SK19] Shorten, C.; Khoshgoftaar, T. M.: A survey on image data augmentation for deep learning. *Journal of Big Data*, vol. 6, no. 1, S. 1-48, 2019.
- [BCN06] Buciluă, C.; Caruana, R.; Niculescu-Mizil, A.: Model compression. In: *Proc. of the 12th ACM SIGKDD Int. Conf. on Knowledge Discovery and Data Mining*, S. 535-541, 2006.
- [Go21] Gou, J. et al.: Knowledge distillation: A survey. *Int. Journal of Computer Vision* 129, S. 1789-1819, 2021.
- [RSG16] Ribeiro, M. T.; Singh, S.; Guestrin, C.: "Why should I trust you?" Explaining the predictions of any classifier. In: *Proc. of the 22nd ACM SIGKDD Int. Conf. on Knowledge Discovery and Data Mining*, S. 1135-1144, 2016.
- [Se17] Selvaraju, R. R. et al.: Grad-cam: Visual explanations from deep networks via gradient-based localization. In: *Proc. of the IEEE Int. Conf. on Computer Vision*, S. 618-626, 2017.
- [Çı21] Çınar, A. et al.: Classification of pneumonia cell images using improved ResNet50 model. *Traitement du Signal* 38(1), S. 165-173, 2021.
- [Hi15] Hinton, G. et al.: Deep learning. *Nature* 521(7553), S. 436-444, 2015.

## Towards on-line monitoring and route re-planning in arable crop harvest

Santiago Focke Martinez<sup>1</sup>, Isaak Ihorst<sup>2</sup>, Thomas Wiemann<sup>1,3</sup> and Felix Zeiß<sup>2</sup>

**Abstract:** Route planning for farming machines can be used as a tool to improve the efficiency of arable farming operations. However, discrepancies between actual process parameters and the parameters used for route planning might result in the need to re-plan using updated/corrected planning parameters. This paper presents a concept for process monitoring and route re-planning in arable harvesting operations, together with updates on a previously presented route-planning tool developed to support re-planning during harvesting, and a set of monitoring components developed to generate field worked-area grid-maps and to monitor deviations between planned inner-field tracks and actual machine transit. The newly implemented re-planning features in the route planner and the monitoring components were tested under a simulated harvesting scenario.

**Keywords:** route planning, smart farming, spatial reasoning, ontologies

### 1 Introduction

In the last few years, route planning for arable farming machines has been introduced as a tool aiming to improve the efficiency of farming operations. These improvements can be focused on topics such as operational costs, energy consumption, in-field transit, and soil compaction, among others [Nø22; Mo20; NZ20]. In some scenarios, the precise values of some parameters used for route planning are unknown and can only be estimated. In harvesting operations, for instance, it is necessary to know the amount of yield that will be harvested in a certain area to correctly compute the harvesting windows based on the machines' bunker capacities. Yield estimates, e.g., average yield mass per area unit (t/ha), can be used for planning, but significant deviations to the estimates could render the plan obsolete after some time during the actual harvesting campaign. Plan deviations, such as transit of the machines differing from the planned paths, might have the same effects for the remainder of the operation. In general, several parameters used for planning might have to be updated or corrected while the field harvest is being executed, leading to the need of corresponding updated planned routes, which must not only consider the updated parameters, but also the current states of the field and the participating machines. This paper presents a concept for process monitoring and route re-planning in arable harvesting

---

<sup>1</sup> German Research Centre for Artificial Intelligence (DFKI), PBR, Hamburger Straße 24, 49084 Osnabrück, santiago.focke@dfki.de

<sup>2</sup> University of Osnabrück, Hamburger Straße 24, 49084 Osnabrück, isaak.ihorst@uos.de, fzeiss@uni-osnabrueck.de

<sup>3</sup> Hochschule Fulda, Leipziger Straße 123, 36037 Fulda, thomas.wiemann@informatik.hs-fulda.de

operations. The route planning tool presented in [Fo21; FH22] has been extended to support re-planning for harvesting scenarios where one capacitated machine harvests a field which has a headland surrounding the inner field (core). A set of monitoring components has been developed to generate grid-maps corresponding to the currently worked area, to detect discrepancies between the harvester's actual transit and the computed inner-field tracks and to generate an updated reference line to correct said tracks for future planning. The updated route planner and presented monitoring components were tested in a simulated harvesting scenario.

### 1.1 Related work

Precision farming and controlled traffic farming have been introduced in agriculture in the last decades aiming to improve farming processes, with route planning being a topic of interest for researchers, machine manufacturers and farmers. Route optimization can lead to reductions of energy consumption, labour costs, traffic intensity in the field, and soil compaction, among other benefits. Route planning tools have been developed to assist in arable farming in neutral material flow operations (NMFO), i.e., no material is either inserted to or extracted from the field, e.g. tillage; as well as input- and output- material flow operations (IMFO, OMFO), such as fertilizing and harvesting, respectively. [Ed17] presents an optimised infield route planning tool for NMFOs targeting reductions on traffic intensity, which is evaluated by comparing the planned routes with the routes driven by a professional operator during mowing operations. [BSG12] presents a decision support system which provides the tracks' transversal sequence to work the field by agricultural vehicles carrying time-depended loads, aiming to minimize the risk for soil compaction. The system was demonstrated and tested for units used in organic fertilization. [VS21] also presents a planning method for capacitated field operations such as organic fertilization, which involves two simultaneous optimization criteria: minimization of non-working distance; and optimization of application rates. In [VZS20], another approach for the minimization of total nonworking travel distance in IMFOs was presented for a manure case study. In this case, the approach involves the presence of multiple depots where the machines reload the material. [Sc13] presented a spatio-temporally constraint planning method for a wheat harvesting scenario where capacitated harvesters are assisted by transport vehicles during the operation. The approach in [Nø22] generates routes for harvesters and transport vehicles in grain harvest operations featuring multiple field access points, and the possibility of stationary and on-the-go overloading. In this case, the generation of routes is done prior to and during the actual execution of the operation and aims to reduce travel distances and soil compaction. In [FH22], a route planning tool for OMFOs was presented supporting two working scenarios: one capacitated harvester harvesting without assistance; and one non-capacitated harvester being assisted by one or more transport vehicles. This tool generates machine routes in the spatio-temporal domain aiming to improve the operation efficiency in terms of process duration or soil protection.

The current approaches mostly focus on the planning of the complete operation, where the planned routes are to be executed by a robot or a machine operator, and disregard potential



deviations between the inputs and outputs of the planning tools (including the estimated parameters used for planning), and the actual process parameters and execution. Significant discrepancies might lead to the need of re-planning on partially worked fields based on the current state of the machines, and planning must be executed on the run. To the best of our knowledge, on-line replanning is not a feature that most of the current approaches incorporate or support.

Event detection holds significance across diverse domains, including Environmental Monitoring, Business Intelligence, and IoT [RMG20; Yu20]. Integrating semantic knowledge into event detection processes enhances their accuracy and contextual understanding. However, within the agricultural domain, the utilization of semantic web technologies for problem-solving remains a relatively underexplored area [Du19]. Furthermore, the combination of ontological knowledge with event detection methodologies remains uncommon in this specific domain. [Du19] introduce a semantic model for annotating IoT data streams and generate semantic events applicable to smart city and smart living use cases. [DWH19] introduces SEMAP, a framework that combines spatially annotated data, semantic knowledge, and sensor information to understand and track harvesting campaigns in agriculture. It integrates a spatial database system alongside a knowledge-based system, enabling comprehensive queries for improved agricultural process understanding. [Ni23] integrates SEMAP, with a stream processing engine for real-time analysis of spatial relations. Using Complex Event Processing, it detects spatio-temporal changes and aims to balance computational costs with high-frequency updates. [Mo21] emphasizes machine learning for identifying irregular behaviour within GPS data collected from combine harvesters during wheat harvesting. However, this approach only detects that an anomaly has occurred, without returning knowledge about detected event.

Multiple databases have been developed for storing and querying ontologies containing spatial data. Deeken et al. [DWH18] utilize Apache Jena for managing background knowledge, while Postgis is used for spatial operations. Graph databases such as GraphDB, RDF4J, or Apache Jena can efficiently manage geospatial data, enabling quick spatial queries [Li22]. [Hu19] concluded that GraphDB demonstrates superior performance in handling topological queries, establishing its suitability for practical, real-world applications.

## 2 Methods

The proposed system (Fig. 1) consists of a set of monitoring components and a route planner. The monitoring components use sensor data obtained from the machines in the field to analyze the process and generate the updated parameters used by the route planner. Sensor data include GPS information and yield mass measurements (if available). These components will generate a worked-area grid-map (WAM), as well as updated planning parameters if needed, e.g., corrected average yield-mass in the field or a corrected reference-line for the inner-field tracks. The route planner will use the WAM, current state

of the machines, and other updated parameters to plan the routes for the remainder of the field harvest. Because the route planning process can be computationally expensive (e.g., for large fields), continual re-planning might not be viable. The monitoring components are therefore developed to identify situations, events, and significant deviations to trigger re-planning only when needed. Moreover, the route planner can be configured to only plan a part of the remainder of the operation (e.g., maximum  $x$  harvesting windows).

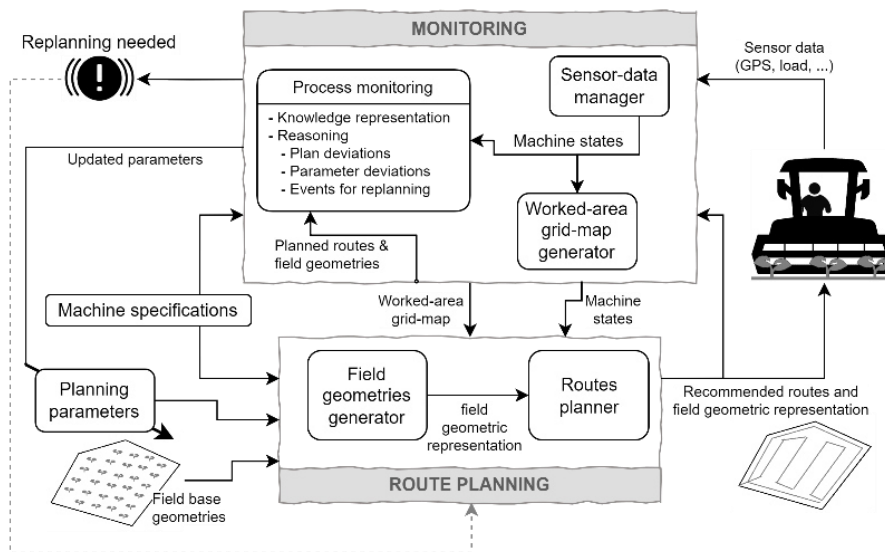


Fig. 1: Components and communication within the proposed monitoring and route planning system

The process monitoring components detect events that lead to re-planning and update and correct the planning parameters of the route planner, based on sensor data, the current states of the machines and the field, as well as the field geometric representation and routes of the current reference plan. To find situations that require re-planning, an OWL ontology is used, which describes concepts, properties, rules, and relationships for harvesting processes [DWH19]. Geospatial relationships can be inferred using the ontology with GeoSPARQL. SPARQL queries have been implemented to query whether a critical situation has occurred. The core of the monitoring component is the GraphDB Server, a graph-based database which serves as the primary repository for the OWL ontology and spatial data. The GraphDB server receives machine sensor data via MQTT. Before storing it, the data undergoes pre-processing, including GPS data filtering for improved accuracy, especially in the absence of Real-Time Kinematic (RTK) data. Additionally, the program calculates machine orientation based on positions recorded over the last driven meters. The monitoring component employs GEOSPARQL queries to detect deviations from the predefined plan. Utilizing a graph-based database such as GraphDB equipped with an

ontology for spatial reasoning facilitates the execution of broader queries. For instance, consider a query that aims to list all entities within a field. The ontology within this setup defines concepts and relationships, such as categorizing a tractor as a movable resource and establishing that a movable resource pertains to an object with a position. Additionally, it denotes that a field possesses a boundary. Leveraging these defined relationships and concepts, querying to retrieve all entities within a field becomes notably straightforward and intuitive.

This paper focuses on one monitoring feature: the detection of inner-field tracks' deviations and corresponding updates of the reference line. This feature was developed and tested under two assumptions: 1) the reference line follows an AB-format (i.e., 2-point line); and 2) the headland width remains unchanged with respect to the originally planned field geometric representation (i.e., there are no changes in the inner-field boundary). The detection of deviations from the planned reference line is carried out through a series of criteria, which were implemented as a SPARQL-Query:

1. **Location:** The machine's location is verified to be inside the inner-field boundary, i.e., excluding the headland region.
2. **Orientation Stability:** The current orientation of the machine is examined for convergence, and it should not have changed significantly over the last 5 seconds.
3. **Alignment Criteria:** A deviation from the AB-line is detected if any of the following conditions are met:
  - 3.1. **Offset Criterion:** The machine's orientation aligns with the AB-line, but it has an offset of at least 30 centimeters. This condition accounts for lateral shifts from the desired path.
  - 3.2. **Angular Difference Criterion:** The orientation of the machine and the AB-line differ by at least 0.3 degrees. This parameter addresses angular deviations in the machine's trajectory.

When a deviation is detected, the system generates a new AB-line based on the calculated orientation and forwards it to the planning component for corrective action. A simple query which returns all machines which are within the inner field is presented below.

```
SELECT ?machine WHERE {
    ?machine a soil:harvester ;
             soil:hasAvgPoint1 ?machine_position .
    ?machine_position geo:asWKT ?machine_position_wkt .
    ?field a soil:field ;
           soil:inner_boundary ?inner_boundary .
    ?inner_boundary geo:asWKT ?inner_boundary_wkt .
```

```

    FILTER (geof:sfWithin(?machine_position_wkt,
    ?inner_boundary_wkt)) }

```

Additionally, a component has been developed to generate and update (online) the worked-area grid-map (WAM). It periodically receives the location of the harvester and updates the cells of grid-map that overlap with the projection of the transited segments into the ground based on the machine's working-width. The cells of the WAM have values between 0 (worked) and 1 (not worked).

The route planning tool presented in [Fo21; FH22] has been extended to support the re-planning features for harvesting scenarios where one capacitated machine harvests a field with a surrounding headland. The overall planning process is divided into three main steps: 1) the generation of the field geometric representation, including the headland and inner-field boundaries and tracks; 2) the generation of the 'base' route, which represents the route that the harvester will follow to cover the field area without considering the capacity constraints or unloading activities; and 3) the final planning of the harvester route including extraction of material and transit to and from the unloading locations, based on the base route and a constrained graph-based search for the non-working transit segments. In the final step, it is possible either to plan for the remainder of the process, or to generate a partial plan for a given number of harvesting windows. For on-line replanning, the field geometric representation is only regenerated if some planning parameters are updated, e.g., the headland width or the reference line used to create the inner-field tracks. Based on the field geometries and WAM, the planner identifies the tracks that have not been completely worked. This set of tracks, together with the current location of the machine, are used to generate the updated base route. Finally, the field geometries, base route and current machine state are used to update the graph properties and plan the overall harvester route for the remainder of the operation.

The monitoring and re-planning features were tested in a simulated scenario on the test field shown in Fig. 2. The field has an area of 0.79 ha and an average yield mass of 90 t/ha. The process was planned with a headland width of 32.4 m and a harvester with a working width of 2.7 m, a bunker mass capacity of 30 t, and a default working speed of 9 km/h. First, two different plans were generated for the completely unharvested field: *PlanAB*, using an inner-field tracks' reference line  $\overline{AB}$  (Fig. 2) with the starting location of the machine being outside of the field near corner B; and *PlanCD*, using reference line  $\overline{CD}$  with the initial location near corner C. The angular difference between  $\overline{AB}$  and  $\overline{CD}$  is  $1.24^\circ$ . Because of the differences in angle and location between the two reference lines, the inner-field tracks in the geometric representation of the field differ for both plans. The plans were generated following a process-duration optimization criteria, where switching points between harvesting windows in the inner-field could only be located at the track-ends and the sequence in which the tracks are worked follow an adjacent-track-next strategy (i.e., the tracks are harvested in order, from one side of the field to the other).

### 3 Results

*PlanAB* was used to test the re-planning features of the route planner. The routes generated for the virgin field (Fig. 2, upper right) were sampled with a period of 1s, a random GPS deviation of up to 1m was added to each sample. Those deviated samples were fed to the WAM generator until a given cut timestamp, at which a WAM was generated. Fig. 2 shows three WAMs generated at different cut timestamps: WAM1, when the harvester was harvesting the headland; WAM2, when the harvester had just finished harvesting an inner-field track and was driving to unload the yield; and WAM3, when the harvester was harvesting an inner-field track. The WAMs, machine locations, and machine loads at the respective cut timestamps were fed to the route planner to generate the respective routes for the remainder of the process, shown in Fig. 2. For the plans of WAM1 and WAM3, the harvester continues harvesting the field where it left off in the partially harvested track, whereas for WAM2 the harvester is sent to unload the yield before returning to the field to continue with the remaining unharvested tracks.

To test the detection and update of inner-field reference lines, *PlanAB* was used as reference, whereas *PlanCD* was used to simulate the harvester's actual transit. As before, *PlanCD* was used to generate a sample every second with a random deviation and send it to the monitoring components. To assess the effect of the GPS accuracy, three tests were carried out with different maximum deviations: 1m, 0.1m and no deviation. As the harvester enters the field near corner C in *PlanCD* (as opposed to corner B where *PlanAB* starts), a replanning command was manually executed shortly after the harvester entered the field, generating a new reference plan *PlanAB\** with the updated machine state and the respective WAM. Note that the monitoring components have not identified a deviation in the reference line, hence *PlanAB\** is generated with reference line  $\overline{AB}$  again. However, the route segments corresponding to headland harvesting, including the respective transit to the unloading locations, are similar for *PlanAB\** and *PlanCD*, hence no significant deviations to the plan occur until the start of the inner-field harvesting. At some point after the harvesting of the inner field starts, the monitoring component detects a deviation from the reference line. The component estimates the actual reference line being followed by the harvester, and replanning is triggered with the updated reference line  $\overline{EF}$  and the corresponding WAM and machine state. Table 1 shows the angular differences between  $\overline{AB}$ ,  $\overline{CD}$  and  $\overline{EF}$ , the time needed by the monitoring component to detect and correct the reference line, and the distance travelled by the machine in the track before the detection was made. The latter two were computed by taking as reference the timestamps and locations of the route-points of the simulated plan *PlanCD*. Fig. 3 shows the updated WAM and reference line  $\overline{EF}$  generated for route replanning for a maximum deviation of 1m, as well as the resulting planned route for the remainder of the process.

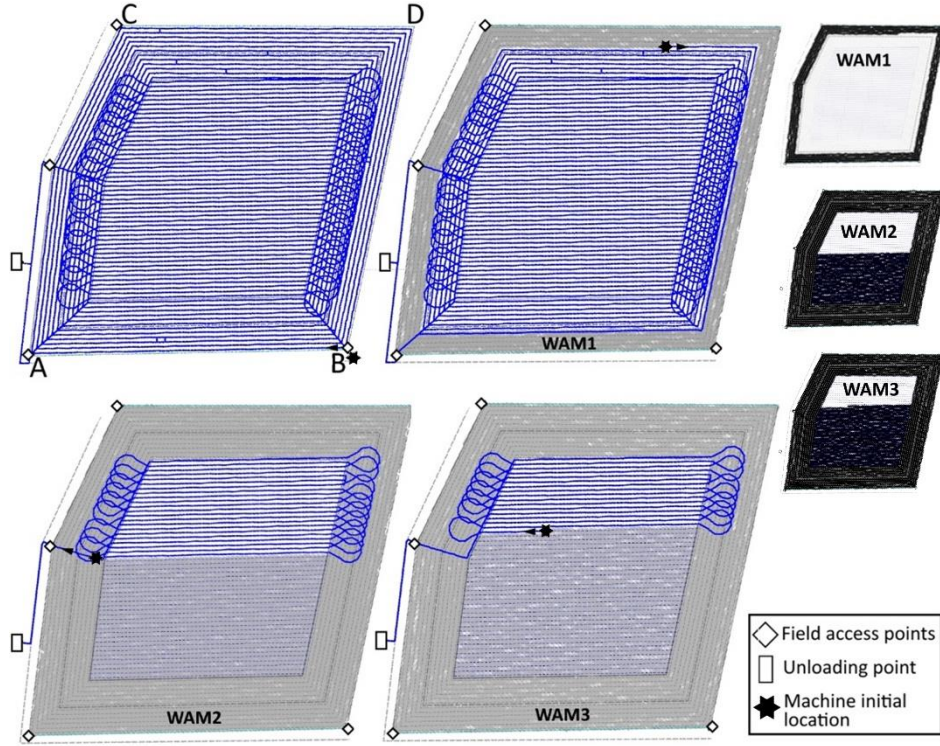


Fig. 2: Planned routes for the virgin field and for replanning using three worked-area grid-maps

|  | Maximum deviation |         |         |
|--|-------------------|---------|---------|
|  | 0 m               | 0.1 m   | 1 m     |
| Angular difference between $\overline{AB}$ and $\overline{EF}$ [°] | -1.236            | -1.1923 | -1.0980 |
| Angular difference between $\overline{CD}$ and $\overline{EF}$ [°] | 1.23e-6           | 0.0441  | 0.1385  |
| Detection time after entering the inner-field [s]                  | 23.0498           | 22.9872 | 24.0753 |
| Travelled track distance before detection [m]                      | 57.7416           | 57.5913 | 60.3161 |

Tab. 1: Test results for the detection and correction of inner-field tracks' reference line with  $PlanAB$  as reference plan and using  $PlanCD$  to simulate the machine transit

A second test was performed using  $PlanAB$  both as reference plan and to simulate the machine transit, in order to check for false-positive detections. The simulations were run again with random GPS deviations of maximum 0, 0.1, and 1 meters. For the former two, the monitoring component did not detect a deviation on the inner-field tracks. With the

higher GPS deviation of 1m, the component detected a track deviation and updated the reference line. The angular difference between  $\overline{AB}$  and the (wrongly) corrected reference line was  $0.504^\circ$ .




Fig. 3: Worked-area grid-map (top left), updated reference line EF (top right), and planned harvester route (bottom) after detection of reference line deviation

Furthermore, runtime tests were conducted for query execution, examining three specific queries. The first query (Q1), as described earlier, checks for deviations from the planned reference line alignment, the second query (Q2) returns all machines currently present in the field, as in the SPARQL example presented in the previous section, and the third (Q3) provides current machine positions and filtered orientation data. Q1 is the most complex query, requiring multiple geometrical computations to check for alignment deviations, whereas Q2 is simpler, involving a single geometrical computation to verify point-in-polygon placement. Q3 solely retrieves data from the database. The tests were conducted during the ongoing simulation of a harvesting campaign involving three machines. They were performed on a computer equipped with an Intel Core i7 7700 processor and 40GB of RAM. A total of 100,000 repetitions were carried out, and the statistical metrics, including the mean, median, standard deviation, maximum, and minimum values, were

computed. The results are summarized in Tab. 2. Notably, all queries were consistently executed in less than one second, highlighting the system's ability to rapidly assess if a new plan is required. The first query exhibits a longer execution time but remains under the one-second threshold. The ability to perform these critical assessments in less than one second is crucial for ensuring the system's responsiveness and its capacity to make timely decisions.

|           | Runtimes [ms] |      |      |
|-----------|---------------|------|------|
|           | Q1            | Q2   | Q3   |
| Mean      | 17.3          | 4.5  | 4.5  |
| Median    | 16.5          | 4.4  | 4.3  |
| Min       | 13.2          | 2.0  | 2.2  |
| Max       | 420.0         | 30.0 | 41.8 |
| Deviation | 2.8           | 1.2  | 1.1  |

Tab. 2: Evaluation of execution times for three queries. All measurements are in milliseconds

## 4 Conclusions

This paper presents a concept for process monitoring and route re-planning in arable harvesting operations, which comprises a set of process monitoring components and a route planner.

The route planning tool presented in [Fo21; FH22] has been extended to support re-planning features using a worked-area grid-map (WAM) generated based on the GPS data from the harvester. The new planner features were satisfactorily tested under a simulated scenario. It is important to note that the process of identification of ‘worked’ states of tracks’ segments implemented in the planner is highly dependent on the correctness of the generated field geometry representation and therefore on the planning parameters used to generate it, including the reference line for inner-field tracks and headland width. This is why proper monitoring and correction of these planning parameters is crucial. The identification is also dependent on the accuracy and resolution of the WAM. For instance, if the WAM resolution is too high with respect to the harvester’s working width, the identification of ‘worked’ state of the track segments might fail.

A process monitoring component used to detect deviations between the planned inner-field tracks and the harvester actual transit was also developed and tested under simulated scenarios using two different plans (routes and field geometries) generated by the route planner: *PlanAB* and *PlanCD*. *PlanAB* was used as reference plan, whereas *PlanBC* was used to simulate the actual machine transit with random GPS deviations. The component was able to satisfactorily detect and correct the inner-field tracks’ reference line and trigger



re-planning around 23s after the start of the inner-field harvest. *PlanAB* was also used to simulate the machine's transit to test for false positives, failing only when a high GPS deviation was used for the simulation.

The time in which the reference line is detected can be improved by adjusting the rules related to filtering in cases where high GPS accuracy can be guaranteed (e.g., when using RTK). Higher GPS accuracy will also reduce the detection of false positives. Furthermore, an Extended Kalman Filter (EKF) could be used to integrate GPS data with additional information, such as speed and steering angle (if provided by the machines), to enhance accuracy and expedite the detection of deviations.

The monitoring components will be extended to integrate features such as detection of discrepancies of other planning parameters (e.g., headland width and harvested yield mass) and corresponding parameter correction, detection of an early/late harvesting window's end, and detection of deviations from the machine path. Furthermore, stream processing, for instance, using Apache Flink, will also be integrated into the monitoring component. This allows for shorter queries by executing only specific partial queries depending on the process's state. Additionally, preprocessing data within the stream processing pipeline eliminates the need for continuous query execution to check for critical states. For instance, when the machine is idle or in a state where it is certain that no re-planning is required.

**Acknowledgements:** The SOILAssist project is funded by the Federal Ministry of Education and Research (BMBF) within the framework of the BonaRes-initiative (grant no. 031B1065B, 031B0684D). The DFKI Niedersachsen (DFKI NI) is sponsored by the Ministry of Science and Culture of Lower Saxony and the VolkswagenStiftung.

## Bibliography

- [BSG12] Bochtis, D.D.; Sørensen, C.G.; Green, O.: A DSS for planning of soil-sensitive field operations. *Decision Support Systems*, 33(1), p. 66-75. 2012.
- [DWH18] Deeken, H.; Wiemann, T.; Hertzberg J.: Grounding semantic maps in spatial databases. *Robotics and Autonomous Systems*, 105, p 146-165, 2018.
- [DWH19] Deeken, H.; Wiemann, T.; Hertzberg, J.: A spatio-semantic approach to reasoning about agricultural processes. *Applied Intelligence*, 49(11), 3821-3833. 2019.
- [Du19] Drury, B. et al.: A survey of semantic web technology for agriculture, *Information Processing in Agriculture* 6/4, p. 487-501, 2019.
- [Ed17] Edwards, G. et al: Route planning evaluation of a prototype optimised infield route planner for neutral material flow agricultural operations. *Biosystems Engineering* 153/17, p. 149-157, 2017.
- [El20] Elsaleh, T. et al.: IoT-Stream: A lightweight ontology for internet of things data streams and its use with data analytics and event detection services, *Sensors* 20/4, p. 9553, 2020.

- [FH22] Focke Martinez, S.; Hertzberg, J.: Route-planning in output-material-flow arable farming operations aiming for soil protection, in 42. GIL-Jahrestagung, Künstliche Intelligenz in der Agrar- und Ernährungswirtschaft, Bonn, 2022.
- [Fo21] Focke Martinez, S. et al: Overview of a route-planning tool for capacitated field processes in arable farming, in 41. GIL-Jahrestagung, Informations- und Kommunikationstechnologie in kritischen Zeiten, Bonn, 2021.
- [Hu19] Huang, W. et al.: Assessment and benchmarking of spatially enabled RDF stores for the next generation of spatial data infrastructure, ISPRS International Journal of Geo-information, 8/7, p. 310, 2019.
- [Li22] Li, W. et al.: Performance benchmark on semantic web repositories for spatially explicit knowledge graph applications, Computers, environment and urban systems, 98, p 101884, 2022.
- [Mo20] Moysiadis, V. et al: Mobile Robotics in Agricultural Operations: A Narrative Review on Planning Aspects. Applied Sciences 10/10, p. 3453, 2020.
- [Mo21] Moso, J.C. et al: Abnormal behavior detection in farming stream data, in Communications in computer and information science, p. 44–56, 2021.
- [Ni23] Niecsch L.; Deeken, H; Wiemann, T.: Detecting spatio-temporal Relations by Combining a Semantic Map with a Stream Processing Engine, 2023 IEEE International Conference on Robotics and Automation (ICRA), 2023
- [Nø22] Nørremark, M. et al: In-Field Route Planning Optimisation and Performance Indicators of Grain Harvest Operations. Agronomy 12/5, p. 1151, 2022.
- [NZ20] Nilsson, R.S.; Zhou, K. Decision Support Tool for Operational Planning of Field Operations. Agronomy 10/2, p. 229, 2020.
- [RMG20] Rhayem, A.; Mhiri, M.; Gargouri F.: Semantic Web Technologies for the Internet of Things: Systematic Literature Review, Internet of Things, vol. 11, p. 100206, Sep. 2020, doi: 10.1016/j.iot.2020.100206.
- [Sc13] Scheuren, S. et.al: Spatio-Temporally Constrained Planning for Cooperative Vehicles in a Harvesting Scenario. KI - Künstliche Intelligenz, 27, p. 341–346. 2013.
- [VZS20] Vahdanjoo, M.; Zhou, K.; Sørensen, C.G. Route Planning for Agricultural Machines with Multiple Depots: Manure Application Case Study. Agronomy, 10(10), p. 1608, 2020.
- [VS21] Vahdanjoo, M.; Sørensen, C.G. Novel Route Planning Method to Improve the Operational Efficiency of Capacitated Operations. Case: Application of Organic Fertilizer. AgriEngineering, 3(3), p. 458-477. 2021.
- [Yu20] Yu, M. et al.: Spatiotemporal event detection: a review, International Journal of Digital Earth, 13/12, p. 1339–1365, 2020.

## Haftung beim Einsatz von KI-Systemen im Agrarsektor

### Regulatorische Bestrebungen und vertragliche Maßgaben

Klaus Gennen<sup>1</sup>

**Abstract:** Das derzeitige deutsche Haftungsrecht erweist sich als den Besonderheiten von KI-Systemen nicht vollends gewachsen. Insbesondere die Anwender von KI werden in Fragen der Beweisführung gegenüber der Herstellerseite oft relativ schlechter gestellt. Dem wirkt die EU durch die anstehende Harmonisierung der nationalen Haftungsregime im Bereich der Produkthaftung im Allgemeinen und der Haftung bei KI im Speziellen entgegen. Der Beitrag erläutert die bestehende Rechtslage im unternehmerischen Verkehr und die Bestrebungen, die Haftung für KI zu vereinheitlichen und zu vereinfachen. Hierneben werden de lege lata vertragliche Gestaltungsmöglichkeiten für eine Eindämmung von Risiken erörtert.

**Keywords:** KI-System, Mängelhaftung, Produkthaftung, Produzentenhaftung, Anwenderhaftung, Produkthaftungs-RL-E, KI-Haftungs-RL-E, Vertragsgestaltung

## 1 Einleitung, Beispiele in der praktischen Anwendung

Künstliche Intelligenz (KI) ist gemäß dem (bei Einreichung dieses Beitrags aktuellen) Vorschlag des EU-Parlaments für eine Definition des Begriffes „KI-System“ in der KI-Verordnung [AI-Act] (Art. 3 Abs. 1 Nr. 1 Entwurf KI-VO [EU23, S. 131]), „*ein maschinengestütztes System, das so konzipiert ist, dass es mit unterschiedlichem Grad an Autonomie operieren kann, und das für explizite oder implizite Ziele Ergebnisse wie Vorhersagen, Empfehlungen oder Entscheidungen hervorbringen kann, die das physische oder virtuelle Umfeld beeinflussen*“. Bezogen auf vier aufsteigende denkmögliche Stufen der Leistungsfähigkeit (1) Reactive Machine, (2) Limited Memory, (3) Theory of Mind und (4) Self Awareness befinden sich aktuelle Systeme der generativen KI auf der Stufe (2).

Der gewerbliche Einsatz von KI-Systemen im Agrarsektor schreitet mit unterschiedlichen Einsatzszenarien voran. Dennoch stehen viele Beteiligte dem Einsatz von KI kritisch gegenüber. Grund sind u. a. die tw. noch tatsächlich oder vermeintlich ungeklärten Rechtsfragen im Zusammenhang mit dem Einsatz der KI. Insbesondere ist zu beleuchten, wer in welcher Weise für fehlerhafte Ergebnisse bzw. für Folgen des Einsatzes der KI haftet. Die Thematik der Haftung im Zusammenhang mit dem Einsatz von KI sei anhand einiger weniger Beispiele veranschaulicht: (1) Eine Technologie bestimmt unter Einsatz u. a. von

---

<sup>1</sup> Professor (Teilzeit) für IT-Recht und Recht des elektronischen Geschäftsverkehrs an der TH Köln, Kölner Forschungsstelle für Medienrecht, klaus.gennen@th-koeln.de; Partner von LLR Rechtsanwälte Partnerschaft mbB, Köln, Leitung Dezernat Digitalisierung/Datenschutz, klaus.gennen@llr.de

Sensordaten an Maschinen und GPS-Satellitendaten und unter Einlesen weiterer, frei verfügbarer Daten das Ertragspotenzial von Teilflächen eines Ackers. Mithilfe dieser Daten können präzise Ertragskarten erstellt werden, um eine auf jedes Teilstück zugeschnittene Anpassung der Saat- und Düngemittel vorzunehmen. So werden Betriebsmittel eingespart, eine Ersparnis von Dünger trägt zudem zum Umweltschutz bei. Wenn eine hierbei eingesetzte KI fehlgeht, kann eine zu gering ausgegebene Menge an Saaten oder Dünger zu niedrigerem Ertrag und wirtschaftlichen Einbußen führen, eine Überdosierung von Dünger zu Umweltschäden und dem Wegfall von Agrarbeihilfen. (2) KI könnte den Einsatz von Transponderhalsbändern in der Viehzucht begleiten, wo sie durch Aktivitätstracking zu einer frühzeitigen Erkennung von Krankheiten oder anderem normabweichendem Verhalten der Tiere führen soll [BU22]. Erkrankte Tiere können früh abgesondert und behandelt werden, was zu einer Ertragsoptimierung führen und eine Förderung des Tierwohls darstellen kann. Eine Fehleinschätzung der KI kann hingegen zu wirtschaftlichen Einbußen durch unrichtig diagnostizierte Krankheit/ Gesundheit führen; die Fehleinschätzung wirkt sich mglw. auch auf das Tierwohl aus. (3) Neben wirtschaftlichen Schäden und denen an Umwelt und Tierwohl sind durch fehlerhafte Entscheidungen von KI auch unmittelbare Schäden an Leib und Leben von Menschen denkbar, beispielsweise in Anwendungsszenarien wie der autonomen Maschinenführung auf der Ackerfläche, wie dies auch im Zusammenhang mit autonomem Fahren im Straßenverkehr thematisiert wird.

## **2 Gesetzlicher Status quo zur Haftung**

### **2.1 Ausgewählte Grundsätze im deutschen Haftungsrecht**

Zu unterscheiden ist zwischen Haftung aus Vertrag und aus Delikt. Vertragliche Haftung meint die Haftung aus einem (i. d. R. zweiseitigen) Vertragsverhältnis, z. B. die Mangelhaftung. Die Ansprüche der Kundenseite sind bei der Mangelhaftung darauf gerichtet, den Mangel zu beheben bzw. den Vertrag zu beenden, wenn die Behebung scheitert, aber auch den durch den Mangel auf der Erwerberseite entstandenen Schaden auszugleichen. Deliktische Haftung meint demgegenüber die außervertragliche Haftung eines Rechtssubjekts gegenüber einem anderen infolge eines Eingriffs in ein geschütztes Rechtsgut (z. B. Eigentum oder Gesundheit); zwischen den beteiligten Rechtssubjekten muss kein Vertrag bestehen.

Im deutschen Haftungsrecht gilt das Verursacherprinzip, wonach der Ersatz des Schadens durch den Verursacher erfolgt. Dabei gibt es Verschuldenshaftung, die (i) widerrechtliches Verhalten (Vertragsverstoß oder Delikt) sowie (ii) Verschulden (i. e. Vorsatz oder Fahrlässigkeit) voraussetzt, und daneben Fälle der Gefährdungshaftung, bei der es um die Haftung für Schäden geht, die sich aus einer an sich erlaubten Gefahr ergeben (z. B. Betrieb eines Kfz, Produkthaftung oder Futtermittelproduktion vgl. § 24 LFGB).

In all diesen Fällen ist der Schädiger eine Rechtspersönlichkeit, also eine rechtsfähige Person oder Einheit, ein Rechtssubjekt. Rechtspersönlichkeit wird einer KI als Produkt in der

juristischen Literatur nicht (ernsthaft) zugesprochen. Für Zwecke der Haftung wird eher auf das Rechtssubjekt „hinter“ der KI abgestellt, z. B. auf Hersteller oder Programmierer. Komplizierter ist es jedoch, soweit es um autonome, selbstlernende Systeme gehen wird: Da diese Art von KI ab einem gewissen Zeitpunkt selbstständige Entscheidungen treffen soll, erscheint ein Rückgriff auf den Hersteller hier schwieriger. Sollte eine autonome KI außerhalb einer durch den Hersteller beherrschbaren Sphäre Entscheidungen treffen, können rechtliche Verantwortlichkeiten nicht zweifelsfrei festgestellt werden.

## 2.2 Vertragliche (Mangel-) Haftung

Sollte beispielsweise ein innerhalb eines einheitlichen Kauf- oder Mietvertrages von einem Landwirt (B2B-Bereich) beschafftes KI-System nach Ablieferung bzw. Mietbeginn fehlerhafte Entscheidungen treffen oder sonst mangelhaft sein, bestehen Mangelhaftungsrechte gegenüber dem Verkäufer oder -mieter. Der Verkäufer muss den Mangel beseitigen oder eine mangelfreie Sache liefern. Gelingt dies nicht, kann der Käufer vom Vertrag zurücktreten und bekommt ggf. den Kaufpreis erstattet oder er kann diesen mindern. Im Mietvertrag kann der Mieter für die Dauer des Bestehens des Mangels die Miete mindern und ggf., wenn der Mangel nicht behoben wird, den Vertrag aus wichtigem Grund kündigen. Voraussetzung ist immer, dass ein Mangel besteht, und dessen Vorliegen muss die Kundenseite beweisen. Der Beweis des Vorliegens eines Mangels kann bei einem KI-System, bei dem wegen des Blackbox-Effektes kaum die Möglichkeit der Einsichtnahme in Prozesse besteht, durchaus problematisch sein.

Im Kauf- und im Mietrecht sind zudem bei Auftreten eines Mangels Ansprüche auf Schadensersatz möglich, insbesondere, wenn durch den Fehler der KI weitere Rechtsgüter des Käufers bzw. Mieters beeinträchtigt werden. Voraussetzung eines Schadensersatzanspruchs ist dabei aber immer, jenseits des Mangels, auch ein Verschulden des Schuldners.

Bei zusammengesetzten KI-Systemen gelten ggf. Besonderheiten. „Smarte“ Produkte, wie die o. a. Transponderhalsbänder, funktionieren nur in Kombination aus körperlichem Gegenstand, dem Halsband, und einer Applikation (App), die aus dem Halsband Signale entgegennimmt und außerhalb des Halsbands verarbeitet. Solche Systeme werden oft nicht als einheitliches Produkt vertrieben, sondern mit aufgespaltenen und rechtlich selbstständigen Verträgen, einerseits mit dem Hersteller der App, andererseits mit dem des Halsbands. Bei digitalen Produkten gelten diese Vertragsverhältnisse im B2B-Verhältnis rechtlich unabhängig voneinander. Auch wenn beide Komponenten für die Funktionsfähigkeit des Produktes im Ganzen notwendig sind, muss der Käufer den Verantwortlichen für den Mangel selbst ermitteln (hier: Halsband oder KI/Software) und nach den Grundzügen der Beweislastverteilung auch die ihm günstigen Tatsachen – und damit einen gesichert vorliegenden Mangel – beweisen und aufgrund dessen Nachbesserung (und ggf. Schadensersatz) einfordern. Das bleibt nicht zuletzt aufgrund der meist unmöglichen Beweisführung für den Käufer als technisch weniger Versierten erfolglos.

Vorteilhaft wäre eine Änderung der Beweislast, sodass der Verkäufer oder -mieter die Mangelfreiheit der Sache beweisen muss, jedenfalls für den Zeitraum bis zur endgültigen Ablieferung beim Käufer und im Rahmen eines Mietvertrags so lange, bis der Mieter eine ihm als Erfüllung angebotene Leistung als Erfüllung angenommen hat. Dann muss auch der Mieter das Vorliegen eines Mangels beweisen.

### 2.3 Produkthaftung für KI-Systeme

Neben der vertraglichen Haftung steht die auf einer EU-Richtlinie basierende Produkthaftung als eine Form der Gefährdungshaftung. Sie setzt kein Vertragsverhältnis der Beteiligten voraus, sondern behandelt den Anspruch Geschädigter, und zwar ausschließlich natürlicher Personen, gegen Entitäten auf Herstellerseite, die ein Produkt in den Markt bringen und für bestimmte Eigenschaften des Produkts gegenüber den durch das Produkt Geschädigten einstehen müssen. § 1 Abs. 1 S. 1 ProdHaftG ordnet an: *„Wird durch den Fehler eines Produkts jemand getötet, sein Körper oder seine Gesundheit verletzt oder eine Sache (eine andere Sache als das Produkt) beschädigt, so ist der Hersteller des Produkts verpflichtet, dem Geschädigten den daraus entstehenden Schaden zu ersetzen.“*

Streitig ist nach dem ProdHaftG, ob ein KI-System ein Produkt darstellt, d. h. eine bewegliche Sache nach § 2 ProdHaftG ist. Ist das KI-System als Teilprodukt bestimmungsgemäß und mehr oder weniger untrennbar in ein anderes Produkt verbaut, z. B. in eine Landmaschine, und ist das zusammengesetzte Produkt der relevante Handelsgegenstand, dürfte im Ganzen eine bewegliche Sache vorliegen. Streitig ist das jedoch noch bei Software als solcher [ausführlich Mü19], hier also für den Fall, dass eine KI-basierte Software isoliert Handelsgegenstand ist, wie in dem Beispiel mit dem aufgespalteten Vertragsverhältnis bzgl. der App und den Transponderhalsbändern. Dann scheidet ggf. bezüglich der App bereits die Anwendbarkeit des ProdHaftG mangels Produkteigenschaft.

Geht man einmal von dem Fall der sachlichen Anwendbarkeit des ProdHaftG auf ein zusammengesetztes Produkt aus, das KI enthält, gilt der o. a. Grundsatz, dass der Hersteller, der ein gefährliches Produkt in den Verkehr bringt, auch für dieses haftet. Voraussetzung ist aber u. a. ein *„Fehler eines Produkts“*. Das mag bei einem KI-System für den Zeitpunkt des Einsatzbeginns beim Kunden noch feststellbar sein. Da autonome KI im Laufe ihres Einsatzes durch die verarbeiteten Daten derart dazu lernt, dass es kaum bis gar nicht nachvollziehbar ist, wie die KI ihre weiteren Entscheidungen trifft (Blackbox-Effekt), lässt sich oft nicht mehr feststellen, ob der entsprechende Fehler bereits in der Ursprungsprogrammierung und damit im Produkt angelegt war oder erst während des Einsatzes durch z. B. *„fehlerhafte“* Daten eingetreten ist, oder gar durch fehlerhafte Anwendung der KI.

Für den Fehler, den Schaden und den ursächlichen Zusammenhang zwischen Fehler und Schaden trägt nach § 1 Abs. 4 ProdHaftG der Geschädigte die Beweislast. Dann müsste der Geschädigte ggf. auch beweisen, dass der Fehler bereits in der Ursprungsprogrammierung vorhanden war, also nicht durch eigene Handlungen respektive Datenverarbeitungen

entstanden ist. Regelmäßig müsste der Geschädigte für den Nachweis eines Fehlers Einsicht in die streng geschützte Programmierung (Quellcode) erhalten und er muss sich auch so weit auskennen, dass er den Fehler im Algorithmus nachweisen kann. Das ist ein in der Regel unmögliches Unterfangen bzw. nur unter Zuhilfenahme eines (im Streitfall ggf. durch das Gericht eingeschalteten) Sachverständigen leistbar.

Liegt ein Fehler vor, kann die Haftung des Herstellers gleichwohl ausgeschlossen sein. Nach § 1 Abs. 2 ProdHaftG ist die Ersatzpflicht (beispielweise) ausgeschlossen, wenn (i) nach den Umständen davon auszugehen ist, dass das Produkt den Fehler noch nicht hatte, als der Hersteller es in den Verkehr brachte, (ii) der Fehler darauf beruht, dass das Produkt zu dem Zeitpunkt, zu dem der Hersteller es in den Verkehr brachte, dazu zwingenden Rechtsvorschriften entsprochen hat, oder (iii) der Fehler nach dem Stand der Wissenschaft und Technik zu dem Zeitpunkt, zu dem der Hersteller das Produkt in den Verkehr brachte, nicht erkannt werden konnte; außerdem ist nach § 1 Abs. 3 ProdHaftG die Ersatzpflicht des Herstellers eines Teilprodukts ausgeschlossen, wenn der Fehler durch die Konstruktion des Produkts, in welches das Teilprodukt eingearbeitet wurde, oder durch die Anleitungen des Herstellers des Produkts verursacht worden ist. Das Vorliegen eines solchen Haftungsausschlusses hat nach § 1 Abs. 4 Satz 2 ProdHaftG der Hersteller zu beweisen.

Damit ist eine Haftung nach dem ProdHaftG nicht ausgeschlossen, aus Sicht des Geschädigten ist aber die Beweislastverteilung oft problematisch.

## **2.4 Produzentenhaftung**

Eine weitere Konstellation der deliktischen, außervertraglichen Haftung ist die so genannte Produzentenhaftung. Anders als die o. g. Produkthaftung, die einen Fall der Gefährdungshaftung darstellt und nur natürliche Personen als Geschädigte betrifft, setzt die Produzentenhaftung ein Verschulden des Herstellers voraus und kann jeden Geschädigten betreffen, also auch Unternehmen. Ihre Besonderheit ist, dass hier die Beweislast im Grundsatz beim Hersteller liegt. Da der Geschädigte selbst oftmals keinen Einblick in den Betrieb des Herstellers hat und entsprechende Beweise für einen Produktfehler damit nur schwierig erbringen kann, muss der Hersteller bei der Produzentenhaftung beweisen, dass er nicht schuldhaft gehandelt hat. Auch hier erschwert aber die selbstlernende Eigenschaft des Algorithmus den Haftungszugriff: Im Einzelfall wird der Hersteller auch hier damit argumentieren können, dass der Schaden nicht durch die ursprüngliche Programmierung, sondern erst deren Autonomie entstanden sei und damit kein Verschulden bei ihm als Hersteller vorliege – aber immerhin muss er das hier beweisen. Bei Beachtung einschlägiger Sicherheitsvorgaben werden die Hersteller den Nachweis des Einhaltens der im Verkehr geschuldeten Sorgfalt jedoch in der Praxis führen können.

## 2.5 Haftung des Anwenders

Eine Haftung des Anwenders von KI im Verhältnis zu einem Dritten, z. B. eines die KI nutzenden Landwirts im Verhältnis zu seinen Abnehmern, kommt vor allem in Betracht, wenn dieser durch den Betrieb der KI bei jenem, gleich ob im Rahmen eines Vertragsverhältnisses (z. B. Belieferung mit mangelhaften Feldprodukten) oder in deliktischer Weise, einen Schaden herbeigeführt hat, und ihm ein Verschulden vorwerfbar ist. Dieses könnte in Bezug auf KI beispielsweise vorliegen, wenn er die in einer Landmaschine implementierte KI nicht nach etwa vorhandenen Herstellerangaben eingesetzt, mit der Technik ausgerüstete Landmaschinen nicht den Vorgaben entsprechend gewartet oder sein Personal nicht im Umgang mit der KI geschult hat. Kann man dem Anwender jedoch kein entsprechendes Verschulden vorwerfen, wird er auch nicht auf Schadensersatz haften müssen. Je nach Art oder Umstand des Schadenseintritts sind natürlich auch Haftungen aus anderen Normen, wie beispielsweise aus dem Umweltrecht, denkbar. Für Futtermittel beispielsweise greift § 24 LFGB.

## 3 Regulatorische Bestrebungen bei der gesetzlichen Haftung im Bereich KI

### 3.1 Einleitung

Der EU-Gesetzgeber hat vor dem Hintergrund aktueller Entwicklungen, zu denen neben dem Bereich KI auch Themen wie die allgemein als unzureichend empfundene Produkthaftung und die Cybersicherheit gehören, das gesetzliche Haftungsrecht auf den Prüfstand gestellt und führt eine EU-weit einheitliche Harmonisierung der gesetzlichen Haftung herbei. Dabei soll auch die Haftung für eine fehlerhafte KI vereinheitlicht und die Geltendmachung von Ansprüchen für Geschädigte vereinfacht werden.

Bereits im April 2018 stellte die EU-Kommission ihre KI-Strategie vor und im Februar 2020 entstand das Weißbuch der EU-Kommission zur künstlichen Intelligenz. Darin appelliert die Kommission mit Blick auf Haftungsfragen an die Mitgliedsländer dahin, dass Vertrauen in KI nur gestärkt werden kann, wenn klare Sicherheitsvorschriften eingeführt werden und der Prozess für Geschädigte, um eine Kompensation zu erhalten, vereinfacht wird. Im April 2021 wurde das entsprechende Regulierungspaket vorgestellt, das so genannte KI-Paket. Derzeit befinden sich die entsprechenden Entwürfe in den Debattenprozessen der EU-Institutionen. Eine endgültige Verabschiedung der Vorschläge steht bei Abgabe dieses Beitrags sozusagen vor der Tür. Zudem gilt für das Instrument der EU-Richtlinie, dass eine Richtlinie nach Inkrafttreten in nationales Recht umgesetzt werden muss. Hierfür haben die Einzelstaaten in der Regel zwei Jahre Zeit.



### 3.2 Entwurf einer Produkthaftungs-Richtlinie

Als Teil des KI-Pakets spielt für Haftungsfragen zunächst der Entwurf einer neuen Produkthaftungs-Richtlinie (Produkthaftungs-RL-E) [EU22] eine erhebliche Rolle. Hier geht es allgemein um Produkthaftung, wiederum ausschließlich für natürliche Personen, und nicht speziell um KI. Mit der neuen Richtlinie soll das unter Ziff. 2.3 bereits angesprochene Produkthaftungsregime verändert und dabei u. a. sachlich erweitert werden.

In Art. 4 Nr. 1 des Entwurfs wird klargestellt, dass auch Software – und damit auch KI – ein „Produkt“ ist, um eine EU-weit einheitliche Produkthaftung herzustellen. Danach ist eine Entschädigung möglich, wenn eine fehlerhafte KI einen Schaden verursacht, ohne dass der Geschädigte das Verschulden des Herstellers nachweisen muss, wie bei jedem anderen Produkt. Dies führt auch dazu, dass Software-Aspekte in die Betrachtung der Fehlerhaftigkeit aufgenommen wurden und ein Produkt z. B. auch dann als fehlerhaft anzusehen ist, wenn es die Sicherheitsanforderungen „*einschließlich sicherheitsrelevanter Cybersicherheitsanforderungen*“ nicht einhält (Art. 6 Abs. 1 lit. f). Der bloße Umstand, dass ein besseres Produkt einschließlich Upgrades auf dem Markt verfügbar ist, macht ein Produkt deswegen jedoch noch nicht inkompatibel mit den neuen Anforderungen der EU (Art. 6 Abs. 2). Nach Art. 10 Abs. 2 wird man nicht von der Haftung befreit, wenn die Fehlerhaftigkeit des Produkts auf eine der folgenden Ursachen zurückzuführen ist, sofern sie der Kontrolle des Herstellers unterliegt: Software, einschließlich Software-Updates oder -Upgrades, oder das Fehlen von Software-Updates oder Upgrades, die zur Aufrechterhaltung der Sicherheit erforderlich sind.

Ein Produktfehler wird zudem auch immer dann vermutet, wenn (i) der Hersteller der Pflicht zur Offenlegung von Beweismitteln nicht nachgekommen ist und/oder (ii) der Geschädigte nachweisen kann, dass das Produkt verbindliche Sicherheitsanforderungen (einschließlich Cybersicherheit) nicht erfüllt und/oder (iii) der Geschädigte nachweisen kann, dass der Schaden durch eine offensichtliche Funktionsstörung des Produkts bei normaler Verwendung oder unter normalen Umständen verursacht wurde. Gerade der letzte Punkt könnte im hier angeführten Beispiel eine Rolle spielen: Sollten in dem o. a. Beispiel die im regulären Betrieb vorkommenden Umwelteinflüsse, wie Hitze, Nässe oder Staub, dazu geführt haben, dass die an den Landmaschinen angebrachten Sensoren fehlerhafte Daten erfasst haben und dies zu einer Überdüngung des Teilstücks geführt hat, könnte auch hier der Produktfehler gleichwohl zunächst vermutet und damit im Grundsatz eine Haftung etabliert werden. Jedenfalls läge es dann in der Beweislast der Herstellerseite nachzuweisen, dass der Kunde entgegen einem expliziten Hinweis in der Bedienungsanleitung die Sensoren nicht hinreichend gereinigt und so die Gefahr der Fehlerfassung gebannt hat.

Die Beweislast für den Produktfehler wird in Art. 9 neu geregelt. Art. 8 ermöglicht die gerichtliche Anordnung, dass relevante Beweismittel aus der Sphäre des Herstellers offengelegt werden müssen; hierzu können auch (im Prozess gesondert zu schützende) vertrauliche Informationen und Geschäftsgeheimnisse gehören.

Die Umsetzungsfrist soll nach Art. 18 Abs. 1 nur 12 Monate statt zwei Jahre ab Wirksamwerden der Richtlinie betragen.

### 3.3 Entwurf einer KI-Haftungs-Richtlinie

Eine weitere Maßnahme im KI-Paket ist der KI-Haftungsrichtlinien-Entwurf (KI-Haftungs-RL-E) [EU22a], der für außervertragliche Haftung gilt. Dabei verfolgt die Richtlinie im Wesentlichen zwei Ziele.

Es sollen nach Art. 4 Geschädigte aufgrund der künftig gesetzlichen Kausalitätsvermutung von der Pflicht entbunden werden, die Ursächlichkeit des Schadens in Bezug auf die Anwendung von KI darzulegen. Für KI-Systeme wird diese Kausalität vermutet, wenn (a) der Kläger nachgewiesen hat oder das Gericht vermutet (Art. 3 Abs. 5), dass ein Verschulden seitens des Beklagten oder einer Person, für deren Verhalten der Beklagte verantwortlich ist, vorliegt, da gegen eine im Unionsrecht oder im nationalen Recht festgelegte Sorgfaltspflicht verstoßen wurde, deren unmittelbarer Zweck darin besteht, den eingetretenen Schaden zu verhindern; (b) nach den Umständen des Falls nach vernünftigem Ermessen davon ausgegangen werden kann, dass das Verschulden das vom KI-System hervorgebrachte Ergebnis oder die Tatsache, dass das KI-System kein Ergebnis hervorgebracht hat, beeinflusst hat; und (c) der Kläger nachgewiesen hat, dass das vom KI-System hervorgebrachte Ergebnis oder aber die Tatsache, dass das KI-System kein Ergebnis hervorgebracht hat, zu dem Schaden geführt hat. Es bleibt damit aber weiterhin bei dem allgemeinen Erfordernis eines Ursachenzusammenhangs zwischen dem schädigenden Ereignis (Ergebnis der KI-Berechnungen) und einem geschützten Rechtsgut des Geschädigten. Ein solches Rechtsgut kann neben Eigentum und Gesundheit im Übrigen auch die Verletzung der Privatsphäre oder durch IT-Sicherheitsprobleme verursachter Schaden sein. Weitere Anwendungsfälle der Absätze 2 ff betreffen dann wieder Hochrisikosysteme.

Hierneben soll gemäß Art. 3 des Entwurfs bei Schäden durch so genannte Hochrisiko-KI-Systeme (Systeme nach Art. 6 des Entwurfs der KI-VO) der Zugang zu Beweismitteln erleichtert werden, die sich nicht im Besitz des Geschädigten, sondern im Besitz von Unternehmen oder Anbietern befinden.

Im Unterschied zur allgemeinen Produkthaftung wird zudem die spezielle KI-Haftung auch für juristische Personen gelten und nicht nur für natürliche Personen – auch geschädigte Unternehmen fallen also unter den persönlichen Anwendungsbereich.

Sollte der Entwurf so umgesetzt werden, wären damit zumindest stellenweise die Probleme abgemildert, die das gesetzliche Haftungsrecht derzeit aufweist. Insbesondere der Blackbox-Effekt kann damit für Hersteller nur noch erschwert als Entlastung dienen.

## 4 Vertragliche Maßgaben

Da die o. a. regulatorischen Bestrebungen nach der Umsetzung in nationales Recht erst ab etwa 2025/2026 greifen werden, kann der Versuch unternommen werden, bei der Anschaffung von KI eine vertragliche Absicherung vorzunehmen, wobei nachvollziehbar ist, dass Beschaffer- und Anbieterseite zumeist diametral entgegengesetzte Interessen verfolgen.

Hierzu gehört zunächst die Festlegung einer genauen Leistungsbeschreibung, in welcher die Vertragspartner festlegen, welche Leistung in welchem Umfang von der KI erwartet werden. Eine Nichteinhaltung der Beschreibung stellt sodann eine Pflichtverletzung dar. Zu einer umfassenden Leistungsbeschreibung gehören alle Aspekte, die im Zusammenhang mit der Funktionalität des Gesamtsystems, den technischen Anforderungen und der Qualität der Ergebnisse der KI stehen. Da bei digitalen, kombinierten Produkten in der Praxis Gewährleistungsansprüche gegenüber dem Dritten oftmals vertraglich wirksam ausgeschlossen sind, könnte hier auf eine möglichst umfangreiche Einstandspflicht des Verkäufers gedrängt werden.

Auch die Einhaltung der Datenschutzvorgaben darf in der Vertragsgestaltung vor allem bei der Verarbeitung personenbezogener Daten nicht vernachlässigt werden.

Gleichermaßen sollte eine ausreichende Datensicherheit im KI-System vorherrschen. Der Schutz vor Verlust, Manipulation oder unberechtigtem Zugriff auf die Daten ist für Hersteller und Anwender von großer Bedeutung. Angelehnt an die oben aufgeführten regulatorischen Bestrebungen kann im Vertrag auch festgehalten werden, dass das Produkt bestimmte (Cyber-)Sicherheitsstandards zu erfüllen hat. Denkbar ist, entsprechende Cybersicherheitsstandards anhand bestimmter Zertifizierungen nachweisen zu lassen.

Gerade beim Einsatz von KI im Agrarbereich kommt es zudem entscheidend auf die Datengenauigkeit der Trainingsdaten an. Der Ursprungsalgorithmus der KI wird dazu mit Daten gespeist, welche das System trainieren sollen. Abhängig von der Qualität der Trainingsdaten kommt die KI im späteren Einsatz dann zu entsprechend qualitativen Ergebnissen. Ein KI-System kann daher auch bei einer einwandfreien Ursprungsprogrammierung fehlgehen, wenn die eingespeisten Trainingsdaten fehlerhaft sind. Es sollte daher vertraglich auch die Passgenauigkeit der Trainingsdaten zugesichert werden; notfalls müsste die Datengesamtheit der Trainingsdaten einigermaßen genau beschrieben werden.

Nicht zuletzt kann der Versuch unternommen werden, in Vertragsklauseln die Haftung für bestimmte Schäden auszuschließen oder es können besondere Anforderungen an die Art des Verschuldens gestellt werden. Beides unterliegt jedoch strengen gesetzlichen Anforderungen, auch im Bereich der Inhaltskontrolle allgemeiner Geschäftsbedingungen, die hier wohl vorherrschen werden (s. a. §§ 307, 310 BGB im unternehmerischen Verkehr). Aus Anwendersicht sollte insbesondere darauf geachtet werden, dass sich im Vertrag keine Klauseln befinden, welche die Haftung des Herstellers für Schäden ausschließen, die aufgrund von Fehlentscheidungen der KI entstehen; hier entgegenzuwirken ist wahr-

scheinlich besser, als sich darauf berufen zu müssen, dass bestimmte Regelungen in ebendiesem Lichte auszulegen seien. Gleichmaßen kann auch aus Entwicklersicht ein solcher Ausschluss im Rahmen von Vertragsklauseln vereinbart bzw. die Haftung begrenzt werden; unter Beachtung der sachlich gleichlaufenden Inhaltskontrolle dieser Klauseln.

Wenn es sich, wie beim Einsatz automatisierter Dünge- und Saatausbringung, um miteinander vernetzte Systeme (KI vernetzt mit Landmaschine) handelt, sollte ein besonderes Augenmerk auf die Anforderungen zu Einsatz und Wartung der Maschinen gelegt werden. Während der Entwickler sicherstellen muss, dass der Einsatz der Technologie unter den dafür nötigen Bedingungen stattfindet, um keinen Fehlgang durch bspw. Umwelteinflüsse herbeizuführen, kann der Anwender in diesem Sinne unter Umständen eine Pflicht verletzen, wenn er die KI nicht nach Herstellerangaben einsetzt, mit der Technik ausgerüstete Landmaschinen nicht den Vorgaben entsprechend wartet oder sein Personal nicht im Umgang mit der KI ausreichend schult. Bei Vertragsschluss sollten hier entsprechende Vorkehrungen getroffen werden, um weder die an den Anwender gestellten Anforderungen uferlos ausweiten zu lassen, noch den Hersteller für einen etwaig unangemessenen Einsatz des Anwenders haften zu lassen.

Neben den bereits genannten Instrumenten gibt es weitere Möglichkeiten zur Vertragsgestaltung. Hierzu könnte gehören, beim Erwerb einer KI-gesteuerten Software im Nicht-EU-Ausland eine so genannte ausdrückliche Rechtswahl zu treffen. Dies bedeutet, dass im Vertrag eindeutig festgehalten werden kann, welches Recht anzuwenden ist. So kann sichergestellt werden, dass auch tatsächlich das Recht eines EU-Mitgliedsstaates anzuwenden ist, um nach der Umsetzung der Richtlinien auch in deren Genuss zu kommen sowie Sicherheit zu erhalten.

Ungeachtet dessen sollte es dem Vertragspartner möglichst schwer gemacht werden, im Falle einer Haftung die Verantwortlichkeit auf andere (indirekt) Beteiligte, wie etwaige Programmierer, Trainer der KI, Hersteller einzelner Komponenten oder Ähnliche (aus Anwendersicht) oder auf ausgelagerten Organisationsstrukturen, wie Lohnunternehmen (aus Entwicklersicht), zu verschieben. Die Haftung für einen Fehlschlag der KI sollte beim direkten Vertragspartner liegen, um im Schadensfall nicht verwiesen werden zu können.

Auch können solche Vertragsklauseln von Bedeutung sein, die sich auf die Herausgabe von möglichen Beweismitteln im Schadensfall beziehen. Da es sich als eher unwahrscheinlich herausstellen wird, dass sich der Hersteller auf die Herausgabe des Quellcodes einlässt, könnte jedenfalls die Offenlegung der Metadaten vereinbart werden.

Die Aufzählung der Möglichkeiten zur Vertragsgestaltung ist an dieser Stelle keinesfalls abschließend, soll jedoch einen ersten Überblick über die breite Vielfalt an vertraglichen Gestaltungsmöglichkeiten geben, die sowohl dem Hersteller als auch dem Anwender zur Verfügung stehen. So können bereits vor Umsetzung der entsprechenden Richtlinien erste Vorkehrungen getroffen werden, um sich im Falle eines Schadens bestmöglich abzusichern.

## 5 Fazit und Ausblick

Damit steht fest, dass das deutsche Haftungsrecht den technischen Besonderheiten insbesondere von autonomen KI-Systemen bisher nicht ausreichend gewachsen ist. Gerade dem Anwender stehen in vielen Fällen gegenwärtig noch einige Hürden im Weg, den Herstellern einen Fehler in ihren Produkten oder ein etwaiges Verschulden nachzuweisen. Die derzeit vorliegenden Entwürfe der europäischen Richtlinien nehmen sich dieser Schwierigkeiten in Teilen an, um die entsprechenden Hürden herabzusetzen. Sie stellen aus Anwenderperspektive einen wichtigen Schritt hin zu einem anwenderfreundlicheren Haftungsrecht dar. Es bleibt jedoch abzuwarten, in welchem endgültigen Wortlaut die Richtlinien zunächst verfasst sein werden, was der deutsche Gesetzgeber daraus macht und – vor allem – inwieweit sich die Regelungen als praxistauglich erweisen werden. Bis dahin sollte man sich vertraglich absichern, um etwaige Beweisschwierigkeiten im Falle eines Schadens bestmöglich zu vermeiden – das setzt allerdings eine gewisse Handlungsmacht voraus.

### Literaturverzeichnis

- [BU22] Bundesministerium für Wirtschaft und Klimaschutz, KAMI – Überwachung der Atemfrequenz von Milchkühen, <https://www.bmel.de/SharedDocs/Praxisbericht/DE/kuenstliche-intelligenz/KAMI.html>, Stand: 12.10.2023.
- [EU18] Europäische Kommission, Künstliche Intelligenz für Europa, 2018.
- [EU21] Europäische Kommission, Förderung eines europäischen Konzepts für künstliche Intelligenz, 2021.
- [EU22] Europäische Kommission, Vorschlag für eine Richtlinie des Europäischen Parlaments und des Rates über die Haftung für fehlerhafte Produkte, 2022.
- [EU22a] Europäische Kommission, Vorschlag für eine Richtlinie des Europäischen Parlaments und des Rates zur Anpassung der Vorschriften über außervertragliche zivilrechtliche Haftung an künstliche Intelligenz (Richtlinie über KI-Haftung), 2022.
- [EU23] Abänderungen des Europäischen Parlaments vom 14.6.2023 zu dem Vorschlag für eine Verordnung des Europäischen Parlaments und des Rates zur Festlegung harmonisierter Vorschriften für künstliche Intelligenz (Gesetz über künstliche Intelligenz) und zur Änderung bestimmter Rechtsakte der Union (COM(2021)0206 – C9-0146/2021 – 2021/0106(COD)).
- [Mü19] Müller, A.-K., Software als „Gegenstand“ der Produkthaftung, Baden-Baden 2019.



## Automatisierte Frucht- und Pflanzenerkennung in Apfelplantagen durch künstliche Intelligenz

### Ein Vergleich von Datensätzen und Deep-Learning-Verfahren

Michael Gerstenberger<sup>1</sup>, Mykyta Kovalenko<sup>1</sup>, David Przewozny<sup>1</sup>, Jannes Magnusson<sup>1</sup>, Eike Gassen<sup>2</sup>, Jakub Pawlak<sup>2</sup>, Jochen Hirth<sup>3</sup>, Laura von Hirschhausen<sup>1</sup>, Detlef Runde<sup>1</sup>, Anna Hilsmann<sup>1</sup>, Peter Eisert<sup>1</sup> und Sebastian Bosse<sup>1</sup>

**Abstract:** Zwei wichtige Ziele des Precision Farming im Obstanbau sind die automatische Bonitur von Apfelplantagen und die Ernte von Äpfeln: Beide setzen voraus, dass Bäume und Früchte zuverlässig erkannt werden. Mittlerweile existieren erste öffentliche Datensätze zum Training von KI-Modellen zur Erkennung von Früchten in Obstplantagen, wie z. B. der Benchmark-Datensatz MinneApple mit über 1000 annotierten Bildern. Eine zentrale Herausforderung bleibt einerseits die begrenzte Generalisierbarkeit der Apfelerkennung, die mit diesen Datensätzen erzielt werden kann. Andererseits bestehen neben der Anzahl der Früchte weitere wichtige Kennzahlen im Obstanbau wie die Fläche der Blätter und Blüten, welche die Bäume im Frühjahr tragen und für die automatische Bonitur von Interesse sind. Die Ziele der hier vorgestellten Forschung sind daher (1) eine Erweiterung der Datenbasis, (2) die vergleichende Evaluation von state-of-the-art Objektdetektoren für die Apfelerkennung über verschiedene Datensätze hinweg und (3) eine neue Methode zur Segmentierung der Bäume. Um diese Ziele zu erreichen, wurden weitere Daten maschinengestützt erfasst und mehr als 600 Bilder mit Hilfe von interaktiven Verfahren annotiert. Diese nutzen jeweils ein vortrainiertes Modell, um dem Nutzer Vorschläge für die Position der Äpfel zu machen, die dann manuell korrigiert und ergänzt werden können. Für die Evaluierung der Apfelerkennung wurden gängige Modellarchitekturen zur Objekterkennung (YOLOv8, ResNet, SSD) für die Detektion von Äpfeln trainiert und im Sinne eines Modellvergleichs getestet. YoloV8 liefert die besten Ergebnisse für die Erkennung von Äpfeln am Baum, die mit einem F1-Wert von 0.77 insgesamt auch sehr hoch ist. Die Übertragbarkeit der Ergebnisse wurde durch eine Kreuzevaluierung mit MinneApple und MS-COCO überprüft und es zeigt sich, dass die Modelle bei Anwendung auf anderen Testdatensätze erheblich schlechter abschneiden als bei der Evaluierung in Bezug auf die zum Training gehörenden Testbilder. Voraussetzung für eine semantische Segmentierung ist die Erkennung der Bäume der vordersten Baumreihe, die hier ebenfalls untersucht wird. Hierbei kommt Deep Optical Flow (RAFT) zum Einsatz, das die Bewegungsparallaxe nutzt, um Tiefeninformationen zu schätzen, und keine rechenintensive Punktwolkenrekonstruktion erfordert. Das Verfahren liefert qualitativ gute Ergebnisse für einen Großteil der Bilder. Unsere Ergebnisse unterstreichen die Bedeutsamkeit von umfangreichen Datensätzen, die es erlauben, Modelle domänenspezifisch zu trainieren und vergleichend zu evaluieren.

---

<sup>1</sup> Heinrich-Hertz Institut, VIT, Einsteinufer 37, 10587 Berlin, michael.werner.gerstenberger@gmail.com

<sup>2</sup> RPTU, Robotersysteme, Gottlieb-Daimler Str. 47, 67663 Kaiserslautern, gassen@informatik.uni-kl.de

<sup>3</sup> Robot Makers GmbH, Merkurstraße 45, 67663 Kaiserslautern, hirth@robotmakers.de

**Keywords:** Smart Farming, Apfelanbau, Fruchterkennung, Baumsegmentierung, Optical Flow, Deep Learning, Computer Vision

## 1 Einleitung

Eines der wichtigsten Ziele des Smart Farming ist es, Werkzeuge zur Optimierung des Pflanzenmanagements bereitzustellen, die es Landwirten ermöglichen, datenbasiert Entscheidungen zu treffen [Bo23]. Um dies leisten zu können, gilt es, die Merkmale der Pflanzen systematisch zu erfassen, aufzubereiten und die wichtigsten Leistungskennzahlen abzuleiten. Zu diesem Zweck werden einerseits maschinelle Aufnahmeverfahren in Anbaugeräten oder autonomen Fahrzeugen eingesetzt [Ge20], andererseits kommen Deep-Learning-Methoden zum Einsatz.

Mittlerweile gibt es eine Reihe von Ansätzen, etwa zur automatischen Erkennung von Unkraut oder (Feld-)Früchten. Der Mangel an öffentlichen Bilddatensätzen bleibt jedoch ein entscheidender Engpass für die schnelle Entwicklung und Evaluierung von Computer-Vision- und Machine-Learning-Verfahren [LY20]. Der Erkennung von Früchten in Obstplantagen kommt insbesondere deshalb eine besondere Bedeutung zu, da bereits erste Anstrengungen unternommen werden, die Ernte von Tafeläpfeln robotergestützt zu automatisieren [Zh20]. Außerdem ist *Smart Spraying* für eine gezielte Anwendung von Pflanzenschutzmaßnahmen im Obstbau denkbar, welches für den Feldanbau bereits umgesetzt wurde [SML22].

In den vergangenen Jahren hat sich daher ein Forschungsfeld herausgebildet, welches sich der Erkennung von Nutzpflanzen wie Getreide in Flächenkulturen oder Früchten im Obstbau widmet [LY20]. Mittlerweile existieren erste Deep-Learning-Datensätze mit Annotationen in Form von *Bounding Boxes* zur Fruchterkennung. Diese sollen beispielsweise die Erkennung von Honigmelonen, Paprika, Avocado, Erdbeeren, Orangen [Sa16], Mangos [Sa16; KMN19; Ko19; LY20], Mandeln [LY20] und die Detektion von Äpfeln in Obstplantagen ermöglichen [HRI20; Sa16; LY20; BKZ19]. Mittlerweile wurden auch spezielle Methoden zur Segmentierung von Früchten in Obstkulturen entwickelt [Ge23; BU17]. Allerdings fehlen umfassende Datensätze zur vollständigen semantischen Segmentierung, welche z. B. auch die Blatt- und Blütenfläche einschließt. Die Forschung zur Apfelerkennung sieht sich vor dem Hintergrund bestehender domänenspezifischer Datensätze dagegen mit der Frage der Übertragbarkeit von Modellen konfrontiert.

Daher wird in diesem Beitrag die Erkennungsgenauigkeit verschiedener Datensätze vergleichend evaluiert und die Frage untersucht, wie gut die bestehenden Modelle für die von uns aufgenommenen Daten generalisieren. Außerdem testen wir gängige Modellarchitekturen vergleichend und zeigen ein Verfahren zur Segmentierung der ersten Baumreihe, das zur Generierung weiterer Deep-Learning-Datensätze genutzt werden kann. Im ersten Teil wird die Datenlage zur Apfelerkennung zusammengefasst und es werden die verwendeten Aufnahme- und Annotationsverfahren sowie der durch diese erzeugte Datensatz beschrieben. Nachfolgend werden die Modelle zur Objekterkennung kurz eingeführt und die



Ergebnisse der Apfelerkennung präsentiert. Das Verfahren zur Vordergrundsegmentierung wird im letzten inhaltlichen Teil vorgestellt.

## 2 Datenlage

Zu den domänenspezifischen Datensätzen für die Apfelerkennung zählt MinneApple mit mehr als 41.000 annotierten Früchten in über 1000 Bildern aus einer Plantage. Es ist jedoch anzumerken, dass die MinneApple-Bilder zum Teil stark überlappen und die Anzahl der gezeigten Bäume begrenzt ist. Es bleibt daher die Frage zu klären, wie gut diese Datensätze für solche aus anderen Aufnahme modalitäten generalisieren. Um neue Daten zu generieren, wurden automatische Aufnahmeverfahren entwickelt, die autonome Roboter für die Datenerfassung einsetzen [Ge20].




Abb. 1: Aufnahmestrategie und Beispielbilder (Aufnahme-Setup mit zwei Stereokameras)

Um zuverlässige Vorhersagen zur Position der Früchte in einer Plantage treffen zu können, benötigen kontemporäre Deep-Learning-Ansätze eine große Anzahl annotierter Daten. Bekannte domänenunspezifische Datensätze enthalten in manchen Fällen bereits die Kategorie Apfel. Dies gilt z. B. für MS-COCO mit 6090 Objektinstanzen für Äpfel, die eine große Heterogenität aufweisen. Einerseits gilt dies für die Umgebung, in welcher die Äpfel aufgenommen wurden. Andererseits wurden in manchen Bildern auch mehrere Äpfel mit einer einzelnen *Bounding Box* markiert [Li19]. Aus dem Umstand, dass Daten von Obstplantagen im Freien aufgenommen werden, resultieren allerdings spezifische Herausforderungen, was die Bedeutsamkeit von domänenspezifischen Datensätzen unterstreicht. Zu nennen sind insbesondere variierende Lichtbedingungen, unterschiedliches Aussehen der Früchte verschiedener Sorten und Reifegrade sowie die partielle Verdeckung durch

Blätter, Zweige oder andere Früchte. Hinsichtlich ihres Umfangs an verfügbaren Bildern sind von den eingangs genannten Datensätzen insbesondere MinneApple und DeepFruits für domänenspezifisches Training geeignet. MinneApple umfasst mit 41.000 die meisten manuell annotierten Objektinstanzen und gilt daher als Benchmark für das Training von Deep-Learning-Verfahren [HRI20]. Der Umstand, dass MinneApple relativ wenige Bäume unter konstanten Wetterbedingungen zeigt, muss jedoch berücksichtigt werden.

Daher wurden für diesen Beitrag zu unterschiedlichen Zeitpunkten der Vegetationsperiode (Frühjahr, mittlere Fruchtgröße, erntereife Früchte) einerseits Stereovideos mit einer Bildgröße von 1280 x 720px im Querformat erfasst. Hierfür kam ein autonomes Roboterfahrzeug von RobotMakers zum Einsatz, an dem zwei Stereokameras angebracht wurden (Abb. 1). Andererseits wurden testweise einzelne monokulare Videos mit 1920 x 1080px im Hochformat händisch aufgenommen. Im ersten Fall deckt das gemeinsame Sichtfeld der Kameras die Gesamthöhe der vorderen Baumreihe ab, während dieses im zweiten Fall für jedes Frame der Kamera gilt. Insgesamt wurden 12.382 Objektinstanzen annotiert (davon 12.148 der vorderen Baumreihe). Unser Datensatz, NaLamKI Apples, enthält Gegenlichtaufnahmen und Aufnahmen im Schatten.




Abb. 2: Interaktive Annotation

Für die interaktive Annotation der Daten wurden spezielle User Interfaces entworfen und in Form einer responsiven Web-Applikation umgesetzt. Die Nutzerinteraktion folgt hierbei dem Entwurfsmuster „Human in the Loop“, um die Annotation der Daten durch ein Zusammenspiel von Mensch und Maschine effizient zu gestalten. Dem Nutzer werden durch die KI Vorschläge gemacht, welche dieser entweder akzeptiert, korrigiert und/oder ergänzt. Der User kann hierfür verschiedene Verfahren für ein *Region Proposal* auswählen. Neben Methoden für das Objekt-Tracking stützt sich die Nutzerinteraktion hierbei insbesondere auf Objekterkennungsmodelle mit YOLOv8-Architektur. Alle Daten werden in einer nicht relationalen Datenbank (MongoDB) verwaltet, auf Anfrage des Users entnommen und dargestellt. Ein auf dem aktuell bestehenden Pool an Daten trainiertes Modell macht Vorschläge für die *Bounding Boxes* der Äpfel. Der User kann hierbei den Schwellenwert anpassen, der dazu verwendet wird, *Bounding Boxes* anhand der vorhergesagten Wahrscheinlichkeit zu filtern, dass diese tatsächlich ein Objekt enthalten. Anschließend akzeptiert oder verwirft er entweder alle Vorschläge oder wählt einzelne *Bounding Boxes* ab. Nicht erkannte Äpfel können manuell hinzugefügt werden. Die Ergebnisse werden zurück in die Datenbank geschrieben. Dies ermöglicht es, die Objekterkennungsnetze für das *Region Proposal* nach der Erzeugung einer ausreichend großen Anzahl zusätzlicher Annotationen nachzutrainieren (siehe Abb. 2).

### 3 Apfelerkennung

Für die Apfelerkennung in Obstplantagen wurden verschiedene Verfahren vorgeschlagen. Ältere Ansätze stützen sich auf manuell entwickelte Deskriptoren für Merkmale der Früchte wie z. B. Farbe, Geometrie und Textur sowie Kombinationen aus diesen [Go15]. Die große Mehrheit der heute eingesetzten Methoden basiert dagegen auf kontemporären Modellen zur Objekterkennung. Insbesondere sind FasterRCNN und YOLO-Architekturen zu nennen.

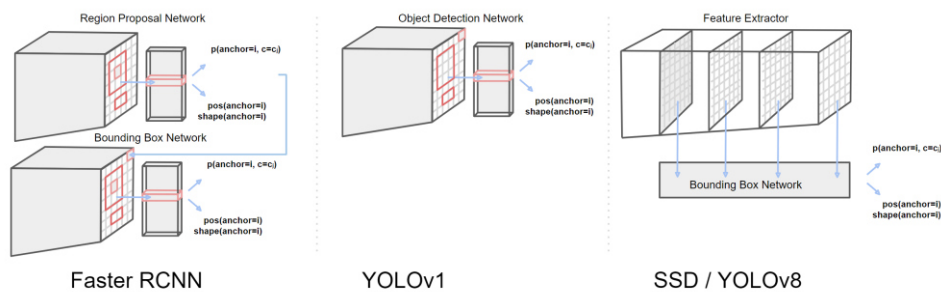


Abb. 3: Modellarchitekturen zur Objekterkennung

Für die Apfelerkennung mit MinneApple wurde bisher vor allem FasterRCNN genutzt [HR120]. Moderne YOLO-Netzwerke haben den Vorteil kürzerer Verarbeitungszeiten und damit einer etwa um den Faktor 2,5 schnelleren Vorhersage. Zudem versprechen sie, auch kleinere Objekte zuverlässig zu erkennen, werden aktiv weiterentwickelt und die Codebasis wird fortlaufend gewartet. FasterRCNN und frühe YOLO-Architekturen nutzen für die Objekterkennung Ankerboxen. Ein Convolutional Neural Network (CNN) wird verwendet, um aus Bildern Merkmalsvektoren zu extrahieren, die räumlich angeordnet sind (*Latent Grid*). Ankerboxen werden a priori für eine Vielzahl möglicher Objektpositionen definiert und verwendet, um die entsprechenden Regionen im *Latent Grid* auszuschneiden. Für jede Klasse und Ankerbox wird ein Wert für die Wahrscheinlichkeit und außerdem die exakte Position der das Objekt umschließenden Box ermittelt. YOLO sagt auf diese Weise direkt die Objektposition voraus, während FasterRCNN sie im Sinne eines *Region Proposals* versteht und sie mit einem zweiten CNN weiter verbessert, was zusätzlichen Rechenaufwand erfordert [TC23]. YOLOv8-Architekturen unterscheiden sich darin, dass sie (1) mehrere Latent Grids auf verschiedenen Stufen eines speziell entwickelten CNNs nutzen und (2) vollständig auf Anchor Boxes verzichten [Jo23]. Damit überlassen sie es dem Netz, geeignete rezeptive Felder zu finden, statt diese a priori einzuschränken. Dadurch werden moderne YOLO-Architekturen SSD ähnlicher, welches jedoch weiterhin Anchor Boxes verwendet und keine spezialisierten Encoder, sondern Standard-Klassifikationsnetze nutzt (Abb. 3). Die Performance unterscheidet sich je nach Use-Case und muss empirisch bewertet werden [TC23].

| Architektur | Test-Subset    | Precision | Recall | mAP@.5 | mAP@.95 | F1    |
|-------------|----------------|-----------|--------|--------|---------|-------|
| YOLOv8      | Alle Testdaten | 0.383     | 0.638  | 0.377  | 0.231   | 0.479 |
|             | Äpfel am Baum  | 0.774     | 0.771  | 0.823  | 0.515   | 0.773 |
| Faster RCNN | Alle Testdaten | 0.596     | 0.855  | 0.559  | 0.391   | 0.702 |
|             | Äpfel am Baum  | 0.6       | 0.862  | 0.566  | 0.397   | 0.707 |
| SSD         | Alle Testdaten | 0.134     | 0.769  | 0.081  | 0.042   | 0.229 |
|             | Äpfel am Baum  | 0.139     | 0.779  | 0.084  | 0.044   | 0.236 |

Tab. 1: Modellvergleich mit NaLamKI Apples

Da für die Apfelerkennung potenziell eine Vielzahl kleiner *Bounding Boxes* erkannt werden muss, verwenden wir die Netzwerke einerseits auf den passend skalierten Originalbildern und andererseits auf überlappenden Teilausschnitten. Die erkannten *Bounding Boxes* für diese unterschiedlichen Skalen werden für die finale Vorhersage wieder zusammengeführt. Der Modellvergleich für unsere Daten ergibt gute Werte für YOLOv8 (F1=.773) und FasterRCNN (F1=.707), während SSD eine unzureichende Erkennung leistet (F1=.236).

| Datensatz         | Evaluierung       | Precision | Recall | mAP@.5 | mAP@.95 | F1   |
|-------------------|-------------------|-----------|--------|--------|---------|------|
| MinneApple        | MinneApple        | 0.9328    | 0.9195 | 0.9649 | 0.6493  | 0.93 |
|                   | NaLamKI (Reihe=0) | 0.6628    | 0.3655 | 0.5304 | 0.2934  | 0.47 |
| NaLamKI (all)     | MinneApple        | 0.5944    | 0.6182 | 0.6261 | 0.3491  | 0.61 |
|                   | NaLamKI (Reihe=0) | 0.848     | 0.8045 | 0.8706 | 0.5593  | 0.83 |
| NaLamKI (Reihe=0) | MinneApple        | 0.5724    | 0.63   | 0.6058 | 0.338   | 0.6  |
|                   | NaLamKI (Reihe=0) | 0.8709    | 0.8471 | 0.9032 | 0.5982  | 0.86 |
| MS-COCO           | MinneApple        | 0.7053    | 0.3431 | 0.5227 | 0.3258  | 0.46 |
|                   | NaLamKI (Reihe=0) | 0.8752    | 0.3641 | 0.6234 | 0.5057  | 0.51 |

Tab. 2: Vergleich von Datensätzen zur Apfelerkennung (YOLOv8)

Ein entscheidender Unterschied zwischen MinneApple und unseren Daten ist, dass für MinneApple nur die Äpfel der vorderen Baumreihe annotiert sind, während solche am Boden oder in hinteren Reihen nicht mit *Bounding Boxes* versehen wurden. Im Gegensatz zu FasterRCNN ist die Erkennungsleistung von Yolo erheblich schlechter, wenn alle Äpfel und nicht nur diejenigen am Baum erkannt werden sollen ( $F1=.773$  vs.  $F1=.479$ ).

Um die generelle Vorhersagequalität zu bewerten, die mit unterschiedlichen Datensätzen erreicht werden kann, wurde ein YOLO-Netzwerk auf MinneApple, MS-COCO und auf unseren Daten trainiert. Die entsprechenden Modelle werden für die Kreuzevaluierung mit den zum Training gehörenden und den jeweils anderen Testdaten evaluiert. Es zeigt sich, dass domänenspezifisches Training sowohl mit unseren Daten als auch mit MinneApple dem auf MS-COCO trainierten Modell überlegen ist. Für unsere Daten erreicht dieses einen F1-Score von nur .51, während das Training mit dem zugehörigen Testdatensatz einen F1-Score von .86 hat. Für MinneApple liegen die entsprechenden Werte bei .46 und .93. Mit einem F1-Score von nur .47 und einem auffällig niedrigen Recall von .37 ist das MinneApple-Modell schlecht auf unsere Daten zu übertragen. Im Gegensatz dazu lässt sich ein auf unseren Daten trainiertes Modell besser auf MinneApple übertragen, wobei die Erkennungsrate ebenfalls nur im mittleren Bereich liegt ( $F1=.61$ ). Insgesamt sind die Erkennungsraten zwischen den Datensätzen erheblich schlechter als innerhalb. Dies spiegelt die Heterogenität der Daten aus der Domäne der Apfelplantagen wider und zeigt die Herausforderung auf, Modelle zu schaffen, die für alle Anpflanzungen gleichermaßen zuverlässige Ergebnisse liefern.

## 4 Semantische Segmentierung

Der Einsatz von Stereokameras oder Structure-From-Motion-Verfahren erlaubt eine 3D-Rekonstruktion der Bäume und somit eine Segmentierung der vordersten Baumreihe. Allerdings benötigen die entsprechenden Verfahren zur Punktwolkenrekonstruktion erhebliche Rechenleistung und wurden bisher nur für wenige Pflanzen demonstriert (Gene-Mole 2020). Auf dem Weg zu einer effizienten Erfassung von Merkmalen wie der Blatt- und Blütenfläche stellen sie daher nur einen ersten Schritt dar. Daher wurde ein neues Verfahren für die Bestimmung eines Schwellenwertes zur Vordergrundsegmentierung entwickelt, das ohne Stereokameras auskommt und RAFT Optical Flow zur Schätzung von Tiefenkarten verwendet.

Aus den mit Optical Flow geschätzten Vektorfeldern ergeben sich pixelgenaue Tiefeninformationen selbst für das monokulare Aufnahme-Setup. Besonders genaue Ergebnisse liefert die Fusion der Ergebnisse verschiedener Skalenniveaus. Um dies zu erreichen, werden die Ausgangsbilder in überlappende Kacheln unterschiedlicher Größe unterteilt und hinsichtlich der zur Verfügung stehenden GPU-Ressourcen durch bilineare Interpolation für RAFT Optical Flow passend skaliert. Die Ergebnisse werden wieder zusammengesetzt und auf Größe des Ursprungsbildes rückskaliert. Um Artefakte zu vermeiden, die daraus

entstehen, dass Optical Flow für manche Kacheln keine zuverlässigen Disparitäten vorhersagen kann, da der globale Kontext fehlt, werden die Ergebnisse der niedrigeren Skalenebene mit denjenigen der darauffolgenden vereint. Nur wenn die Ergebnisse bei höherer Auflösung mit der geringeren Auflösung übereinstimmen (maximal 1,5 Standardabweichungen Unterschied), werden die entsprechenden Werte ersetzt (Abb. 4).

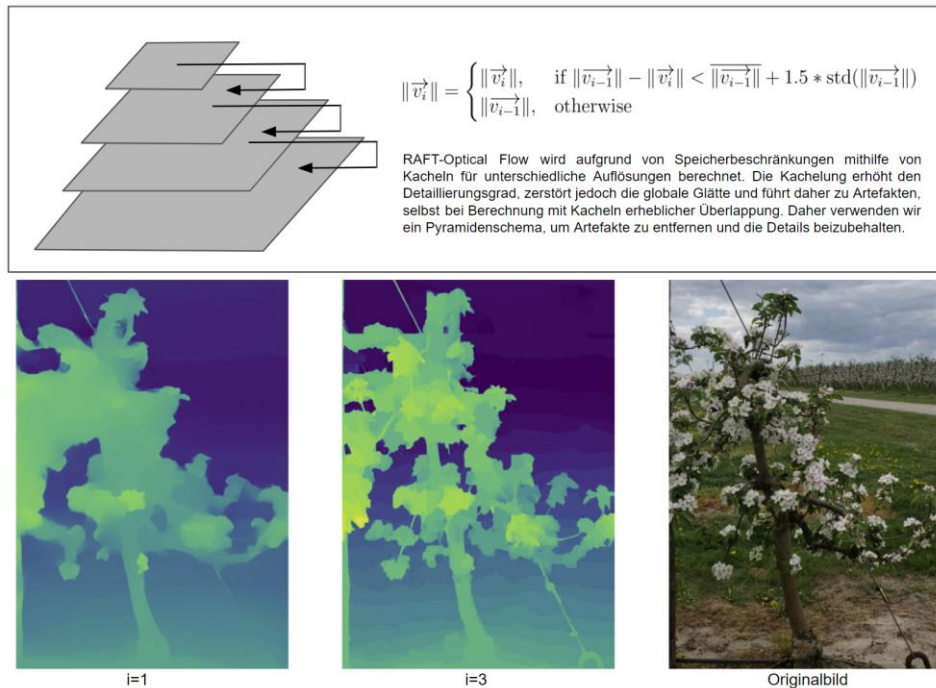


Abb. 4: Multiskalige Berechnung von Optical Flow zur pixeldichten Tiefenschätzung

Durch das vorgeschlagene Verfahren zur automatischen Bestimmung eines zeilenweisen Schwellenwertes können die Pixel der ersten Baumreihe bestimmt werden. Ein solcher zeilenweiser Schwellenwert ist notwendig, da sich die vorderen Bildbereiche des Bodens z. T. näher an der Kamera befinden als die Bäume selbst und ein globaler Schwellenwert daher keine zuverlässige Vordergrund-Hintergrund-Segmentierung ermöglicht. Das Verfahren stützt sich auf die Erkennung des Bodens und der ersten beiden Baumreihen.

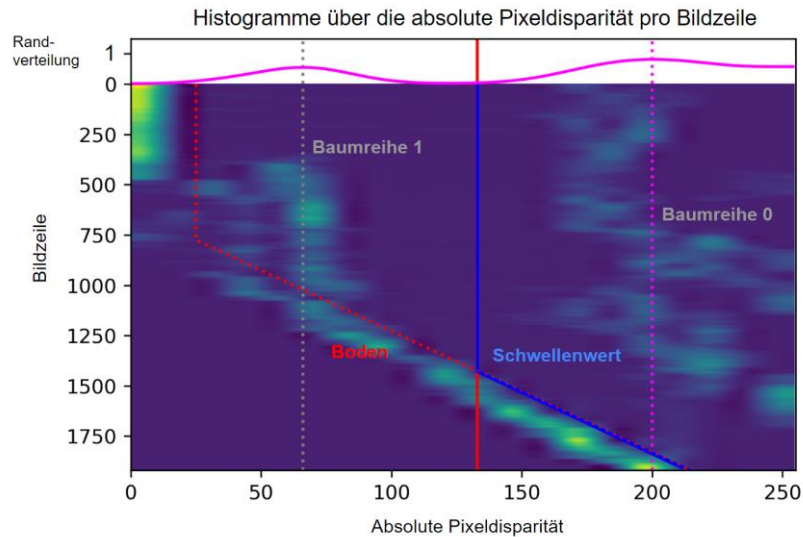


Abb. 5: Automatische Bestimmung eines zeilenweisen Schwellenwertes

Zunächst wird eine Karte der absoluten Pixeldisparitäten berechnet. Da Videos in der parallelen Vorbeifahrt an den Baumreihen aufgenommen wurden, ist insbesondere die horizontale Komponente relevant, welche die Bewegungsparallaxe erfasst. Anschließend wird für jede Bildzeile ein Histogramm über die Pixeldisparitäten berechnet. Hierfür werden 255 Klassen mit uniformem Abstand verwendet, wobei die untere Grenze der ersten Klasse null ist, während die maximal gemessene Verschiebung (geringste Tiefe) als obere Grenze der letzten Klasse gewählt wird. Bereiche mit geringer Verschiebung zwischen den Frames (große Entfernung zur Kamera) finden sich in dieser Repräsentation im linken Bereich, während solche mit einer großen Disparität (geringe Entfernung zur Kamera) rechts liegen. Die Baumreihen und der Boden sind gut zu erkennen (siehe Abb. 5). Um den Schwellenwert für den Boden zu schätzen, werden die zeilenweisen Histogramme durch einen Gauß-Filter geglättet und die lokalen Maxima bestimmt. Das erste lokale Maximum gibt Aufschluss über die Tiefe des Bodens in der jeweiligen Bildzeile. Um den Schwellenwert für den Boden zu bestimmen, werden die Koordinaten der lokalen Minima und Bildzeilen der unteren Bildhälfte durch ein lineares Regressionsmodell vorhergesagt, wobei diejenigen lokalen Maxima ausgeschlossen werden, die einer Verschiebung von unter 10 % entsprechen (Abb. 5, gestrichelte diagonale Linie). Eine positive Steigung der Regressionsgeraden zeigt an, dass dieser Schritt den Boden nicht korrekt erkennt, so dass die entsprechenden Aufnahmen ausgeschlossen werden können. Die Randverteilung über die Spalten gibt Aufschluss über die Baumreihen, die sich dort als lokale Maxima zeigen (Abb. 5). Der Schwellenwert für die Baumreihen wird so gewählt, dass er in der Mitte zwischen diesen Werten liegt (Abb. 5, blaue vertikale Linie), und der zeilenweise Schwellenwert ergibt sich als Maximum des Boden-Schwellenwertes und des Baumreihen-Schwellenwertes. Für einen Großteil der verwendeten Videos aus dem Frühjahr, bei denen



der Boden durch die Bäume noch nicht verdeckt ist, liefert dieses Verfahren gute Ergebnisse.

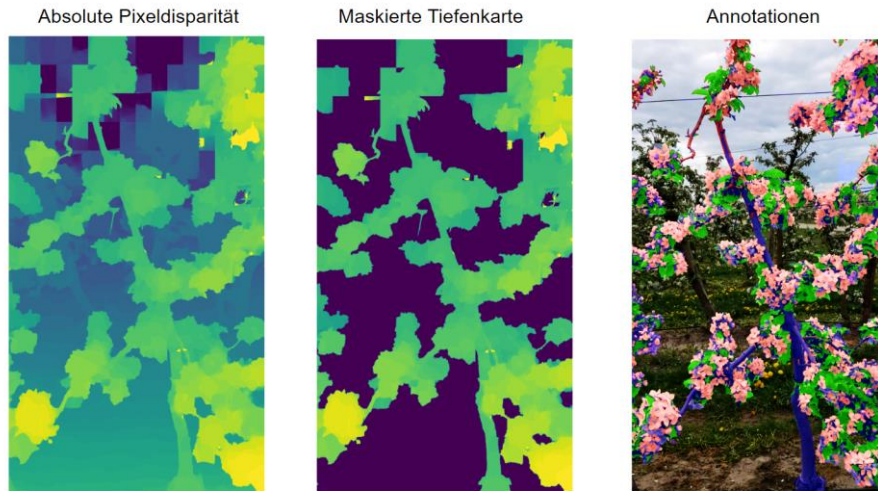


Abb. 6: Semantische Segmentierung von Ast-, Blatt- und Blütenflächen

Die Segmentierung von Ast-, Blatt- und Blütenflächen kann anschließend über die Pixelfarbe erreicht werden. Hierfür wurden Filter manuell definiert, welche Bereiche des HSV-Farbraumes eingrenzen. Grüntöne hinreichender Intensität entsprechen den Blättern, die Blüten sind sehr helle, wenig gesättigte Bereiche, Blautöne entsprechen dem Himmel und die verbleibenden Vordergrundpixel werden als Holz annotiert (Abb. 6). Während sich die Unterscheidung von Stützpfeuern und Astfläche mit diesem Verfahren schwierig gestaltet, überzeugt die Segmentierung der Bäume in einem großen Teil der blütentragenden Bäume. Ein Beispiel zeigt Abb. 6, wobei die Astfläche blau, die Blattfläche hellgrün und die Blüten pink hervorgehoben sind. Es bleibt jedoch anzumerken, dass eine Segmentierung über den Farbraum stark von der Witterung abhängig ist und für andere Aufnahmen abweichende Filterparameter notwendig sind.

## 5 Zusammenfassung und Ausblick

Die automatisierte Frucht- und Pflanzenerkennung in Apfelplantagen stützt sich auf Deep-Learning-Verfahren und Datensätze, die für deren Training geeignet sind. Beide Teilfragen sind aus agrartechnischer Sicht überaus bedeutsam. Die Fruchterkennung ist insbesondere deshalb wichtig, da gezielte Pflanzenschutzmaßnahmen eine Einsparung von Insektiziden versprechen und Voraussetzung für die robotergestützte Ernte von Tafeläpfeln ist. Eine zuverlässige Segmentierung der Bäume wird zukünftig ermöglichen, andere



wichtige Kennzahlen wie die Blütenfläche vorauszusagen und das Wachstum zu kontrollieren. Um den aktuellen Stand der Forschung besser zu verstehen, wurden für diesen Beitrag daher einerseits weitere Daten maschinengestützt erfasst, um Datensätze sowie Modellarchitekturen für die Objekterkennung zu vergleichen. Andererseits wurde die Frage der semantischen Baumsegmentierung adressiert.

Unsere Ergebnisse zur Apfelerkennung zeigen, dass YOLOv8 und FasterRCNN geeignete Architekturen für die Erkennung von Äpfeln in Plantagen sind, während SSD unzureichende Ergebnisse liefert. Domänenspezifisches Training ist vorteilhaft. Der Vergleich zwischen der Apfelerkennung mit einem Datensatz für die allgemeine Objekterkennung (MS-COCO) und Daten aus Apfelplantagen (MinneApple und NaLamKI) zeigt eine überlegene Vorhersagequalität beim Training mit den Daten aus der jeweiligen Obstkultur. Zwar zeigen die Ergebnisse, dass unsere Daten besser auf den Benchmark-Datensatz MinneApple übertragen werden können als umgekehrt, allerdings ist die Übertragbarkeit insgesamt noch nicht zufriedenstellend. Daher ist zu erwarten, dass auch in Zukunft Daten manuell annotiert werden müssen, um den bestehenden Datenpool zu erweitern. Human-in-the-Loop-Ansätze zur Datenannotation haben dabei einen entscheidenden Vorteil. Sie erlauben effizientes Labeling durch menschliche Beteiligung, nutzen bestehende Modelle und erweitern damit sukzessive den bestehenden Datenpool. Mit der stetigen Fortentwicklung von interaktiven Verfahren zur Inferenzkorrektur können diese Potenziale in Zukunft vermutlich noch besser genutzt werden [Ge22]. Für die semantische Segmentierung ist der hier vorgestellte Ansatz jedoch aktuell noch nicht geeignet, da initiale Annotationen fehlen.

Wir zeigen jedoch, dass eine pixelgenaue Vordergrundsegmentierung für einen großen Teil unserer Daten durch die Berechnung und Verarbeitung von RAFT Optical Flow erreicht werden kann. Das vorgeschlagene Verfahren stützt sich auf die Berechnung von Pixeldisparitäten und bestimmt zeilenweise Schwellenwerte für die Segmentierung. Obwohl es nicht immer gute Ergebnisse liefert, kann es zur Erzeugung von Trainingsdaten verwendet werden. Nachdem sie manuell bereinigt und ggf. Korrekturen vorgenommen wurden, können zukünftig Deep-Learning-Verfahren für die Segmentierung auf diesen Daten trainiert werden. Beim Einsatz von geeigneten Verfahren zur Augmentierung der Daten versprechen diese robustere Ergebnisse.

#### Literaturverzeichnis

- [BU17] Bargoti, S.; Underwood, J.P.: Image segmentation for fruit detection and yield estimation in apple orchards. In: *Journal of Field Robotics* 34 (6), S. 1039–1060, 2017.
- [BKZ19] Bhusal, S.; Karkee, M.; Zhang, Q.: *Apple Dataset Benchmark from Orchard Environment in Modern Fruiting Wall*, 2019.
- [Bo23] Bosse, S. et al.: Nachhaltige Landwirtschaft mittels Künstlicher Intelligenz. Ein plattformbasierter Ansatz für Forschung und Industrie. In: 43. GIL-Jahrestagung, Resiliente Agri-Food-Systeme. 2023.

- [Ge20] Gené-Mola, J. et al.: Fruit detection and 3D location using instance segmentation neural networks and structure-from-motion photogrammetry. In: *Computers and Electronics in Agriculture* 169, S. 105165. 2020.
- [Ge22] Gerstenberger, M. et al.: But that’s not why: Inference adjustment by interactive prototype deselection. In: *arXiv preprint arXiv:2203.10087*. 2022.
- [Ge23] Gerstenberger, M. et al.: A differentiable Gaussian Prototype Layer for explainable Segmentation. In: *arXiv preprint arXiv:2306.14361*. 2023.
- [Go15] Gongal, A. et al.: Sensors and systems for fruit detection and localization: A review. In: *Computers and Electronics in Agriculture* 116, S. 8-19. 2015.
- [HRI20] Häni, N.; Roy, P.; Isler, V.: MinneApple: a benchmark dataset for apple detection and segmentation. In: *IEEE Robotics and Automation Letters* 5 (2), S. 852–858. 2020.
- [Jo23] Jocher, G. et al.: YOLO by Ultralytics. Online verfügbar unter <https://github.com/ultralytics/ultralytics>, , abgerufen am 25.01.2024. 2023.
- [KMN19] Kestur, R.; Meduri, A; Narasipura, O.: MangoNet: A deep semantic segmentation architecture for a method to detect and count mangoes in an open orchard. In: *Engineering Applications of Artificial Intelligence* 77, S. 59–69. 2019.
- [Ko19] Koirala, A. et al.: Deep learning for real-time fruit detection and orchard fruit load estimation: Benchmarking of ‘MangoYOLO’. In: *Precision Agriculture* 20, S. 1107–1135. 2019.
- [Li19] Lin, T. et al.: Microsoft COCO: Common Objects in Context. In: *European Conference on Computer Vision*: Springer, Cham, S. 740–755. 2019.
- [LY20] Lu, Y.; Young, S.: A survey of public datasets for computer vision tasks in precision agriculture. In: *Computers and Electronics in Agriculture* 178, S. 105760. 2020.
- [Sa16] Sa, I. et al.: Deepfruits: A fruit detection system using deep neural networks. In: *sensors* 16 (8), S. 1222. 2016.
- [SML22] Storey, G.; Meng, Q.; Li, B.: Leaf disease segmentation and detection in apple orchards for precise smart spraying in sustainable agriculture. In: *Sustainability* 14 (3), S. 1458. 2022.
- [TC23] Terven, J.; Cordova-Esparza, D.: A Comprehensive Review of YOLO: From YOLOv1 and Beyond. In: *arXiv preprint arXiv:2304.00501*. 2023.
- [Zh20] Zhang, Z. et al.: Technology progress in mechanical harvest of fresh market apples. In: *Computers and Electronics in Agriculture* 175, S. 105606. 2020.

## CherryGraph: Encoding digital twins of cherry trees into a knowledge graph based on topology

Andreas Gilson<sup>1</sup>, Mareike Weule<sup>1</sup>, Jonathan Hansen<sup>1</sup>, Lukas Meyer<sup>2</sup>, Fabian Keil<sup>1</sup>,  
Oliver Scholz<sup>1</sup>, Annika Killer<sup>3</sup>, Patrick Noack<sup>3</sup>, Marc Stamminger<sup>2</sup> and Ute Schmid<sup>4</sup>

**Abstract:** *CherryGraph* is a structural framework for mapping trees into an ontology-based knowledge graph that can be used as database backend for digital twins. Based on the reconstructed 3D topology of scanned trees, information is encoded in a knowledge graph that resembles the real canopy structure of trees. Thus, *CherryGraph* enables consistent navigation within the branching system of a tree over different time points regardless of natural fluctuations. The resulting knowledge graph can then be queried for arbitrary use cases or aggregated on different hierarchy levels. We demonstrate the potential of *CherryGraph* by using data of real cherry trees from the 2023 cherry season with exemplary queries that can be extended to include spatial and temporal dimensions for comparing indicators like elongation growth of shoots or tracking the development of other various tree traits over time.

**Keywords:** cherry tree, digital horticulture, digital twin, knowledge graph, orchard, phenotyping, tree topology, precision farming

### 1 Introduction

The creation of precise digital twins is a crucial step for the digitalization in smart farming and precision agriculture. While there has been a lot of progress recently in the general field of smart farming, horticulture is still a niche [NH22] that gets relatively little attention from researchers. The *For5G: Digital Twin* project [Me23a] contributes to this niche by presenting an end-to-end pipeline for digital twins in horticulture. This paper presents the next concluding step of our project publications: mapping physical traits and components of trees into a digital knowledge graph representation. The digitalization of living trees is a complex procedure, and our proposed approach *CherryGraph* contributes to research in this field in multiple ways:

---

<sup>1</sup> Fraunhofer Institut für Integrierte Schaltungen (IIS/EZRT), Flugplatzstr. 75, 90768 Fürth, {andreas.gilson, franz.uhrmann, mareike.weule, fabian.keil, jonathan.hansen, oliver.scholz}@iis.fraunhofer.de

<sup>2</sup> Friedrich-Alexander-Universität Erlangen-Nürnberg, Chair of Visual Computing, Cauerstraße 11, 91058 Erlangen, {lukas.meyer, marc.stamminger}@fau.de

<sup>3</sup> Hochschule Weihenstephan-Triesdorf, Neuseser Straße 1, 91732 Merkendorf, {annika.killer, patrick.noack}@hswt.de

<sup>4</sup> Otto-Friedrich-Universität Bamberg, Cognitive Systems, An der Weberei 5, 96047 Bamberg, ute.schmid@uni-bamberg.de

1. By relying on the tree topology instead of the Euclidian space we ensure consistency over time and mitigate problems caused by natural fluctuations of spatial relations that occur during the development of a bud into a harvested fruit.
2. *CherryGraph* works at various levels of abstraction. It is possible to encode generic global features of a tree (height, size, topology, etc.) in the same way as detailed representation of traits (branches, cherries, blossoms, etc.) and external data of arbitrary types (temperature, weather events, etc.).
3. The knowledge graph enables individual querying with customized inquires for specific use-cases (e.g., calculation of correlations between external factors and their influence on harvest yield or in-depth comparisons of different trees).
4. Our approach enables novel kinds of visualizations that assist decision-making processes in orchards by blending virtual symbolic information with real data.

*CherryGraph* closes the gap between data acquisition and higher-level processing steps of end-user application for researchers, breeders and farmers. The resulting knowledge graph is effectively the data backend of the *For5G: digital twin*. Based on the topology of trees, the data is stored into a graph database that enables precise querying and visualizations for specific questions of interest.

## 2 Background and Related Work

The current state of digitalization in agriculture is referred to as the fourth agricultural revolution or “Agriculture 4.0” [PN22]. The digital twin paradigm could be a key technology [NH22] for the next step of digitalized agriculture. Even though it received increasing attention in recent years [PN22], it remains a niche topic relatively little exploited in research [NH22]. The overarching objective of digital twins is to capture and model the complexity of an entity (living or not) and its dynamic embeddedness to the environment [POA21]. Digital twins offer a holistic approach, combining different angles and leveraging new technological opportunities [POA21]. Most studies surrounding this topic in agriculture focus on less holistic and more isolated areas of this research field, like e.g., AI applications, data analytics or robotics [NH22]. While the application of digital twins in orchards and fruit cultivation is an even smaller niche, there too has been an uptick of related publications in recent years:

[Za23] explore the concept of digital twins for orchards on a theoretic level, while formulating the key principles with focus on yield management for apples, pears and sweet cherries. [Ti23] developed a digital model of an apple tree as environment to train a robot arm with reinforcement learning. [An20] propose a generic digital twin framework focussing on a distributed network of wireless sensors. A promising approach for developing digital twins of orchards comes from [Pe19] – they use a combination of LiDAR and cameras for ground-based scanning and trialled multiple types of crops. However, they focus on 3D LiDAR data, which has its own set of challenges that vastly

differ from 2D images gathered in our project. Furthermore, most of the work mentioned focuses on data capturing or sensors, which does not cover database frameworks for digital twins. Outside of the agricultural domain, the connection between digital twins and knowledge graphs has been subject of research. In [Sa21] it is argued that knowledge graphs are an effective way for structuring heterogeneous data and are well suited for designing intelligent digital twins. Other researchers go one-step further, exploring the potential and risks of knowledge graphs for digital twins. The authors from [Zh21] investigate new possibilities that arise through the usage of knowledge graphs as database, like deep learning-based detection of faulty data. Whereas [Ch21] address security concerns of applied digital twins in agriculture.

### 3 Methodology and Setup of *CherryGraph*

For end-user-applications, it is required to fuse information from different hierarchy levels (from orchard to blossoms) into one shared data structure. A knowledge graph-based system with individual nodes fulfills this requirement, but also lacks an inherent structure. This can lead to incomprehensibility and unnecessary complex queries. This is why we chose a diversified hierarchy layout for *CherryGraph* with multiple levels.

#### 3.1 Hierarchical structure

The *CherryGraph* hierarchy provides four levels as listed in Tab. . An orchard contains cherry trees, which are groups of forks, branches and trunks, which again carry data values (see Fig. 1).

| Hierarchy level | Physical counterpart   |
|-----------------|--|
| 0               | Orchard / tree group   |
| 1               | Individual tree  |
| 2               | Object group (e.g.: branch, fork, trunk)                                       |
| 3               | Data values (e.g.: number of cherries, trunk diameter, leaf area, tree height) |

Tab. 1: Hierarchical structure of *CherryGraph*

This structure allows a high flexibility for adding new data to the knowledge graph and makes it possible to query recursively. Besides, external data like weather (level 0), soil type (level 1) can be easily added to the knowledge graph according to their hierarchy level. Depending on whether one wants to compare the number of cherries of a single tree

over time or the total number of cherries of two orchards, one can formulate recursively queries based on the hierarchical levels.




Fig. 1: Hierarchy level from orchard (left) to data object (right)

### 3.2 Knowledge graphs

A knowledge graph is used to store knowledge in a dynamic way. It allows us to add any kind of information and to set connections between data. The structure of a knowledge graph makes it possible to query not only specific data points but also to generate new knowledge from graph traversing queries.

In general, a knowledge graph is a graph-structured data model based on specific ontologies. The graph nodes and their relationships can be represented by semantic triples such as resource description framework (RDF) triples. These triples are based on a simple structure that each triple consists of a subject, a predicate and an object. Hereby, the subject and the object are graph nodes, and the predicate is the connection/edge between them [W323a]. The semantic schema of the triples, which defines allowed expressions and relationships, is given by the ontologies on which the knowledge graph is based. Depending on the content and the usage of the knowledge graph, several different ontologies exist for different themes [W323b].

For *CherryGraph*, we chose the prov-ontology (PROV-O) [W323c], the RDF schema (RDFS) [Wi23] and the web ontology language (OWL) [W323d]. For describing the topology-based cherry tree data, we developed our own ontology, called *for5G*.

PROV-O provides a simple description of knowledge using a small set of classes and properties to classify and link data. The three main classes are: `Prov:Entity`, `Prov:Activity`, and `Prov:Agent`. An entity is a real or imaginary thing with fixed aspects. An activity is something that occurs over time and links two entities together. An agent is a person or something that is responsible for an activity or entity [W323c].

Each RDF subject and object is assigned to one of the three PROV-O classes and can be linked to each other by a few expressions that can be seen in Figure 2. These connections are the RDF predicates.

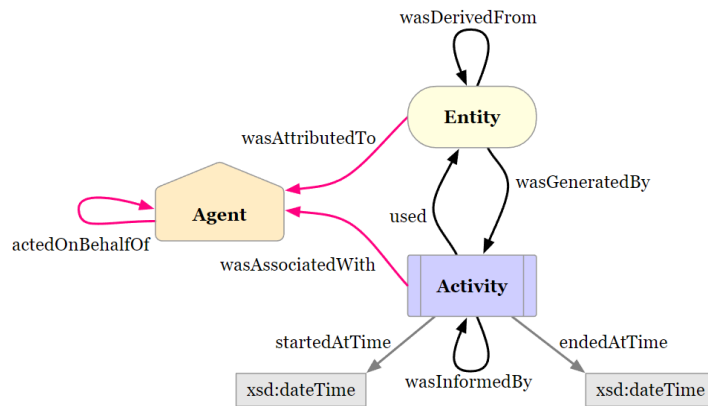


Fig. 2: Schema of the three PROV-O base classes and their connections [W323c]

Besides the main classes, there are the expanded PROV-O terms (see Fig. 3). Here, the agent and entity class have subclasses and some more possible relations, which are needed to describe a complex network.

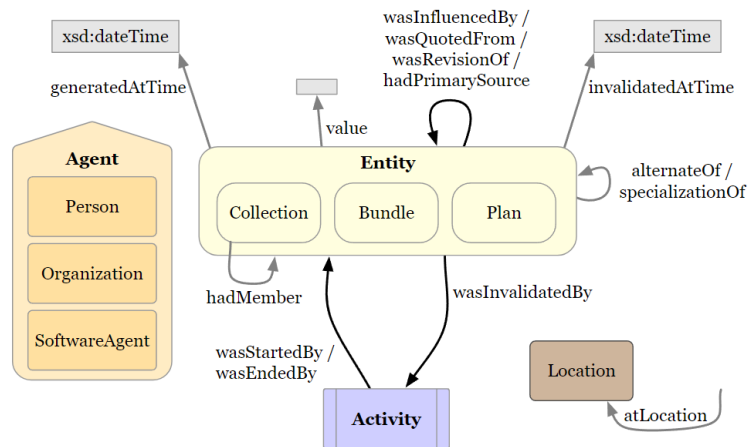


Fig. 3: Schema of the expanded PROV-O classes [W323c]

For *CherryGraph*, we elaborated what data is provided for the graph and how it is linked to each other in the context of PROV-O (see Fig. 4). Regarding the PROV-O classes, a cherry tree yields several points of information: each cherry tree is a specific cherry tree, which belongs to a tree orchard. It has a specific position and crop data (tree size, trunk diameter, number of cherries, blossoms, buds) for different time stamps.

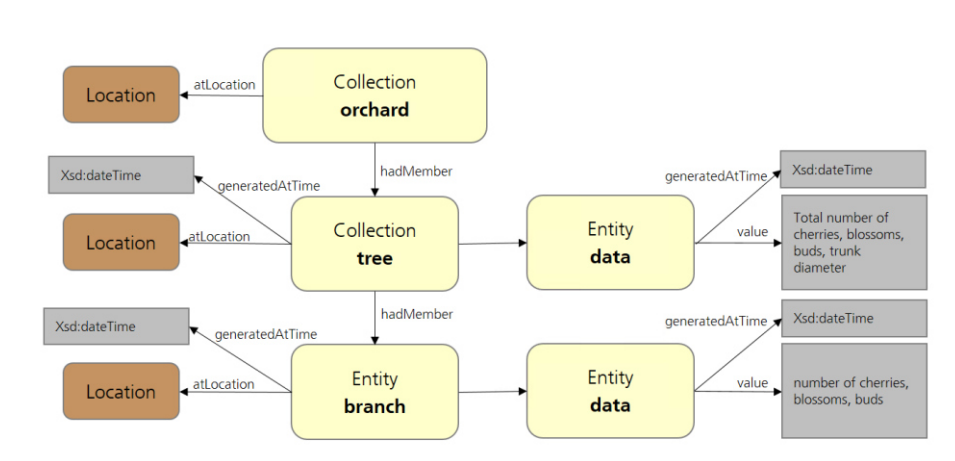


Fig. 4: Schematic drawing of cherry tree data relations according to PROV-O

The schematic drawing shows that there are relations that cannot be covered by PROV-O. One point is that every tree and every branch is linked to possibly many data entities (e.g., number of cherries or the trunk diameter at a specific time). Data is an entity which can belong to a whole tree (Collection of branches) or to one specific branch. The PROV-O entity-entity dependencies do not match these relationships in their formulation. Another point is that every data entity has a specific value (e.g., number of cherries or blossoms), but PROV-O provides no possibility to label the value. Furthermore, each Collection and Entity should be generally labelled as “orchard”, “tree”, “branch” or “data”. Thus, we extended *CherryGraph* with our own ontology: *for5G*.

### 3.3 For5G ontology

For *CherryGraph*, it is essential to label the entities and link them in the context of cherry trees. Therefore, the *for5G* ontology provides semantic terms, which are listed in Tab. 2.

| For5G term       | Usage   |
|------------------|---|
| For5G:type       | Links to for5G type which specifies the type of the entity. Possible types: data, tree, branch, fork, orchard |
| For5G:data       | Marks an entity as data   |
| For5G:branch     | Marks an entity as a branch   |
| For5G:cherrytree | Marks an entity as a tree   |



|                          |  |
|--------------------------|--|
| For5G:fork               | Marks an entity as a fork point between branches   |
| For5G:orchard            | Marks an entity as an orchard  |
| For5G:hadData            | Links to entity containing data  |
| For5G:hadValueType       | Links to literal, which specifies data value type.<br>Possible types: length, nb_of_cherries, etc.       |
| For5G:connected          | Links two forks in a branch  |
| For5G:branchLevel        | Different types of branches (trunk, main branch, etc.)   |
| For5G:id                 | A for5g specific id  |
| For5G:hadAcquisitiontype | Links to literal, which specifies data acquisition type.<br>Possible types: topology, ground truth, etc. |

Tab. 2: Semantic terms of the *for5G* ontology

While Tab. 2 lists the current state of the *for5G* ontology, this list is not exhaustive and likely will be extended as part of the ongoing project progress.

## 4 *CherryGraph* in Practice

In the following, we show the application of *CherryGraph* based on real data of a cherry tree from the *For5G: digital twin* project. The evaluated drone data includes a branch, which was also examined manually. Thus, we have ground-truth data of the exact numbers of buds, blossoms and cherries and their positions at the branch. The evaluated branch topology was parsed to RDF triples in consent of *CherryGraph* and put onto a Jena Apache Fuseki SPARQL server [Je23] for querying.

### 4.1 Topology guided mapping from real world into knowledge graph

Our goal for the *For5G: Digital Twin* project is to develop an end-to-end pipeline for digital twins in horticulture. Information of higher hierarchy levels e.g., information about the orchard can be set up independently of data acquisition. For more detailed levels like tree or sub-tree levels, we chose another approach. The sweet cherry trees of our project are scanned once at the start of the season during dormancy. Utilizing specialized semantic segmentation [SGS23] and *CherryPicker* [Me23b], we gain detailed graphs that represent the topology of individual trees and their canopy structure. This tree skeleton is subsequently used as “navigation map” for tracking the tree and its traits throughout the whole season. The extracted topology information is directly translated into RDF triples. Each Node in the topology graph represents information about the location of fork points

and edges contain information about branches. This information needs to be translated into the subject-predicate-object form of RDF triples to be usable by a triple store through the turtle file format [W323e]. Iterating through the topology data generates the needed hierarchical structure, always adding geospatial and time information to exactly label generated items. In this step, each item gets its unique identifier and ontology IRI (Internationalized Resource Identifier) [Da23].

Furthermore, the distance between two connected forks is calculated as Euclidian distance between the two 3D point coordinates of the forks. The result is the length of the branch between the forks and is added as value of a data entity with `for5G:hadValueType "length"` to the RDF triples. The data entity is connected to the branch entity with `for5g:hadData`. Since the topology is based on scaled 3D cherry tree point clouds, the calculated length is in metrical units. The same procedure can be applied to other data entities like e.g., clusters of blossoms that are attached to their respective branch entity.

## 4.2 Querying

Based on our project data collected during the 2023 cherry season, we created a *CherryGraph*, and parsed our project data into RDF triples accordingly. In Figure 5, we display two example SPARQL queries that demonstrate information retrieval in practice.

```

SELECT (SUM(xsd:float(?v)) as ?total) WHERE {
  # find a specific orchard
  ?orchard for5g:type for5g:orchard .
  ?orchard for5g:id "orchard_01" .
  ?orchard prov:hadMember ?tree .

  # select one tree
  ?tree for5g:type for5g:cherrytree .
  ?tree for5g:id "Satin_02" .
  ?tree prov:hadMember ?branch .

  # get all branches and data
  ?branch for5g:type for5g:branch .
  ?branch for5g:hadData ?data .

  # select data for 'length'
  ?data prov:atTime "2023-05-17".
  ?data for5g:hadValueType "length" .
  ?data prov:value ?v .
}

SELECT ?growth WHERE {
  {
    SELECT (SUM(?v1f) as ?total1) WHERE {
      ?data1 for5g:hadValueType "length" .
      ?data1 prov:atTime "2023-05-17" .
      ?data1 prov:value ?v1 .
      BIND(xsd:float(?v1) as ?v1f) .
    }
  }
  {
    SELECT (SUM(?v2f) as ?total2) WHERE {
      ?data2 for5g:hadValueType "length" .
      ?data2 prov:atTime "2022-05-17" .
      ?data2 prov:value ?v2 .
      BIND(xsd:float(?v2) as ?v2f) .
    }
  }
  BIND(?total1-?total2 as ?growth)
}

```

Fig. 5: Example for SPARQL queries from our current implementation of *CherryGraph*, containing data of the 2023 season from the *For5G: Digital Twin* project cherry trees

The left query in Figure 5 is for calculating the total branch length of a specific tree. The actual query includes the SPARQL term `SELECT` and the condition term `WHERE`. All values `v` that fulfill the conditions will be summed up and returned as `total`. In the condition section, the hierarchal structure of the cherry tree is visible. First, one filters the orchards for the searched “orchard\_01” and retrieves all its trees. Second, one reduces the trees to

“Satin\_01” and gets all its branches. Third, the data of all branches is selected and last, one asks for all values of the data type “length” at the specific time “2023-05-17”. This query can be also used for counting the total number of blossoms, buds or cherries by slightly modifying it. To achieve this, the searched data type must be changed. Instead of “length”, it could be “nb\_of\_cherries”.

For data comparison over time, one can query for several different time stamps and evaluate the returned values or modify the query as shown on the right side of Figure 5.

These two example queries demonstrate the methodology for information retrieval from *CherryGraph*. It is also possible to aggregate data of different objects to gain very detailed information on higher hierarchy levels like e.g., the average branch length of a single tree within the orchard, which then can be used to identify potential problematic trees or tree groups that perform significantly better than the rest. This has obvious potential for end-users like farmers that try to maximize yield and researchers or breeders that run extensive experiments with different species, soil, fertilizers or watering cycles. Furthermore, *CherryGraph* is able to store external data like hours of sunshine, temperature or frequency and quantity of precipitation. The combination of detailed tree trait information with external data enables novel angles for research and tracking of orchards.

### 4.3 Result visualization

Choosing the 3D point clouds of real trees as foundation for our data pipeline comes with another benefit: it allows novel forms of visualization. In the process of extracting semantic information in the form of symbolic representations out of the original point cloud, the structure of the object in question remains untouched. This allows us to use the original data together with the extracted topology and object values to create novel views. We demonstrated this in Figure 6 on sub-tree level using a single branch. Individual data objects are forks within the branch that allow us to calculate the lengths of shoots or sub-branches and clusters of points from blossoms. We can calculate the blossom cluster volumes and use this for further research like estimating the yield based on blossom quantity.

Similar kinds of analysis are also possible on higher hierarchy levels (tree group or orchard) and for all kinds of measured data instances (buds, leaves, cherries and visible signs of pests, dryness or diseases).

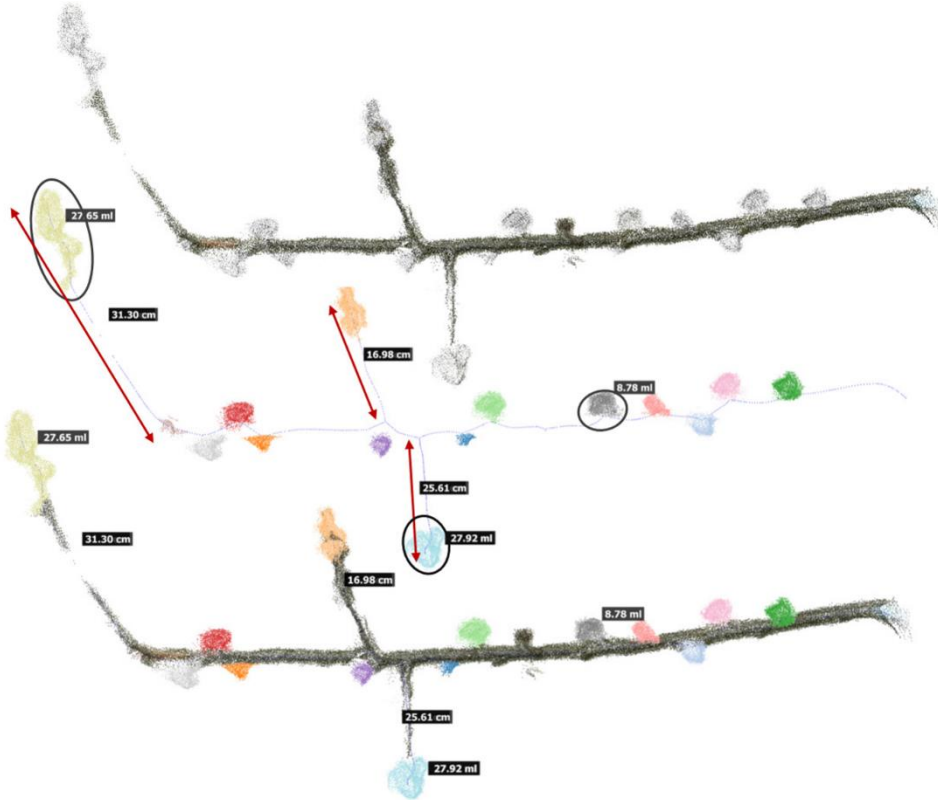


Fig. 6: Example for novel visualizations: original point cloud (top), extracted skeleton with instance segmented blossom clusters (middle) and combined view (bottom). Numerical values describe exemplary sub-branch lengths (cm) and blossom cluster volumes (ml)

## 5 Remaining Challenges

Since the *For5G: digital twin* project has completed data acquisition during only one season so far, it is not yet clear how the overlap of topologies from different seasons of the same tree will cause problems. Growth of new shoots or measures like severe pruning have the potential to inflict fundamental changes in the branching structure and topology. However, even if this problem becomes unsolvable, it only affects sub-tree level analyses and will not impede analysis on the more crucial higher hierarchy levels.

Additionally, there are challenges remaining before our approach becomes truly practical for farmers and other commercial use-cases. The data acquisition process is still too expensive in terms of time and resources, and it is not yet clear for which particular use

cases the cost-benefit ratio for mapping of individual trees will become worthwhile in the future. Incomplete data is also problematic for advanced analyses, even though the knowledge graph system of *CherryGraph* can handle sparse or missing data points.

## 6 Conclusion and Outlook

*CherryGraph* is the database backend for the *For5G: Digital Twin* project. The knowledge graph solves several challenges of the data storage process within the digitalization of trees and orchards at the same time. By following a flexible hierarchy, it embodies the physical canopy structure of trees and their fine-grained traits over time, while still being able to store data about external events and higher-level information about orchard setups. We explain the newly developed *for5g* ontology and highlight example queries that demonstrate the potential for analyses and novel insights of our digital twin concept for different types of end users, like farmers, researchers or breeders.

While the *CherryGraph* is self-contained as a database concept, there are multiple challenges remaining when one takes a step further away and evaluates it embedded into the overarching project goal. Data collection is too resource-intensive and many of the processing steps in between (e.g., yield prediction, automated fruit counting, branch analysis, watering status, pests and sickness) are not sufficiently solved for application in practice. Yet, the underlying concept of *CherryGraph* can easily be transferred to other use cases. We are eager to contribute to the scientific community around digital twins in agriculture and thus release the project data gathered so far in an accompanying publication [Gi24]. We also plan to further develop our processing and visualization methods during the course of our project with the ultimate goal of transferring the theoretical concept of digital twins into actual agricultural practice.

### Bibliography

- [An20] Angin, P. et al.: AgriLoRa: A Digital Twin Framework for Smart Agriculture. *J. Wirel. Mob. Networks Ubiquitous Comput. Dependable Appl.* 11, pages 77-96, 2020.
- [Ch21] Chukkapalli, S. S. L. et. al: Cyber-Physical System Security Surveillance using Knowledge Graph based Digital Twins - A Smart Farming Usecase, 2021 IEEE International Conference on Intelligence and Security Informatics (ISI), San Antonio, pages 1-6, 2021.
- [Da23] Internationalized Resource Identifiers, <https://datatracker.ietf.org/doc/html/rfc3987>, 23.10.2023.
- [Gi24] Gilson, A. et al.: CherrySet -- A comprehensive dataset of three cherry trees throughout the 2023 season. *Authorea Preprints - North American Plant Phenotyping Network Annual Conference (NAPPN)*, West Lafayette, 2024.

- [Je23] Apache Jena Fuseki, <https://jena.apache.org/documentation/fuseki2/>, 23.10.2023.
- [Me23a] Meyer, L. et al.: For5G: Systematic approach for creating digital twins of cherry orchards. In (Gesellschaft für Informatik e.V.): 43. GIL-Jahrestagung, Resiliente Agri-Food-Systeme, Osnabrück, pages 411–416, 2023.
- [Me23b] Meyer, L. et al.: CherryPicker: Semantic Skeletonization and Topological Reconstruction of Cherry Trees. In (IEEE/CVF): Proc. Conference of Computer Vision and Pattern Recognition (CVPR) Workshops, Vancouver, pages 6244–6253, 2023.
- [NH22] Nasirahmadi, A.; Hensel, O.: Toward the Next Generation of Digitalization in Agriculture Based on Digital Twin Paradigm, In Sensors and Robotics for Digital 2/2022, 2022.
- [Pe19] Peyman, M. et al: Digital Twin for the Future of Orchard Production Systems, In: The Third International Tropical Agriculture Conference (TROPAG), 2019.
- [PN22] Purcell, W.; Neubauer, T.: Digital Twins in Agriculture: A State-of-the-art review, In: Smart Agricultural Technology 3/2023, 2022.
- [POA21] Pylianidis, C.; Osinga, S.; Athanasiadis, I.: Introducing digital twins to agriculture, In: Computers and Electronics in Agriculture 184/2021, 2021.
- [Sa21] Sahlab, N. et. al: Knowledge Graphs as Enhancers of Intelligent Digital Twins, In: *4th IEEE International Conference on Industrial Cyber-Physical Systems (ICPS)*, Victoria, BC, Canada, 2021, pp. 19-24. 2021.
- [SGS23] Scholz, O.; Gilson, A.; Schmid, U.: Spherical Subsampling as a new Approach for Augmentation of 3D Point Cloud Data of biological Scans, In: North American Plant Phenotyping Network, 2023.
- [Ti23] Tian, X. et al: Fruit Picking Robot Arm Training Solution Based on Reinforcement Learning in Digital Twin, In Journal of ICT Standardization 11/2023, 2023.
- [Wi23] RDF Schema, [https://en.wikipedia.org/wiki/RDF\\_Schema](https://en.wikipedia.org/wiki/RDF_Schema), 16.10.2023.
- [W323a] Resource Description Framework (RDF) Model and Syntax Specification, <https://www.w3.org/TR/PR-rdf-syntax/>, 16.10.2023.
- [W323b] List of ontologies, [https://www.w3.org/wiki/Lists\\_of\\_ontologies](https://www.w3.org/wiki/Lists_of_ontologies), 16.10.2023.
- [W323c] PROV-O: The PROV Ontology, <https://www.w3.org/TR/prov-o/>, 16.10.2023.
- [W323d] Web Ontology Language (OWL), <https://www.w3.org/OWL/>, 16.10.2023.
- [W323e] RDF 1.1 Turtle, <https://www.w3.org/TR/turtle/>, 23.10.2023.
- [Za23] Zarembo, I. et al: Digital Twin: Orchard Management using UAV. In: Environment. Technologies. Resources, 2023.
- [Zh21] Zhu, Y. et al: A knowledge graph based construction method for Digital Twin Network, *IEEE 1st International Conference on Digital Twins and Parallel Intelligence (DTPI)*, Beijing, pages 362-365, 2021.

## **Analyse des Product Carbon Footprints im Produktions- und Verarbeitungsprozess von Topinambur (*Helianthus tuberosus* L.)**

**Ein ganzheitlicher Ansatz unter Einbeziehung von Wasserverbrauch, menschlichen Arbeitszeiten und Stromverbrauch**

Hakan Guerler<sup>1</sup>, Hilke Risius<sup>1</sup>, Richard Albrecht<sup>2</sup>, Julian Rosenbaum<sup>1</sup>, Christin Röpert<sup>1,3</sup>, Frank Lienig<sup>2</sup> und Eckart Kramer<sup>1</sup>

**Abstract:** Der PCF bezieht sich auf die Bilanzierung der Treibhausgas (THG) - Emissionen und des THG-Abbaus entlang des gesamten Lebenszyklus eines Produkts. Ziel dieser Studie ist es, den Product Carbon Footprint (PCF) in der Wertschöpfungskette von Topinambur zu analysieren. Eine repräsentative Menge von 100 kg Topinambur wurde als Grundlage für die PCF-Berechnung im Anbau und in der Verarbeitung gewählt. Für die gesamte Verarbeitung wurden der Strom- und Wasserverbrauch sowie die menschliche Arbeitszeit gemessen. Die Ergebnisse zeigen die signifikante Rolle des Wasserverbrauchs bei den Treibhausgasemissionen, gefolgt vom Stromverbrauch und der menschlichen Arbeitszeit. Diese Ergebnisse unterstreichen die Dringlichkeit der Identifizierung von Emissionsminderungspotenzialen in der Topinambur-Verarbeitung und unterstreichen gleichzeitig die Bedeutung einer genauen Datenerfassung und realistischer Emissionsfaktoren für zukünftige Untersuchungen.

**Keywords:** Product Carbon Footprint (PCF), Topinamburanbau – und verarbeitung

### **1 Einleitung**

Im Verbundprojekt „Stadt-Land-Fluss“ (SLF) werden daten- und auf Künstliche Intelligenz (KI) gestützte Methoden zur Stärkung regionaler Wertschöpfungsketten mittels digitaler Datenplattformen und Methoden der KI erforscht. Ein Teilziel des Projekts ist die Nachhaltigkeitsanalyse von Wertschöpfungsketten der Agrar- und Ernährungswirtschaft (AEW) mit Hilfe des CO<sub>2</sub>-Fußabdrucks (Product Carbon Footprint, PCF). Die Wertschöpfungskette Topinambur wird in der vorliegenden Arbeit unter Einbeziehung der menschlichen Arbeitskraft und des Wasserverbrauchs untersucht.

---

<sup>1</sup> Hochschule für nachhaltige Entwicklung Eberswalde, Schicklerstr.5, 16225 Eberswalde, Hakan.Guerler@hnee.de, Hilke.Risius@hnee.de, Julian.Rosenbaum@hnee.de, Christin.Roepert@hnee.de, Eckart.Kramer@hnee.de

<sup>2</sup> Lienig Wildfruchtverarbeitung GmbH, Dabendorf, Märkische Str. 66, 15806 Zossen, Richard.Albrecht@lienig.com, flienig@lienig.com

<sup>3</sup> pro agro e.V., Gartenstraße 1-3, 14621 Schönwalde / Glien, christin@food-mentor.de

Die Produktion, Verarbeitung und der Konsum von Lebensmitteln verursachen mehr als 20 % der anthropogenen Treibhausgasemissionen. Diese Zahl wird bis zum Jahr 2050 voraussichtlich auf 30 % steigen. Jährlich entstehen so etwa 9.800 bis 16.900 Millionen Tonnen CO<sub>2</sub>. So gilt die ressourcenintensive Agrar- und Ernährungswirtschaft bei derzeitigem Konsummuster als einer der Hauptverursacher des Klimawandels, welcher die natürlichen Systeme belastet und somit die menschliche Lebensgrundlage gefährdet. In diesem Zusammenhang stehen die Verringerung von Schadstoffeinträgen in Atmosphäre, Boden und Wasser sowie die Gewährleistung einer nachhaltigen Bewirtschaftung natürlicher Ressourcen im Fokus von ernährungswirtschaftlichen Betrieben [Ka22].

Umso wichtiger ist es, einzelne Ressourcenverbräuche und Schadstoffemissionen entlang der Wertschöpfungskette mittels geeigneter Bewertungsmethoden sichtbar zu machen, um zielgerichtet betriebliche oder kettenübergreifende Maßnahmen zur Reduktion von Wasser- und Energieverbräuchen zu ergreifen. Hierfür hat sich in Forschung und Wirtschaft der sogenannte Product Carbon Footprint (PCF) etabliert. Er kann als Messgröße beschrieben werden, die sämtliche Ressourcenverbräuche in CO<sub>2</sub>-Äquivalenten zum Ausdruck bringt, welche im Verlauf des Lebenszyklus eines bestimmten Produkts freigesetzt werden [RG21]. Die Analyse des PCF leistet einen wichtigen Beitrag zur Gestaltung nachhaltiger Wertschöpfungsketten. Er ermöglicht die Analyse von Prozessschritten hinsichtlich ihrer Klimawirkung sowie die Identifizierung von Optimierungspotenzialen [PAP11].

Bislang besteht nach derzeitigem Kenntnisstand keine Möglichkeit, den bei Anbau, Verarbeitung und Transport entstehenden PCF zu berechnen und für jede Prozessstufe zu erfassen, zu analysieren und zu optimieren. Hierzu werden geeignete Tools benötigt, um die relevanten Daten automatisiert mittels geeigneter Schnittstellen zu Farm-Management- und ERP-Systemen zu erfassen. Das Potenzial einer solchen Analyse und Optimierung soll anhand der Wertschöpfungskette Topinambur gezeigt werden.

Im Folgenden wird die besondere Bedeutung von Topinambur als regionale Nutz- und Speisepflanze betont und die Wertschöpfungsketten werden skizziert. Anschließend erfolgt die Einordnung in den wissenschaftlichen Diskurs zur Berechnung von CO<sub>2</sub>-Äquivalenten (CO<sub>2</sub>-e). In Abschnitt 2 wird die Darstellung der verwendeten Annahmen und Berechnungsvorschriften zur Ermittlung des PCF beschrieben. Hierbei legen wir besonderes Augenmerk auf die Beschreibung relevanter Datenpunkte in diesem Kapitel. Unserer PCF-Berechnung liegt bereits eine vorhandene PCF-Rechnung zugrunde, jedoch haben wir sie noch präziser gestaltet, indem wir technische Schnittstellen (APIs) genutzt haben und Faktoren wie Wasserverbrauch, menschliche Arbeitszeiten und Energieverbrauch eingebunden haben. Die gewonnenen Ergebnisse werden im Anschluss präsentiert, inklusive einer anschließenden Diskussion, in der die Ergebnisse in einen größeren Kontext eingeordnet werden. Dies ermöglicht es, den Mehrwert unserer präziseren PCF-Berechnung zu verdeutlichen, insbesondere in Bezug auf die regionale Herkunft von Topinambur.



## 2 Material und Methoden

### 2.1 Wertschöpfungskette Topinambur

Die Analyse der Wertschöpfungskette Topinambur erfolgt für die in Abb. 1 dargestellten Prozessschritte anhand der erfassten Daten zur Primärproduktion, den Verarbeitungsstufen und den erforderlichen Transporten.

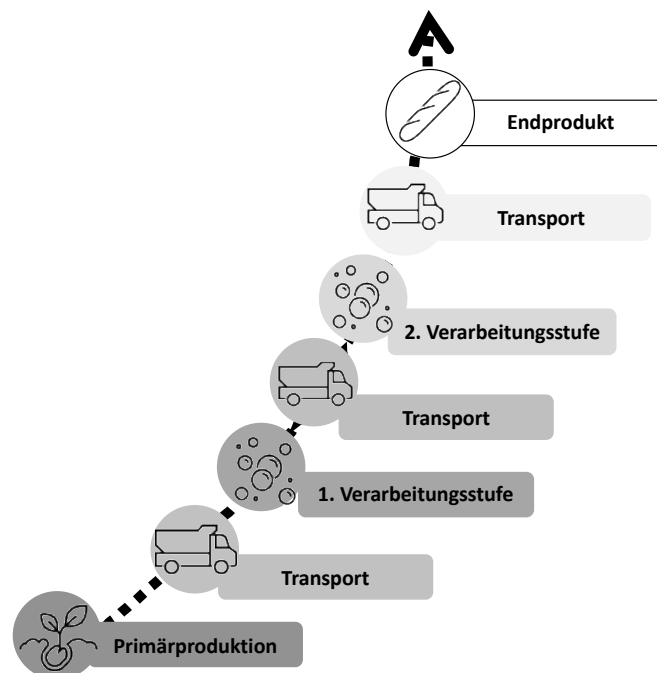


Abb. 1: Untersuchte Elemente der Wertschöpfungskette Topinambur (verändert nach [Sh23])

Topinambur (*Helianthus tuberosus* L.) ist eine in Nordamerika heimische Pflanze und vielseitig nutzbar. Im Vergleich zu traditionellen landwirtschaftlichen Nutzpflanzen weist Topinambur vorteilhafte Eigenschaften auf, darunter eine hohe Wachstumsrate, eine gute Toleranz gegenüber Frost, Trockenheit und ungünstigen Bodeneigenschaften, eine starke Resistenz gegen Schädlinge und Pflanzenkrankheiten sowie einen minimalen bis gar keinen Düngemittelbedarf auf [Ko85; St07]. Konventionell wird Topinambur als Lebensmittel oder als Futtermittel verwendet. Alternative Verwendungen insbesondere zur Herstellung von funktionellen Lebensmittel- und Futtermittelzusätzen wie Inulin, Oligofructose und Fruktose sind bereits etabliert [Ya15].

**Anbau und Ernte:** Topinambur wird in der Regel im Frühjahr angebaut. Bevorzugt werden sonnige Standorte und durchlässige Böden. Beispielhaft wurden in der vorliegenden

Studie konventionelle und konservierende Bodenbearbeitungsverfahren hinsichtlich ihres PCF gegenübergestellt. Die Ernte erfolgt im Herbst nach Absterben der Pflanze und erfolgt mit einem Kartoffelroder (zweireihig, gezogen).

**Reinigung und Vorbereitung:** Nach der Ernte werden die Topinamburknollen gründlich gereinigt, um Erde und Rückstände zu entfernen. Anschließend werden sie zur Erleichterung der Saftgewinnung geschält und durch Schneiden oder Zerkleinern in einer Mühle in kleine Stücke zerteilt.

**Pressung:** Die zerkleinerten Topinamburstücke werden in eine Saftpresse gegeben, um den Saft zu extrahieren. Dabei wird der Saft von den festen Bestandteilen getrennt. Der gewonnene Topinambursaft ist reich an natürlicher Süße und Inulin, einem Ballaststoff, der sich positiv auf die Darmgesundheit auswirken kann.

**Filtration und Klärung:** Der extrahierte Topinambursaft kann trüb sein, daher wird er oft filtriert und geklärt, um Verunreinigungen zu entfernen und eine klare Flüssigkeit zu erhalten.

**Pasteurisierung und Abfüllung:** Um die Haltbarkeit des Saftes zu verlängern und etwaige schädliche Mikroorganismen abzutöten, wird der Saft pasteurisiert, indem er auf eine bestimmte Temperatur erhitzt wird. Anschließend wird der Saft in Flaschen oder andere Behälter abgefüllt.

**Lagerung und Vertrieb:** Der Topinambursaft wird kühl und dunkel gelagert, um seine Qualität zu erhalten. [Ko85; Ya15]

## 2.2 Datenerhebung

In Tabelle 1 sind die Prozessschritte, die Datenbeschreibung, die Datenquellen sowie die Erfassung der Daten aufgeführt. Die Erfassung der Daten erfolgt in Verarbeitungsbetrieb 2 über APIs (Schnittstellen), weitere APIs zu der in den jeweiligen Prozessstufen verwendeten Software wie Farm-Management-Software und ERP-Systemen sind derzeit noch nicht vorhanden. Hier soll das Potenzial einer automatisierten Datenerfassung zur Berechnung des PCF aufgezeigt werden.

In dieser Studie wurden umfangreiche Daten von Topinambur-Verarbeitungsbetrieben gesammelt. Dabei kamen moderne Sensortechnologien (SIMATIC HMI Siemens, JUMAG DG 560) und IoT-Geräte zum Einsatz, um präzise Informationen über den Wasserverbrauch und den Energieverbrauch zu erfassen. Dies ermöglichte die Erhebung von Daten in Echtzeit und minimierte menschliche Fehlerquellen. Die vorliegenden Daten wurden durch die Nutzung technischer Schnittstellen (APIs) akquiriert. In den Betrieben erfolgt die Datenverarbeitung über das Odoo-ERP-System, welches als Open-Source-Managementsystem fungiert und sämtliche innerbetrieblichen Daten zentralisiert und sammelt. Diese zentrale Datenerfassung ermöglicht es uns, einen umfassenden Überblick über verschiedene betriebsinterne Prozesse und Aktivitäten zu erhalten.

| <b>Prozessschritt</b> | <b>Datenbeschreibung</b>  | <b>Datenquelle</b>   | <b>Datenerfassung</b>                        |
|-----------------------|---|--|--|
| Produktion            | Maschinenausstattung, Verfahrensschritte, Kraftstoffverbrauch, Arbeitszeit, Transpirationskoeffizient | Angaben der landwirtschaftlichen Betriebe, Farm-Management-Software, KTBL<br>Literatur | Interviews, APIs zu Farm-Management-Software |
| Verarbeitung          | Verfahrensschritte, Wasserverbrauch, Energieverbrauch, Arbeitszeit                                    | Angaben der Verarbeiter, ERP-System, Literatur   | APIs zu ERP-Systemen                         |
| Transport             | Kraftstoffverbrauch   | Angaben der Verarbeiter und Logistiker   | Logistik-Management-Software                 |

Tab. 1: Beschreibung, Herkunft und Erfassung der Daten der regionalen Wertschöpfungskette Topinambur

Unser Zugriff auf das Odoo ERP-System erfolgt über eigens eingerichtete technische Schnittstellen. Diese Schnittstellen ermöglichen die nahtlose Integration relevanter Daten aus dem PCF in unser SLF-Ökosystem. Dadurch können wir sicherstellen, dass alle für unsere betrieblichen Abläufe wichtigen Informationen in Echtzeit verfügbar sind. Diese Daten werden anschließend über benutzerfreundliche Dashboards bereitgestellt, um die Nutzung und Interpretation für unsere Mitarbeiter zu erleichtern.

Die erfassten Daten werden sorgfältig in unserer Datenbank gespeichert. Dies ermöglicht nicht nur die sichere Aufbewahrung, sondern auch eine umfangreiche Datenhistorie, die für zukünftige Analysen von unschätzbarem Wert ist. Um diese Daten weiterzuverarbeiten und wertvolle Einblicke zu gewinnen, setzen wir auf die Python-Programmiersprache. In unserem Analyseprozess nutzen wir verschiedene Python-Bibliotheken, darunter Pandas, um Daten effizient zu verwalten und zu manipulieren. Matplotlib wird verwendet, um aussagekräftige Grafiken und Visualisierungen zu erstellen, die es uns ermöglichen, Trends und Muster zu erkennen. Die NumPy-Bibliothek wird eingesetzt, um mathematische Operationen auf den Daten durchzuführen und komplexe Berechnungen auszuführen.

### 2.3 Methoden zur Ermittlung der Nachhaltigkeit in Lebensmittel-Wertschöpfungsketten

Das Life Cycle Assessment (LCA) [Di00a; Di00b] berücksichtigt eine Vielzahl von ökologischen Wirkungen, während der PCF lediglich einen Teil des LCA abbildet [Ho13]. Ziel der Berechnung des PCF ist die Ermittlung der produktbezogenen CO<sub>2</sub>-Emissionen

und damit verbundener, möglicher Reduktionspotenziale entlang der Wertschöpfungskette. Aufgrund der geringeren Komplexität im Vergleich zum LCA wird in der vorliegenden Studie der PCF verwendet [vgl. Ho13]. Darüber hinaus sollen die Informationen zum CO<sub>2</sub>-Wert eines Produkts an Lieferanten, Kunden oder Verbraucher kommuniziert werden, damit eine Handlungsentscheidung zukünftig an der Nachhaltigkeitsleistung des Produkts festgemacht werden kann und das Produkt mit den geringsten CO<sub>2</sub>-Emissionen ausgewählt wird. Im Kontext des SLF-Projekts soll die Vergleichbarkeit unterschiedlicher Angebote durch die Entwicklung eines Demonstrators als Teil des SLF-IKT Ökosystems ermöglicht werden.

## 2.4 Annahmen zur Berechnung des PCF

Die Annahmen zur Berechnung des PCF für die Prozessschritte in der Wertschöpfungskette Topinambur erfolgte mit folgenden Annahmen:

**Erzeugung:** Die exemplarische Berechnung wird sowohl für wendende und als auch konservierende Bodenbearbeitungsverfahren durchgeführt. Die Verfahrensschritte zweier landwirtschaftlicher Betriebe wurden erfasst und exemplarisch mit dem KTBL-Verfahrensrechner Pflanze [Kt22] zusammengestellt. Arbeitszeiten und Kraftstoffverbrauch wurden anhand einer standardisierten Verfahrenskette Topinambur-Anbau berechnet. Daraus wurde anhand der Norm ISO 14067 als internationaler Referenzstandard [LeUG21] der PCF für 100 kg Topinambur berechnet. Der Transpirationskoeffizient von *Helianthus tuberosus* L. liegt bei 400 l/kg Knollenertrag (TM) im Bereich zwischen Kartoffeln und Zuckerrüben. Zur Realisierung eines regionsüblichen Gesamtbiomasseertrages von 25 t FM/ha/a Knollenertrag wird der Wasserbedarf von Topinambur in der Vegetationszeit mit ca. 222 l/m<sup>2</sup> angenommen. Daraus ergibt sich ein Wasserverbrauch von ca. 89,1 l/kg Frischmasse Topinamburknollen [Ja13; Lt23; Ro23].

- Angenommener Ertrag (t Knollen je ha): 25 t/ha, Trockenmassegehalt (TM) 21,6%, angenommene Anbaufläche: 20 ha, Hof-Feld-Transportentfernung 3 km für Berechnung des Diesel- und Arbeitszeitbedarfs der Verfahrensschritte mit dem KTBL-Verfahrensrechner Pflanzenbau [Kt22].
- Verfahrensvarianten: konventionelle und konservierende Bodenbearbeitung.

**Verarbeitung je 100 kg Topinamburknolle (Frischmasse):** Der Wasserverbrauch für den gesamten Verarbeitungsprozess wurde durch direkte Messungen erfasst. Die eingesetzten Wassermengen in den einzelnen Verarbeitungsschritten wie Reinigung, Schälen und Kochen wurden erfasst und summiert, um den gesamten Wasserverbrauch zu quantifizieren. Die Arbeitszeiten, die in den verschiedenen Verarbeitungsschritten aufgewendet wurden, wurden durch eine elektronische Zeiterfassungsmethode (Odo Zeiterfassungsoftware) ermittelt. Der Stromverbrauch wurde durch den Einsatz von Messgeräten (SIMATIC HMI Siemens, JUMAG DG 560) an den relevanten Maschinen und Geräten ermittelt. Die Daten wurden mithilfe von Schnittstellen erhoben, wie im Abschnitt zur Datenerhebung ausführlich erläutert wird.

- Wasserverbrauch: 500 Liter, menschliche Arbeitszeit: 8 Stunden, Stromverbrauch: 150 kWh.

**Transport je 100 kg Topinamburknolle (Frischmasse):** Die Transportentfernungen wurden mit Hilfe eines Kartendienstes ermittelt. Die Transportentfernung beträgt über die gesamte Wertschöpfungskette insgesamt 215 km.

Die beispielhafte PCF-Berechnung erfolgte anhand der folgenden Parameter (Tab. 2):

| Prozess      | Parameter                             | Berechnung                            | Methode      |
|--------------|---------------------------------------|---------------------------------------|--------------|
| Produktion   | Kraftstoffverbrauch je Arbeitsvorgang | 2,64 CO <sub>2</sub> -e je l Diesel   | [Ho13, Kt22] |
|              | Arbeitszeitbedarf je Arbeitsvorgang   | 0,05 CO <sub>2</sub> -e je h          |              |
|              | Wasserbedarf je kg Topinambur         | 0,2 CO <sub>2</sub> -e je l Wasser/kg |              |
| Verarbeitung | Wasserverbrauch                       | 0,2 CO <sub>2</sub> -e je l Wasser/kg | [Ho13]       |
|              | Menschliche Arbeitszeit               | 0,05 CO <sub>2</sub> -e je h          |              |
|              | Stromverbrauch                        | 0,47 CO <sub>2</sub> -e je kWh        |              |
| Transport    | Transportkilometer                    | 0,49 CO <sub>2</sub> -e je km/t       | [Ho13]       |

Tab. 2: Berechnung der PCF Wertschöpfungskette Topinambur

Der arbeitsbezogene PCF-Anteil ergibt sich aus dem Zeitaufwand in den jeweiligen Prozessen. Individuelle Faktoren wie u.a. die Ernährung haben Einfluss [Sc22] und lassen sich regional abschätzen [Nu19]. Für die Analyse wurden 2150 kg ernährungsbedingte CO<sub>2</sub>-e je Person und Jahr angenommen.

### 3 Ergebnisse und Diskussion

Die Analyse des Product Carbon Footprints (PCF) für 100 kg Topinambur im gesamten Herstellungsverfahren ergibt einen Gesamt-PCF von 377,8 kg CO<sub>2</sub>e für konventionelle und geringfügig geringere 376,7 kg CO<sub>2</sub>e für konservierende Bodenbearbeitungsverfahren. Diese Zahl repräsentiert die gesamten Treibhausgasemissionen, die während des Erzeugungs-, Verarbeitungs- und Transportprozesses anfallen. Zu diesen Emissionen tragen verschiedene Faktoren bei, darunter der Verbrauch von Wasser, Energie (Diesel und Strom) und menschlicher Arbeitszeit.

Die Ergebnisse (Tab. 3) zeigen, dass im Erzeugungsprozess der Wasserverbrauch mit 178,1 kg CO<sub>2</sub>e den größten Anteil am PCF hat. Die Energie trägt hier mit 6,1 kg CO<sub>2</sub>-e (konservierende Bodenbearbeitungsverfahren 5,0 kg CO<sub>2</sub>-e) und die menschliche Arbeit mit 0,01 kg CO<sub>2</sub>-e bei. Bei der Verarbeitung dominiert der Energieverbrauch mit 70,7 kg CO<sub>2</sub>-e, gefolgt vom Wasserverbrauch mit 10 kg CO<sub>2</sub>-e und der menschlichen Arbeit mit

7,5 kg CO<sub>2</sub>-e. Beim Transport beträgt der PCF 105,4 kg CO<sub>2</sub>-e, wobei die Beiträge von Wasser und Energie hier nicht spezifiziert werden.

| <b>Prozessschritt</b> | <b>Gesamt -PCF</b> | <b>Wasser</b> | <b>Energie (Diesel und Strom)</b> | <b>Menschliche Arbeit</b> |
|-----------------------|--------------------|---------------|-----------------------------------|---------------------------|
| Erzeugung             | 184,3 (183,2*)     | 178,1         | 6,1 (5,0*)                        | 0,01                      |
| Verarbeitung          | 88,2               | 10,0          | 70,7                              | 7,5                       |
| Transport             | 105,4              | k.A.          | k.A.                              | k.A.                      |
| Gesamt                | 377,8 (376,7*)     | 188,1         | 76,8 (75,7*)                      | 7,5                       |

Tab. 3: PCF (kg CO<sub>2</sub>-e) der Erzeugung, des Transports und der Verarbeitung von 100 kg Topinambur; \* konservierende Bodenbearbeitungsverfahren

Diese Ergebnisse legen nahe, dass insbesondere der Wasserverbrauch bei der Erzeugung und der Energieverbrauch bei der Verarbeitung als Schlüsselbereiche für potenzielle Reduzierungen der CO<sub>2</sub>-Emissionen in der Wertschöpfungskette von Topinambur betrachtet werden sollten. Die Daten dienen als Grundlage für weitere Analysen und betonen die Wichtigkeit einer genauen Erfassung aller Ressourcenverbräuche im gesamten Herstellungsprozess. Sie unterstreichen auch die Bedeutung von realistischen Emissionsfaktoren für weiterführende Studien. In einer aktuellen Studie beziffern [La23] das verbleibende CO<sub>2</sub>-Budget für die kommenden sechs Jahre auf 247 Milliarden Tonnen CO<sub>2</sub>, um die globale Erwärmung mit einer Wahrscheinlichkeit von 50 % bei 1,5° C zu halten. Dies betont die Relevanz zur Reduktion von CO<sub>2</sub>-Emissionen.

Die Analyse zeigt, dass der Wasserverbrauch bei der Erzeugung einen erheblichen Anteil am Gesamt-PCF hat. Dies unterstreicht die Notwendigkeit, effiziente Wassermanagementstrategien zu entwickeln, um den Wasserverbrauch im Produktionsprozess zu minimieren. Technologische Innovationen zur Wasseraufbereitung und -rückgewinnung könnten dazu beitragen, den Wasserverbrauch und die damit verbundenen Emissionen zu reduzieren [Xu20].

Aus den methodischen Überlegungen ergibt sich, dass der PCF-Anteil für die menschliche Arbeit einbezogen werden muss, wenn er > 1% ist. Im Ergebnis der Analyse der WSK traf dies für die Stufe Verarbeitung (ca. 1,98 %) zu.

Die vorliegende Analyse des Product Carbon Footprints (PCF) für 100 kg Topinambur über den gesamten Herstellungsprozess bietet interessante Erkenntnisse in Bezug auf die Umweltauswirkungen des Produkts. Die Integration von menschlichen Arbeitszeiten in eine Lebenszyklusanalyse (Life-cycle assessment, LCA) ist ein bemerkenswerter Schritt, der in dieser Studie implementiert wurde [Sh23; Xu20]. Menschliche Arbeitskraft spielt eine zentrale Rolle in der landwirtschaftlichen Produktion und kann wesentliche Auswirkungen auf die Umweltbilanz haben. Die präzise Erfassung von Arbeitszeiten und deren Einbindung in das Modell haben zu realistischeren Ergebnissen geführt. Die Berücksichtigung des menschlichen Faktors in der Nachhaltigkeitsanalyse ist von großer Bedeutung,

da sie zeigt, wie Arbeitszeiten nicht nur die Produktionsprozesse, sondern auch die Nachhaltigkeitsbestrebungen beeinflussen können. Dies trägt dazu bei, die soziale Dimension der Nachhaltigkeit in die Analyse zu integrieren. Der Wasserverbrauch stellt einen kritischen Faktor in der Landwirtschaft und Lebensmittelproduktion dar [Ca23]. In dieser Studie wurde der Wasserverbrauch bei der Topinambur-Produktion auf regionaler Ebene untersucht. Dies ermöglichte die Identifizierung von Potenzialen zur Wassereffizienz und die Entwicklung von Maßnahmen zur Reduzierung des Wasserverbrauchs. Insbesondere im Erzeugungsprozess von Topinambur hat der Wasserverbrauch einen erheblichen Anteil am Gesamt-PCF, was die Notwendigkeit von effizienten Wassermanagementstrategien unterstreicht. Technologien zur Wasseraufbereitung und -rückgewinnung könnten hier einen wichtigen Beitrag leisten [ON23].

Der Stromverbrauch in den Verarbeitungsanlagen ist ein weiterer entscheidender Aspekt bei der Bestimmung des PCF von Topinambur. Der Einsatz modernster Technologien zur Energieerfassung und -analyse war essenziell, um präzise Daten zu sammeln. Dadurch konnten Energieeffizienzmaßnahmen identifiziert und die CO<sub>2</sub>-Emissionen reduziert werden. Insbesondere bei der Verarbeitung von Topinambur ist der Energieverbrauch der dominierende Faktor im PCF, was die Bedeutung von Energieeffizienz und der Nutzung nachhaltiger Energiequellen in diesem Prozessschritt hervorhebt [Wa23].

Die Datenerhebung spielt eine zentrale Rolle bei der Bewertung der Nachhaltigkeit und bei der Entwicklung von Strategien zur Reduzierung von Treibhausgasemissionen. Ohne genaue Daten könnten wichtige Aspekte übersehen werden, was zu unvollständigen oder irreführenden Schlussfolgerungen führen könnte. In dieser Studie ermöglichte die gründliche Erfassung und Analyse von Daten die Identifizierung des hohen Wasserverbrauchs im Erzeugungsprozess und des hohen Energieverbrauchs in der Verarbeitungsphase als Schlüsselbereiche für potenzielle Verbesserungen. Die Wichtigkeit der Datenerhebung geht über die reine Quantifizierung von Emissionen hinaus. Sie trägt auch dazu bei, die Transparenz des Produktionsprozesses zu erhöhen und informierte Entscheidungen über Nachhaltigkeitsinitiativen zu ermöglichen. Durch die Erfassung und Analyse von Daten können Unternehmen und Entscheidungsträger evidenzbasierte Maßnahmen ergreifen, um den PCF zu reduzieren und die Umweltauswirkungen zu minimieren [El23].

Zusammenfassend zeigt diese Studie, dass die Berücksichtigung aller relevanten Faktoren – von menschlicher Arbeit über Wasserverbrauch bis hin zum Energieeinsatz – für eine umfassende Nachhaltigkeitsanalyse unerlässlich ist. Sie bietet wertvolle Einblicke in die spezifischen Bereiche, in denen Umweltauswirkungen reduziert werden können, und betont die Wichtigkeit einer ganzheitlichen Betrachtung des Lebenszyklus von landwirtschaftlichen Produkten.

## 4 Schlussfolgerungen

Die durchgeführte Untersuchung des PCF für Topinambur über den gesamten Herstellungsprozess bietet aufschlussreiche Erkenntnisse über die Umweltauswirkungen des Produkts. Es wurde deutlich, dass der Wasserverbrauch, insbesondere in der Erzeugungsphase, einen erheblichen Einfluss auf die gesamten Treibhausgasemissionen ausübt. Ebenso spielt der Energieverbrauch, vor allem in der Verarbeitungsphase, eine wichtige Rolle. Der Beitrag der menschlichen Arbeitszeit zum PCF, obwohl geringer, unterstreicht die Relevanz einer ganzheitlichen Betrachtung der Produktionsprozesse.

Diese Ergebnisse verdeutlichen die Dringlichkeit, effektive Strategien zur Senkung der Emissionen in der Topinambur-Produktion zu entwickeln. Dabei ist es unerlässlich, einen besonderen Fokus auf die präzise Datenerhebung sowie auf realistische Annahmen bezüglich der CO<sub>2</sub>-Emissionen von Wasser, Energie und anderen Ressourcen für zukünftige Forschungsarbeiten zu legen. Die Studie liefert praktische Ansatzpunkte für die Gestaltung nachhaltiger Ernährungssysteme und betont die Bedeutung einer umfassenden und genauen Erfassung aller relevanten Daten.

Obwohl in dieser Studie die Anwendung von Künstlicher Intelligenz (KI) nicht explizit thematisiert wurde, unterstreicht die Arbeit die Wichtigkeit datengetriebener Methoden, insbesondere zur Schließung von Datenlücken und zur Verbesserung der Präzision in der Umweltbewertung. Die Integration fortschrittlicher Analysetechniken und KI-basierter Modelle könnte zukünftig eine Schlüsselrolle spielen, um detaillierte Einblicke zu gewinnen und effektive Maßnahmen zur Reduzierung von Umweltauswirkungen zu identifizieren.

Die Studie verdeutlicht, dass ein robustes Datenmanagement unerlässlich ist, um fundierte Entscheidungen über Nachhaltigkeitsinitiativen zu treffen. Die Qualität und Verlässlichkeit der Daten bilden das Fundament für die Entwicklung effektiver Strategien zur Reduzierung des ökologischen Fußabdrucks. Die Implementierung von fortgeschrittenen Datenmanagement-Systemen und der Einsatz von KI-Methoden könnten in zukünftigen Studien eine zentrale Rolle spielen, um Datenlücken zu schließen und die Genauigkeit der Umweltbewertungen zu verbessern. Insgesamt bietet die Studie praxisnahe Ansatzpunkte für die Entwicklung nachhaltiger Ernährungssysteme und betont die Bedeutung eines ganzheitlichen und datengetriebenen Ansatzes. Ein effizientes Datenmanagement ist nicht nur für die Erhebung und Analyse von Umweltdaten entscheidend, sondern auch für die Überwachung und Bewertung von Fortschritten in Richtung Nachhaltigkeitsziele.

Die ausschließliche Verwendung des PCF als Indikator für ökologische Nachhaltigkeit, insbesondere für die Entwicklung von Nachhaltigkeitsstrategien, kann irreführend sein, da Umweltwirkungen von Produkten nicht nur Auswirkungen auf den Klimawandel haben können, sondern Themen wie beispielweise Eutrophierung, Schadstoffeinträge und Ressourcenverbrauch haben. Daher könnte die Verwendung des PCF lediglich zu einer Problemverschiebung führen, wenn die THG-Emissionen reduziert werden, während andere



Umweltauswirkungen zunehmen. Daher sollten weitere Umweltwirkungen in Unternehmensentscheidungen integriert werden, um nachhaltiger zu produzieren [Sc21].

Heuristische und KI-Methoden könnten bestehende Datenlücken über die Wertschöpfungskette hinweg schließen. Die vorliegende Analyse liefert einen Einblick wie der PCF erfasst und modelliert werden kann. Es ergibt sich weiterer Forschungsbedarf beispielsweise zur möglichen CO<sub>2</sub>-Kompensation durch dezentrale erneuerbare Energieversorgung.

**Förderhinweis:** Die Förderung des Vorhabens erfolgt aus Mitteln des Bundesministeriums für Ernährung und Landwirtschaft (BMEL) aufgrund eines Beschlusses des deutschen Bundestages. Die Projektträgerschaft erfolgt über die Bundesanstalt für Landwirtschaft und Ernährung (BLE) im Rahmen des Programms zur Innovationsförderung.

#### Literaturverzeichnis

- [Ca23] Qilin, C. et al.: Evolving water, energy and carbon footprints in China's food supply chain. In: *Journal of Cleaner Production* Bd. 423 (2023), S. 138716, 2023
- [Di00a] DIN Deutsches Institut für Normung e.V.: Umweltmanagement - Ökobilanz - Anforderungen und Anleitungen (ISO 14044:2006 + Amd 1:2017 + Amd 2:2020); Deutsche Fassung EN ISO 14044:2006 + A1:2018 + A2, 2020.
- [Di00b] DIN Deutsches Institut für Normung e.V.: Umweltmanagement - Ökobilanz - Grundsätze und Rahmenbedingungen (ISO 14040:2006 + Amd 1:2020); Deutsche Fassung EN ISO 14040:2006 + A1, 2020.
- [El23] Elgarahy, A. et al.: Sustainable management of food waste; pre-treatment strategies, techno-economic assessment, bibliometric analysis, and potential utilizations: A systematic review. In: *Environmental Research* Bd. 225 (2023), S. 115558, 2023
- [Ho13] Hottenroth, H. et al.: Carbon Footprint für Produkte. Handbuch für die betriebliche Praxis kleiner und mittlerer Unternehmen (Abschlussbericht). Pforzheim, Germany : INEC (Institute for Industrial Ecology Pforzheim), 2013
- [Ja13] Janket, A. et al.: Genetic diversity of water use efficiency in Jerusalem artichoke („Helianthus tuberosus“ L.) germplasm. In: *Australian Journal of Crop Science* Bd. 7, Southern Cross Publishers Lismore, NSW (2013), Nr. 11, S. 1670–1681, 2013
- [Ka22] Karwacka, M. et al.: Freeze-dried snacks obtained from frozen vegetable by-products and apple pomace – Selected properties, energy consumption and carbon footprint. In: *Innovative Food Science & Emerging Technologies* Bd. 77 (2022), S. 102949, 2022
- [Kt22] KTBL: Verfahrensrechner Pflanze des Kuratoriums für Technik und Bauwesen in der Landwirtschaft e. V. (KTBL)., 2022
- [Ko85] Kosaric, N. et al.: Industrial processing and products from the Jerusalem artichoke. In: *Agricultural Feedstock and Waste Treatment and Engineering, Advances in Biochemical Engineering/Biotechnology*. Berlin, Heidelberg : Springer, 1985 — ISBN 978-3-540-39441-9, S. 1–24, 1985

- [La23] Lamboll, R.D. et al.: Assessing the size and uncertainty of remaining carbon budgets. In: *Nature Climate Change*, 2023
- [Lt23] LTZ: Topinambur (*Helianthus tuberosus* L.) Hinweise zum Pflanzenbau. Karlsruhe, Germany : Landwirtschaftliches Technologiezentrum Augustenberg (LTZ), 2023
- [Nu19] nu3 Nutrition Experts: CO<sub>2</sub>-Fußabdruck-Index für Ernährung 2018| nu3. URL <https://www.nu3.de/blogs/nutrition/co2-fussabdruck-index-fuer-ernaehrung-2018>. - abgerufen am 2022-11-25. — nu3.de, 2022
- [ON23] Omar, M.E.D.; Nangia, V.: On-farm water energy food carbon-footprint nexus index for quantitative assessment of integrated resources management for wheat farming in Egypt. In: *Water-Energy Nexus* Bd. 6 (2023), S. 122–130, 2023
- [PAP11] Pandey, D.; Agrawal, M.; Pandey, J.S.: Carbon footprint: current methods of estimation. In: *Environmental Monitoring and Assessment* Bd. 178 (2011), Nr. 1–4, S. 135–160, 2011
- [RG21] Rondoni, A.; Grasso, S.: Consumers behaviour towards carbon footprint labels on food: A review of the literature and discussion of industry implications. In: *Journal of Cleaner Production* Bd. 301 (2021), S. 127031, 2021
- [Ro23] Rolbiecki, S. et al.: Influence of Forecast Climate Changes on Water Needs of Jerusalem Artichoke Grown in the Kuyavia Region in Poland. In: *Energies* Bd. 16 (2023), Nr. 1, S. 533, 2023
- [Sc21] Scrucca, F. et al.: Carbon Footprint: Concept, Methodology and Calculation. In: Muthu, S.S. (Hrsg.): *Carbon Footprint Case Studies, Environmental Footprints and Eco-design of Products and Processes*. Singapore : Springer Singapore, S. 1–31, 2021
- [Sh23] Shabir, I. et al.: Carbon footprints evaluation for sustainable food processing system development: A comprehensive review. In: *Future Foods* Bd. 7 (2023), S. 100215, 2023
- [Sc22] Schunkert, S.: *Der UBA-CO<sub>2</sub>-Rechner für Privatpersonen*: (2022), S. 44, 2022
- [St07] Stolzenburg, K.: *Vermarktungsbereiche, Qualitätsanforderungen und pflanzenbauliche Möglichkeiten der Qualitätsbeeinflussung von Topinambur (*Helianthus tuberosus* L.)*. Landwirtschaftliches Technologiezentrum Augustenberg, Vortrag zur Internationalen Grünen Woche, Berlin, 2007
- [Wa23] Wang, C. et al.: Potential of technological innovation to reduce the carbon footprint of urban facility agriculture: A food–energy–water–waste nexus perspective. In: *Journal of Environmental Management* Bd. 339 (2023), S. 117806, 2023
- [Xu20] Xu, Z. et al.: Comparative evaluation of carbon footprints between rice and potato food considering the characteristic of Chinese diet. In: *Journal of Cleaner Production* Bd. 257 (2020), S. 120463, 2020
- [Ya15] Yang, L. et al.: The prospects of Jerusalem artichoke in functional food ingredients and bioenergy production. In: *Biotechnology Reports* Bd. 5 (2015), S. 77–88, 2015

## Adaptive real-time crop row detection through enhancing a traditional computer vision approach

Mortesa Hussaini<sup>1</sup> , Max Voigt<sup>2</sup>  and Anthony Stein<sup>3</sup> 


**Abstract:** Crop row detection is important to enable precise management of fields and optimize the use of resources such as fertilizers and water. Autonomous machines need an effective but also robust real-time row detection system to be able to adapt to different field conditions. In this paper, we present an enhanced crop row detection approach which integrates traditional computer vision methods with further techniques such as k-means clustering or probabilistic Hough transformation. The resulting hybrid method allows for efficient and robust detection of straight and curved crop rows in image and video material. We validate our approach empirically on the crop row benchmark dataset (CRBD) and compare it with other state-of-the-art approaches. Furthermore, we demonstrate that our approach is designed to be adaptive and thus becomes straightforwardly transferable to other experimental setups. To corroborate that, we report on results when our approach is validated on representative corner cases which have been collected in the scope of a research project. Observations and current limitations of our approach are discussed along with possible solutions to overcome them in future work.

**Keywords:** crop row detection, precision agriculture, machine learning, artificial intelligence


### 1 Introduction

Due to a growing world population and progressing climate change, precision and efficiency become indispensable and essential for sustainable agriculture. Row crops such as maize or rice constitute one of the most important basic foods to ensure sufficient food supply [Gal17b; PC12]. Due to large spacing, crop rows favour soil erosion by wind and water, as well as the development of weeds due to good light penetration. While adequate nutrients, light, and water are available between rows, plants within the row compete for them. All these factors necessitate treatments such as hoeing, watering, and fertilizing, which should be as highly accurate, environmentally friendly and resource-efficient as possible while still being executed autonomously. Real-time detection and visualization of plant rows within a field plot is a fundamental prerequisite for this. Our research aims to develop a robust and efficient algorithm, which can be adapted to different

---

<sup>1</sup> University of Hohenheim, Dept. Artificial Intelligence in Agricultural Engineering & Computational Science Hub (CSH), mortesa.hussaini@uni-hohenheim.de,  <https://orcid.org/0000-0002-3621-7776>

<sup>2</sup> University of Hohenheim, Dept. Artificial Intelligence in Agricultural Engineering, max.voigt@uni-hohenheim.de,  <https://orcid.org/0009-0004-0645-9303>

<sup>3</sup> University of Hohenheim, Dept. Artificial Intelligence in Agricultural Engineering & Computational Science Hub (CSH), anthony.stein@uni-hohenheim.de  <https://orcid.org/0000-0002-1808-9758>

circumstances and conditions of different fields and settings, e.g., camera position, image resolution or the space between the crop rows.

Therefore, we start with briefly reviewing selected methods from both, traditional computer vision (“CV”) as well as machine learning-based methods in Section 2, where we cast light on the potential, but also observed challenges that have been discovered with different approaches. Direct transfer and applicability of published methods to deviating settings constitute the most challenging aspects we encountered. Hence, developing an adaptive and straightforwardly adaptable approach becomes an important task. Nevertheless, for considering a possible real-time application of the method, the trade-off between accuracy and efficiency is subject of investigation. Accordingly, in Section 3 our combined approach integrating traditional CV with further advanced techniques is introduced and illustrated step by step. Section 4 presents our validation approach and presents the results obtained applying our method to an often-used benchmark dataset, the CRBD, allowing a comparison with other state-of-the-art approaches from literature. We further assess the performance in terms of robustness of our approach on another dataset recorded in the scope of the NaLamKI project [Bo23]. This dataset entails less frequent but relevant challenging cases, which we refer to as corner cases (cf. Sec. 4.3), on which previous methods have shown decreasing performance. Results are presented and discussed thoroughly while highlighting advances and disadvantages when compared to others. Finally, we summarise our findings and provide an outlook on future work.

## 2 Related Work

Ranging from conventional colour-based threshold algorithms [RS88], over more advanced CV models [Gu13; Ro12], to deep learning approaches [BHC19; Do21], there already exist many approaches which address the challenging task of crop row detection (“CRD”). Even though deep neural networks have demonstrated their potential to perform best on this task [Sh23], they often are much more costly in terms of time, labor and data preprocessing. For instance, a large and balanced dataset as well as thorough model choice and configuration are needed to achieve a well-adopted state. In contrast, basic CV models not only work without a labelled dataset to be trained on, but also require much less computation capacity. However, the faster computation time usually must be traded off against some accuracy when e.g., compared to a well-trained deep neural network. Initial approaches based on traditional CV used a straightforward green-brown distinction to identify crop rows in standard RGB images [RS88]. However, such methods are susceptible and only work properly under ideal conditions, e.g., constant lighting conditions and low degree of noise or other distortions such as weed occurrences between the rows. A combining template matching with dynamic programming method (TMGEM) was proposed in [VCH16] together with the CRBD [VCH15], a dataset proposed for benchmarking of CRD approaches (cf. Sec. 4.1) to be evaluated on. Nevertheless, the runtime of this approach prevents it from real-time application. Approaches such as implementing a Region of Interest (RoI) or morphological operations [PHH07] have been

added to the model pipeline. One example of such a pipeline is introduced by [Ga17a]. Their algorithm, which we still deem a traditional CV approach in this paper, is divided into three phases: the first phase is focusing on the segmentation task, with the goal to extract only the relevant information from the RGB input image, in a suitable format. The next phase utilises Hough transformation [Ho62] (“HT”), a method for recognising lines, to detect a bundle of lines in this context. Having extracted a root point, by calculating the corresponding slope of the curve, the actual crop row can be detected in the third and last phase. A similar approach is introduced in [Zh18]. Instead of HT they use clustering techniques to detect the lines. Concurrently deep learning approaches, training neural network architectures to segment crop row images, have emerged. [Do21] utilises CRBD to train an image segmenting U-Net model. However, since the dataset is too small for comprehensive training, they make use of data augmentation to compensate for that. This again points to a disadvantage of such deep learning-based approaches that, in consequence of their depth, they usually require a large amount of data to produce reliable results.

### 3 Method

As mentioned before, there are various models and algorithms for CRD already existing and even though their basic structure and pattern appears similar at first glance, crop rows exhibit high degrees of heterogeneity.

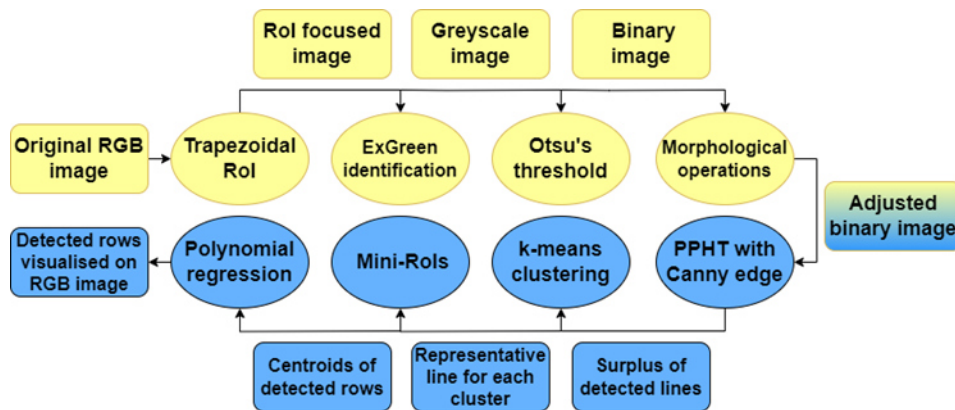


Fig. 1: Pipeline of our approach, which we distinguish in two phases: segmentation phase (yellow) and crop row detection phase (blue)

Available approaches we found were either not well reproducible or only performing well on a certain dataset or under idealised conditions. This lack of robustness and adaptability motivated us in developing our own enhanced model. In this section, we propose a new CV pipeline for real-time CRD which enhances previous approaches in several aspects as described below. Our enhanced approach works robustly not only on different available

datasets, but also on identified corner cases, representing specific and challenging conditions in crop row fields. Additionally, our detection pipeline is highly efficient and thus performing fast enough for being directly deployed on land machines for real-time application. The work from [Ga17a] served as a reference point for our enhanced approach. To make such a traditional CV approach more robust and efficient, we decided to exchange certain steps in the processing chain by improved ones, but also extended it by introducing new steps into the image processing pipeline (cf. Fig. 1). Our targeted modifications are described in the following.

### 3.1 Segmentation phase




Fig. 2: Illustration of the individual segmentation phases

The segmentation phase begins by defining a Region of Interest (RoI). Forming an RoI is a relatively basic operation which saves computation time in the subsequent operations by removing parts of the image irrelevant to our task. Consequently, it is a common technique in several CRD approaches. Nevertheless, the choice of form and position of the RoI varies between models and highly depends on the resolution of the image, plant species, growth stage of the plant, vehicle dimensions and associated distance to ground, as well as on the orientation of the camera. These parameters render existing models difficult to be reconstructed if implemented in a highly specialised way to a specific setting and are therefore difficult to be adapted to other setups. To alleviate these shortcomings, we have investigated the effects of different geometries and positions of RoIs and discovered that choosing a trapezoidal RoI is advantageous in most cases (cf. Fig. 2a). Since usually all rows converge to a vanishing point, the image area becomes less relevant towards the background (upper area of the image), and so it is not necessary for the row detection task to keep the same width there as in the very front (lower area of the image). This action saves computational resources in succeeding operations and therefore contributes to the real-time applicability of our approach. Our RoI adapts automatically to the width and height of the image. With this automated design, our method becomes not only more efficient, but also adaptable to other settings involving challenging corner cases (cf. Sec. 4.3). By assuming that there is an average of 70 cm between the rows and the orientation on the maximum permissible width of 3 m for agricultural machines in Germany [He03], this results in a reasonable setting. This arrangement will further assist the HT (cf. Sec. 3.2). After the RoI determination, the common and well-known Excess Green Vegetation Index (“ExGreen”) [Wo95] distinguishes plants from soil (cf. Fig. 2b). To refine our

segmentation, we apply Otsu’s method [Ot79], a threshold value method named after its developer, followed by Morphological Operations [PHH07]. The advantage over other threshold methods is that the chosen Otsu’s method determines the threshold automatically, by minimising the variance within the image foreground and background while maximising it between them. Gray values below the threshold turn into zero while the others into 1, which results in a binary image. The application of morphological operations supports the reduction of remaining noise, e.g., (small) weeds or mossy objects (cf. Fig. 2c). Therefore, a specific matrix (structure element) moves as a filter over the binary image and pixel values (zero or 1) are examined and modified according to their neighbourhood within the matrix. Depending on the binary value of the neighbours, the pixels are changed or kept accordingly. Here, we operated with different structure elements and repetitions dependent on the ExGreen of the image.

### 3.2 Row detection phase

With the binary biomass-background segmentation of the image, HT methods [Ho62] for recognizing patterns, in our case lines, become usable. To improve the effectiveness of this, we apply Canny Edge method [Ca86]. In general, HT methods need a very accurate calibration and the often-used classic variant considers every point in the parameter space. This enables increased computational resources and time. Furthermore, in case of bad calibration, there is a risk that none or not enough lines will be detected. Accordingly, we decided to follow another approach here, and utilize the Progressive Probabilistic HT (“PPHT”) [MGK00]. This variant selects only a random sample of points from the entire point space, which is sufficient to form a representative set (cf. Fig. 3a). The advantage of this approach we want to exploit is that, compared to the classic HT, it can either compute the same number of lines more efficiently or provide us with more lines under the same computational effort or a combination of both (more detailed analysis in [GMK99]). At the same time, the less sensitive calibration of the HT parameters increases the adaptability for other plants, growth stages and technical setups. Adjusting the PPHT happens in a constant trade-off between accuracy and speed, since it should be reliable and run in real-time. As we experienced, an ideal setting of parameters for recognizing the exact number of lines (i.e., crop rows) needed is difficult. Thus, in our approach we preferred to have a surplus of information from the output of the PPHT, rather than too few recognized lines. To reduce the excess of lines, we add a machine learning-based clustering, based on the k-means algorithm [Ja99] (cf. Fig. 3b). K-means has proven to be highly robust against outliers and works reliably even with a heterogeneous distribution of lines. We then compute so called mini-RoIs and their centre of gravity, point where concentration of white pixels is the strongest, along the lines by calculating the image moments within them [Hu62] (cf. Fig. 3c). In contrast to the approach in [Gal7a], ours not just calculates a fixed number of mini-RoIs along the lines detected by HT, but additionally updates their slope beginning from the second one and continuing this for each one. The position of each mini-RoI is adjusted each step according to the slope and the width is updated by a decreasing term. That is because our experience revealed that the series are not always

purely straight and thus they would not match the real slope of the HT lines in this case. Furthermore, outliers, e.g., interruptions in the crop rows, are considered with this approach and this makes our method more robust to challenging circumstances in fields. To make the algorithm adaptive to different image sizes, the number of mini-RoIs is not fixed but adjusts automatically according to the size of the image.




Fig. 3: Illustration of the individual row detection steps

As a result of this step, we obtain one set of centre points per row. Finally, these centre points are visualised by either simple piece-wise connection or by a polynomial function of first or second (better for curved rows) order using regression analysis.

## 4 Evaluation

CRD models are often evaluated either qualitatively on a selection of representative images or based on specifically developed metrics in literature. Hence, literature research did not reveal a standardised measuring unit to assess the performance of CRD methods. Nevertheless, we utilise the CRDA (crop row detection accuracy; cf. Sec. 4.1) for our evaluation here. Moreover, proposed models have often not been made available and are thus hardly comprehensible or not fully reproducible, what makes a detailed comparison with other models difficult. We evaluate our model (cf. Sec. 4.2) both qualitatively on detected lines in representative cases and quantitatively by means of utilising the available CRBD [VCH15] (cf. Sec. 4.1). Since this dataset includes some heterogeneity regarding the ground-truth obtained and in our opinion does not cover much challenging exceptional cases, we also tested our method on more specific corner cases to demonstrate the robustness of our model (cf. Sec. 4.3).

### 4.1 Crop Row Benchmark Dataset (CRBD)

The CRBD contains 281 crop row images with a size of 320 x 240 pixels of various types of plants and different weather conditions, weed pressure and camera angles. The images are subdivided in  $v$  image rows, and the ground truth is determined by two numeric values for each image row  $v$ :  $d_v^*$ , which denotes the fixed distance between the vertically oriented crop row lines. And  $c_v^*$ , the distance between the image centre and its closest crop row line. Each image is assigned to a .crp text file containing these values. With these, the ground



truth values  $u_{v,i}^*$  for each crop row and each image row can be determined and then compared to the detected values  $u_{v,i}$ . Following [VCH15], the accuracy of the detected crop rows for each image is calculated by

$$\text{CRDA} = \frac{1}{m(h-v_0)} \sum_{v=v_0}^{h-1} \sum_{i=1}^m s(u_{v,i}, u_{v,i}^*, d_v^*), \quad \text{with}$$

$$s(u^*, u, d^*) = \max\left(1 - \left(\frac{u^* - u}{\sigma d^*}\right)^2, 0\right),$$

where  $m$  represents the number of crop rows to be evaluated on and  $\sigma d_v^*$  determines a horizontal distance corridor (scaled by a sensitivity parameter  $\sigma$ ) between the detected and the ground truth value in which the matching score  $s(u_{v,i})$  for the considered value  $u_{v,i}$  does not become zero. The closer  $s(u_{v,i})$  is to 1, the more accurate the detection. During our experiments, we encountered several difficulties when working with this dataset.




Fig. 4: Examples for problematic ground truth in CRBD. The yellow lines visualise the ground truth, calculated by the specified  $c_v^*$  and  $d_v^*$  values, which not always proceed accurate along the centre of the crop row, as shown in (b). Illustration (a) exemplifies that the ground truth  $c_v^*$  value (yellow) does not always represent the crop row closest to the image centre (dashed red line) correctly. Here, the blue line would have been the correct one in our understanding. Illustration (c) is an example where not enough ground truth data was provided. Illustration (d) is an example of an unrealistic use case due to angle and distance to its field of view.

While incorrectly set (left or right shifted)  $c_v^*$  values (cf. Fig. 4a) could be recalculated and corrected, inaccurate ground truth lines deviating slightly from the crop rows (cf. Fig. 4b) are not straightforwardly adjustable and distorted experimental results. This could be observed when setting  $\sigma$  to smaller values, which resulted in considerable performance breakdowns even for small deviations (cf. Sec. 4.2). Additionally, the number of annotated image rows contained by the .crp files were found to vary arbitrarily. For some images, the ground truth values are less than 170, which might conflict with the selected RoI of our approach (cf. Fig. 4c). Furthermore, for some images, the inclusion into the dataset remained unclear, since they neither constitute representative nor relevant cases, in our opinion (cf. Fig. 4d). For the sake of obtaining comparable quantitative results, our solution was to filter and group the images into categories. Accordingly, 204 images where

the  $c_v^*$  values have been found to be chosen correctly were grouped and named “correct  $c_v^*$ ” in the following. The others 77 images are not considered further.

## 4.2 Results

We tested our model on the “correct  $c_v^*$ ” dataset.  $\sigma \in \{0.1, 0.5, 1\}$  was varied to gain insights on the sensitivity regarding this parameter. We calculated our considered crop row points  $u_{v,i}$  with linear regression and the average CRDA value over all contained images. We then further distinguished between images with straight and curved crop rows to analyse the influence of this factor. Due to the stochastic nature of the PPHT, we evaluated our model by repeating the test  $n = 30$  times and report the average, the worst and best scores of all our runs in Table 1. It should be emphasised that no adjustments for individual images were made during the experiments and the model performed with the same setup for all images.

|                     |                | CRDA of correct $c_v^*$<br>(N=204) |        |        | CRDA of straight<br>rows (N = 32) |        |        | CRDA of curved rows<br>(N = 172) |        |        |
|---------------------|----------------|------------------------------------|--------|--------|-----------------------------------|--------|--------|----------------------------------|--------|--------|
| n = 30              |                | avg                                | min    | max    | avg                               | min    | max    | avg                              | min    | max    |
| <b>Our approach</b> | $\sigma = 0.1$ | 0.4538                             | 0.4483 | 0.4599 | 0.4957                            | 0.4746 | 0.5028 | 0.4459                           | 0.4372 | 0.4514 |
|                     | $\sigma = 0.5$ | 0.7126                             | 0.7023 | 0.7199 | 0.7780                            | 0.7520 | 0.7868 | 0.7032                           | 0.6918 | 0.7128 |
|                     | $\sigma = 1.0$ | 0.8027                             | 0.7939 | 0.8107 | 0.8553                            | 0.8406 | 0.8683 | 0.7940                           | 0.7862 | 0.8050 |
| <b>TMGEM</b>        | $\sigma = 0.1$ | 0.7538                             | -      | -      | 0.7281                            | -      | -      | 0.7586                           | -      | -      |
|                     | $\sigma = 0.5$ | 0.9639                             | -      | -      | 0.9492                            | -      | -      | 0.9667                           | -      | -      |
|                     | $\sigma = 1.0$ | 0.9811                             | -      | -      | 0.9673                            | -      | -      | 0.9836                           | -      | -      |

Tab. 1: Comparison of CRDA of our approach against TMGEM [VCH16] on specific datasets of CRBD. Due to low resolution of the pictures, small  $\sigma$  has big impact on our approach (cf. Sec. 4.4). Less accuracy here is in trade-off with much higher runtime speed (cf. Tab. 2)

To compare the computational efficiency and real-time capability with other CRD methods, we measured the average runtime per frame of our approach for the segmentation phase, the row detection phase and in total with two different hardware settings<sup>4</sup>. On TS1\* we tested the runtime of our approach to images of 2000 x 650 resolution to be comparable to [Gal17a]. Results are presented in Table 2.

<sup>4</sup> Computations have been performed on three different test settings (TS1, TS1\* & TS2) using two different hardware specifications. TS1 & TS1\*: AMD Ryzen Threadripper PRO 5965WX CPU, Geforce RTX 3090 GPU, 64GB RAM, Ubuntu 24.04 OS. TS2: AMD Ryzen 3 5300U CPU, AMD Radeon Graphics Display GPU, 8 GB RAM, Windows 11 OS.

| N = 204              | Segmentation Phase [s] |         |        | Row Detection Phase [s] |        |        | Total [s] |        |        |
|----------------------|------------------------|---------|--------|-------------------------|--------|--------|-----------|--------|--------|
|                      | avg                    | min     | max    | avg                     | min    | max    | avg       | min    | max    |
| n = 30               |                        |         |        |                         |        |        |           |        |        |
| <b>TS1 (ours)</b>    | 0.0009                 | 0.0008  | 0.0018 | 0.0131                  | 0.0096 | 0.051  | 0.0131    | 0.0105 | 0.053  |
| <b>TS2 (ours)</b>    | 0.0014                 | <0.0001 | 0.0061 | 0.0202                  | 0.0130 | 0.0965 | 0.0202    | 0.0140 | 0.0987 |
| <b>Doha et al.</b>   | -                      | -       | -      | -                       | -      | -      | 0.032     | -      | -      |
| <b>TMGEM</b>         | -                      | -       | -      | -                       | -      | -      | 1.749     | 1.687  | 1.953  |
| <b>TS1* (ours)</b>   | 0.0130                 | 0.0104  | 0.0223 | 0.1290                  | 0.0067 | 0.2990 | 0.1291    | 0.0194 | 0.3134 |
| <b>Garcia et al.</b> | 0.2530                 | -       | -      | 0.3547                  | -      | -      | 0.6073    | -      | -      |

Tab. 2: Runtime speed per frame of the approaches from Garcia et al. [GA17a], Doha et al. [DO21], TMGEM [VCH16] and our approach with different test settings. Due to the lack of hardware information, a straight comparison is not possible. Nevertheless, the different test settings TS1, TS1\* & TS2 allow for relative comparability.

### 4.3 Corner cases




Fig. 5: Demonstration of the application of our method on detected corner cases<sup>5</sup>

It can be observed that open-source data often does not reflect all relevant cases that might occur in agricultural contexts. Some works appeared to validate the proposed techniques in experimental settings comprising close to ideal scenes with proper light conditions, less interfering objects or weeds, and well-proceeding continuous crop rows lines. To substantiate our findings on the benchmark dataset, we additionally evaluate our approach qualitatively on such challenging cases showcasing its robustness. Examples are depicted in Figure 5. One recognised corner case which typically occurs in fields are crop rows next to the lateral edge of the field (cf. Fig. 5a). Especially during the segmentation phase the high number of missing rows can have a negative effect on threshold methods since they analyze the distribution of the pixels of the whole image. Also, the appearance of disturbing objects (e.g., trash, fence poles, cf. Fig. 5b), which can occlude parts of the rows and thus lead to row interruptions are not uncommon. High weed pressure is considered in Figure 5b as well as late growth stage in Figure 5c, both interfering with the detection of lines due to the overlap of green values in the image. Obviously, the opposite, a smaller amount of green values, e.g., due to low crop presence in early stages but also at the end of a crop row, where the horizon makes up a large share of the image (cf. Fig. 5d), can

<sup>5</sup> The images were recorded in Kaiserslautern by a ZED 2 Stereo Camera (1920 x 1080) installed on the front of a land machine and in Erfurt using a Mavic 2 Pro drone (3840 x 2160) with an altitude of 2.5m.

disturb the detection process. Even though some adjustments to the parameters of our approach are necessary, Figure 5 shows that our method is adaptable to all these corner cases.

#### 4.4 Discussion

The results, presented in Table 1, may lead to the conclusion that our approach is not comparable with TMGEM, but this was to be expected, since it not only has a far higher runtime, but also the evaluation method and dataset, including the ground truth with all its discussed difficulties (cf. Sec. 4.1), were developed for that method. Also, our approach can achieve acceptable CRDA, if we do not choose  $\sigma$  too small, which in our opinion does not make much sense on images with low resolution. As an example, when  $d_v^* = 10$  and  $\sigma = 0.1$ , even one pixel deviation suffices the matching score to evaluate  $s = 0$ . Considering the real-time capability, our model achieves substantially increased runtime speed (cf. Tab. 2), also in comparison to the deep learning approach [Do21] and, in particular, to the approach of [Gal7a], on which our method is based (cf. Tab. 2). With TS1\* a comparison with [Gal7a] was attempted by testing our model on the same image resolution. Comparing TS2 with TS1 shows that our approach does not require strong hardware to perform fast. As discussed before, a one-to-one comparison of these approaches is hardly possible since we could not find a uniform test environment and the models are neither available nor well reproducible. Our attempt to rebuild the model from [Gal7a] and test it on the CRBD led to the result that this approach did not work on the dataset, since it could not find any lines utilising HT. We assume that either the low image resolution or the heterogeneity of the images or both have pushed the model to its limits. Moreover, we evaluated our model only utilising linear regression for the last step of the row detection stage. Polynomial regression of second order could improve accuracy, particularly for detecting curved crop rows, and will be investigated further in future work. Also, further corner cases were identified and qualitatively evaluated to demonstrate robustness and adaptivity, to varying resolutions and technical characteristics of the images, of our model.

## 5 Conclusion

We presented a traditional CV approach enhanced by basic machine learning techniques (clustering, linear regression) and specific variations of fundamental steps (RoI, HT) in the pipeline for detecting crop rows on RGB image data. A quantitative and qualitative assessment on the CRBD as well as on selected challenging corner cases demonstrates the efficiency and robustness of our approach on both straight and curved crop rows. In spite of the comparable performance with other state-of-the-art row detection methods, there exists potential for optimizing our approach. Future work will focus on training a deep neural network for the automatic adjustment of an optimal RoI at the segmentation phase, which further improves our method's adaptivity. Furthermore, a meta optimization

approach, as presented in [Ma17], to let our pipeline self-optimize its hyperparameters and operators in response to given field and sensory conditions can be employed.

**Acknowledgments:** This work and the NaLamKI (Nachhaltige Landwirtschaft mittels Künstlicher Intelligenz) project are supported by the Federal Ministry for Economic Affairs and Climate Action (BMWK) based on a decision by the German Bundestag (01MK21003J).

## Bibliography

- [BHC19] Bah, M. D.; Hafiane, A.; Canals, R.: CRowNet: Deep network for crop row detection in UAV images. *IEEE Access*, 8:5189–5200, 2019.
- [Bo23] Bosse, S. et al.: Nachhaltige Landwirtschaft mittels Künstlicher Intelligenz – ein plattformbasierter Ansatz für Forschung und Industrie. In: 43. GIL-Jahrestagung, Resiliente Agri-Food-Systeme, pp. 41–52. Gesellschaft für Informatik e.V., Bonn, 2023.
- [Ca86] Canny, J.: A computational approach to edge detection. *IEEE Transactions on pattern analysis and machine intelligence*, (6):679–698, 1986.
- [Wo95] Woebbecke, D. M. et al.: Color Indices for Weed Identification Under Various Soil, Residue, and Lighting Conditions. *Transactions of the ASAE*, 38(1):259–269, 1995.
- [Do21] Doha, R. et al.: Deep Learning Based Crop Row Detection with Online Domain Adaptation. In: *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. KDD '21*, Association for Computing Machinery, New York, NY, USA, p. 2773–2781, 2021.
- [Ga17a] García-Santillán, I. D. et al.: Automatic detection of curved and straight crop rows from images in maize fields. *Biosystems Engineering*, 156:61–79, 2017.
- [Ga17b] Gazal, A. et al.: Breeding climate change resilient maize and wheat for food security. *Archives of Agriculture and Environmental Science*, 2(2):129–133, 2017.
- [GMK99] Galamhos, C.; Matas, J.; Kittler, J.: Progressive probabilistic Hough transform for line detection. In: *Proceedings. 1999 IEEE computer society conference on computer vision and pattern recognition (Cat. No PR00149)*. volume 1. IEEE, pp. 554–560, 1999.
- [Gu13] Guerrero, J. M. et al.: Automatic expert system based on images for accuracy crop row detection in maize fields. *Expert Systems with Applications*, 40(2):656–664, 2013.
- [He03] Heitmann, G.: *Landwirtschaftliche Fahrzeuge im Straßenverkehr*. aid Infodienst Verbraucherschutz, Ernährung, Landwirtschaft eV, 2003.
- [Ho62] Hough, P.V.C.: Method and means for recognizing complex patterns. 12 1962.
- [Hu62] Hu, M.-K.: Visual pattern recognition by moment invariants. *IRE Transactions on Information Theory*, 8(2):179–187, 1962.
- [Ja99] Jain, A. K. et al.: Data clustering: a review. *ACM computing surveys (CSUR)*, 31(3):264–323, 1999.

- [Ma17] Margraf, A. et al.: An Evolutionary Learning Approach to Self-configuring Image Pipelines in the Context of Carbon Fiber Fault Detection. In: 2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA). pp. 147–154, 2017.
- [MGK00] Matas, J.; Galambos, C.; Kittler, J.: Robust detection of lines using the progressive probabilistic hough transform. *Computer vision and image understanding*, 78(1):119–137, 2000.
- [Ot79] Otsu, N.: A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1):62–66, 1979.
- [PC12] Poudel, M. P.; Chen, S.-E.: Trends and variability of rice, maize, and wheat yields in South Asian countries: A challenge for food security. *Asian Journal of Agriculture and Rural Development*, 2(393-2016-23885):584–597, 2012
- [PHH07] Pan, J.; Huang, M.; He, Y.: Crop and Weed Image Recognition by Morphological Operations and ANN model. In: 2007 IEEE Instrumentation Measurement Technology Conference IMTC 2007. pp. 1–4, 2007.
- [Ro12] Romeo, J. et al.: Crop row detection in maize fields inspired on the human visual perception. *The Scientific World Journal*, 2012, 2012.
- [RS88] Reid, J.F.; Searcy, S.W.: An algorithm for separating guidance information from row crop images. *Transactions of the ASAE*, 31(6):1624–1632, 1988.
- [Sh23] Shi, Jiayou et al.: Row Detection BASED Navigation and Guidance for Agricultural Robots and Autonomous Vehicles in Row-Crop Fields: Methods and Applications. *Agronomy*, 13(7):1780, 2023.
- [VCH15] Vidović, I.; Cupec, R.; Hocenski, Ž.: Crop Row Benchmark Dataset, 2015.
- [VCH16] Vidović, I.; Cupec, R.; Hocenski, Ž.: Crop row detection by global energy minimization. *Pattern Recognition*, 55:68–86, 2016.
- [Zh18] Zhang, X. et al.: Automated robust crop-row detection in maize fields based on position clustering algorithm and shortest path method. *Computers and Electronics in Agriculture*, 154:165–175, 2018.

## Exploring AI for interpolation of combine harvester yield data

Lucas Johannsen <sup>1</sup>, Sebastian Ramm <sup>2</sup>, Yves Reckleben<sup>3</sup> and Stephan Doerfel<sup>4</sup>


**Abstract:** In the wake of eco-schemes introduced by the EU's Common Agricultural Policy, this study evaluates AI-based interpolation methods for generating yield maps as one component of a decision support system, aiding farmers in eco-scheme implementation. The research contrasts ordinary Kriging (OK) with AI techniques – Random Forest (RF) enhanced with spatial features (RFsp), covariates (RFspco) and DeepKriging (DK), utilizing combine harvester yield data. Performance metrics show AI, especially RF variants, surpassing OK. For a 0.7 split,  $R^2$  were 0.6 (OK), 0.77 (RF), 0.81 (RFsp), 0.78 (DK); MSE were 0.6 (OK), 0.34 (RF), 0.28 (RFsp), 0.32 (DK). Spatial features boosted accuracy, while incorporating Terrain Models had no relevant impact on the results. These findings are crucial for an automated, accurate decision support system, facilitating eco-scheme adoption for farmers. The efficiency of AI methods underscores their potential in promoting sustainable, informed agricultural practices.


**Keywords:** artificial intelligence, machine learning, yield map, spatial prediction, interpolation

### 1 Introduction

In January 2023, the European Union's Common Agricultural Policy (CAP) unveiled new guidelines concerning agricultural subsidies, prominently featuring the introduction of eco-schemes. These eco-schemes represent voluntary initiatives for farmers, focusing on enhanced environmental and climate protection measures that surpass the foundational criteria set by conditionality. By adopting these measures, such as designating portions of their land as non-productive or planting flowering strips, farmers become eligible for compensatory payments [BM23a]. This presents farmers with the task of determining which eco-schemes to implement in their individual fields without incurring financial setbacks. Traditionally, farmers have relied on their vast field management experience and on field-level assessments to make such decisions. However, this method may overlook certain

---

<sup>1</sup> FuE-Zentrum FH Kiel GmbH, Grüner Kamp 11, 24783 Osterrönfeld, lucas.johannsen@fh-kiel.de,   
<https://orcid.org/0009-0004-7731-5630>

<sup>2</sup> FuE-Zentrum FH Kiel GmbH, Grüner Kamp 11, 24783 Osterrönfeld, sebastian.ramm@fh-kiel.de,   
<https://orcid.org/0009-0009-6834-4321>

<sup>3</sup> Kiel University of Applied Sciences, Agricultural Engineering, Grüner Kamp 11, 24783 Osterrönfeld,  
yves.reckleben@fh-kiel.de

<sup>4</sup> Kiel University of Applied Sciences, Data Science, Grenzstrasse 3, 24149 Kiel, stephan.doerfel@fh-kiel.de

field sections optimal for eco-scheme implementation. To refine this decision-making, a comprehensive, site-specific economic examination of production data is crucial, aiming to spotlight areas with subpar productivity or high production expenses. Therefore, the project “KI-Anbauplanung: Räumliche Optimierung landwirtschaftlicher Öko-Regelungen auf Basis heterogener Feldinformationen“ aims to develop a prototype of a web-based decision support system (DSS) for farmers to assist them in their choices and promote the adoption of eco-schemes [RJR23]. Early statistics on the adoption of eco-schemes as climate and environmental protection measures by German farmers indicate underutilization of allocated funds [BM23b], underscoring the significance of this decision-support tool. In this context, site-specific yield data are an important source to describe the productivity of fields. Today's combine harvesters typically come equipped with yield monitoring systems that continuously collect GPS-referenced yield points during harvesting. Yield measurements from combine harvesters aren't spread uniformly across the field; instead, they're tied to the harvester's driven path. These measurements provide an average yield that represents the area covered by the harvester's working width between two successive recordings. In contrast, yield maps offer a continuous set of values for each grid point, evenly dispersed over the field. To fill any data gaps, interpolation methods use surrounding points for estimation.

One technique that has gained widespread acceptance for interpolating yield data is Kriging in its various forms [B103]. Kriging has several strengths that make it a popular method for spatial prediction. One of the biggest advantages of Kriging is its flexibility. Various semivariogram models can be used to capture different types of spatial correlations, from standard options like linear or exponential to customized functions tailored to the specific use case. Furthermore, Kriging serves as the Best Linear Unbiased Predictor, providing estimates that are both unbiased and have minimal variance. However, Kriging is not without its limitations. The method's flexibility in the choice of semivariogram is also a drawback, as it is sensitive to this selection, which must adequately reflect the data. It also assumes normally distributed residuals, which is not always the case. Furthermore, the technique demands a robust dataset for effective application. Lastly, Kriging requires the estimation of a covariance function that must adequately reflect the data's inherent spatial dependence [WO07].

From the development of the web-based DSS, specific requirements emerge for the interpolation method. A site-specific economic evaluation of a farm involves vast data, necessitating automated analysis. Traditional interpolation techniques, such as Kriging, demand specialized parameterization knowledge, making them less suitable for implementation into the DSS for farmers. Additionally, yield data from combine harvesters typically contain random and systematic errors that usually cannot be completely removed even with filtering [BSR01; B103]. Hence, the interpolation method should be robust against noise. Therefore, exploring alternatives is logical, with AI-based methods standing out as a promising option. In current research, there are a few attempts to apply machine learning to interpolate yield data to maps [We20], but the main focus is on yield prediction – a closely related but distinct topic. Yield prediction looks to forecast future yields based



on different variables, whereas yield mapping aims to extend measured yields to unsampled areas of the field. The review by [vKC20] underscores the growing emphasis on yield prediction in machine learning applications within agricultural research. It highlights the most used variables and popular deep learning algorithms like Convolutional Neural Networks, Long Short-Term Memory networks, and Deep Neural Networks (DNNs). The lack of comparable studies on yield data interpolation, especially contrasting various ML architectures, highlights a significant gap in current research.

The objectives of this paper include evaluating and comparing the performance of a traditional interpolation method, namely Ordinary Kriging (OK), and different machine learning based approaches, in the context of combine harvester yield data. Out of the approaches found in literature, two have been selected for examination: Random Forest (RF), which is extensively used in some variations [Si23], and a Deep Neural Network-based approach to cover a broader spectrum of machine learning techniques.

RF is an ensemble learning approach that employs Decision Trees as its base. It operates on three pillars: Decision Trees, Bagging, and Decorrelation. Decision Trees serve as the basis for Regression Trees, which focus on minimizing the Mean Squared Error (MSE) in their partitions. Bagging improves model performance by aggregating decision trees built on bootstrap samples, significantly reducing model variance, and improving accuracy. Decorrelation enhances the ensemble's robustness by ensuring each tree focuses on different data features, mitigating overfitting issues. RF offers advantages like non-linear variable mapping and robustness against noise but faces limitations like parameter sensitivity and computational overhead for feature-rich data. It is also known to struggle with high-dimensional, sparse data. The Random Forest spatial prediction system (RFsp) stands out as a specialized framework that accounts for spatial autocorrelation. It uses a set of geographical covariates to incorporate proximity between observation and target locations. In RFsp, it is defined by a range of buffer distances or other proximity measures. This makes RFsp especially effective in capturing spatial correlation similarly to techniques like Kriging. While RFsp effectively tackles the spatial autocorrelation limitations found in standard RF algorithms, room for improvement remains, such as optimizing distance measures and addressing issues with large datasets or extrapolation [He18].

In this study, Digital Terrain Models (DTMs) have been evaluated as additional predictors in the Random Forest spatial model with covariates (RFspco). Due to the strong correlation between the elevation data from DTMs and crop yield, DTMs have emerged as a strong candidate for a covariate [MO17]. The high-resolution nature of this data further reinforces its utility in this context.

DNNs, on the other hand, have demonstrated significant utility in diverse areas such as computer vision and Natural Language Processing [LBH15]. However, their direct application to spatial prediction poses challenges owing to data scarcity and a limited set of features. The study by [Ch20] addresses these constraints by incorporating techniques

from Universal Kriging to augment the feature space. Specifically, they introduce an "embedding layer", essentially a dense matrix populated with spatial variables, which facilitates the DNN in capturing complex spatial patterns. In operational terms, this methodology initiates with a grid of spatial points, denoted as "K". Distances between the sample data and these grid points are measured, analogous to the procedures employed in RFsp models. These distances are subsequently transformed through a Wendland kernel. The choice of Wendland kernel is particularly advantageous due to its capacity to assign greater weight to proximate points, effectively serving as a localized influencer for the data. Consequently, this enriches the feature space, enhancing the applicability of DNNs in spatial prediction tasks.

This research distinguishes itself by undertaking a comprehensive survey of critical dimensions that remain unique in the field. It rigorously compares interpolation models like Kriging, RF, and DK to assess their efficacy. Moreover, it delves into the impact of spatial features, particularly point distances, on RF's performance and investigates the implications of incorporating Digital Terrain Models as covariates in RFsp. A pivotal aspect of the study is to analyze how different train-test split ratios affect the performance of machine learning models in yield interpolation. The overarching goal is to identify an interpolation method that not only excels in performance but also aligns with the DSS requirements, a quest that has not been previously embarked upon in this domain.

## 2 Material and Methods

The combine harvester's yield monitoring data (Claas Lexion 760 TT) used in this study were gathered from seven fields in eastern Schleswig-Holstein, Germany, during the 2022 harvest (Tab. 1).

| Field | Area [ha] | Crop          | Initial number of yield points | Final number of yield points after filtering |
|-------|-----------|---------------|--------------------------------|--|
| 1     | 25.5      | winter wheat  | 8876                           | 7631   |
| 2     | 7.6       | winter barley | 3859                           | 2929   |
| 3     | 21.0      | winter canola | 8844                           | 7569   |
| 4     | 18.4      | winter wheat  | 7410                           | 5732   |
| 5     | 30.4      | field beans   | 8202                           | 6685   |
| 6     | 20.7      | field beans   | 6486                           | 5352   |
| 7     | 24.9      | winter wheat  | 8165                           | 6446   |

Tab. 1: Number of yield observations per dataset before and after cleaning

These data represent the yield distribution of typical arable crops for this region and were initially stored in ISOXML format (ISO 11783). Relevant features such as coordinates,

yield per area (t/ha), crop moisture (%), harvester throughput (t/h) and speed (m/s) were extracted from the ISOXML files and stored as Geopandas-Dataframe. As described before, raw data from combine harvester yield monitoring systems are prone to errors, which affects the accuracy of yield maps. This implies that the data should be cleaned prior to utilization.

In this study, a simple rule-based filter was applied, using the following criteria for filtering the yield data:

- Detection of overlaps using distances between points on neighboring tracks, considering a threshold of 9 meters (given a 10.5 meter working width).
- Elimination of zero values in yield, grain moisture, harvester throughput, and speed.
- Identifying outliers three times the standard deviation away from the average yield.

The filters were applied sequentially, the results visualized in GIS and evaluated using histograms. Based on this, the parameters for filtering were determined.

In addition to the yield data, a DTM was chosen as potential covariate. It indicates the altitude above sea level of each square meter [LV22]. The altitude was added to the yield datasets as an additional feature based on the position of individual yield points within the DTM grid cells.

Based on the data from Fields 1 to 6, five different models were implemented in Python 3.9 for the purpose of interpolating the combine harvester's yield data:

(1) OK, serves as a baseline model and benchmark. For this study, the “PyKriging” library [Mu], was employed. Weight (bool) and variogram-model were treated as hyperparameters. As for every model approach, a separate hyperparameter optimization study was conducted for each dataset to identify the most suitable parameter combination.

(2) The DK model, a Deep Neural Network, was initially designed in TensorFlow [Te23] but has been implemented in PyTorch [Pa19] for this study. The specific architecture is a multi-layer perceptron with four linear layers, each followed by a Rectified Linear Unit activation function. Dropout layers and batch normalization techniques are incorporated to mitigate overfitting and stabilize training. The input layer takes the length of the training dataset, and three hidden layers each contain 100 neurons. Post-activation function, a dropout layer with 0.5 probability is integrated, and batch normalization occurs after the first and third layers. The output layer provides a single value, and MSE is used as the loss function. The architecture remains constant, but learning rate and epoch numbers are tailored for each dataset. To ensure consistent results, a manual seed is set at 1. Data scaling is crucial for DeepKriging, requiring feature values from 0 to 1. Thus, sklearn's [Pe12] MinMaxScaler is utilized for coordinates and targets. Nodes are established as a grid over the field, and Euclidean distances from each data point to these nodes are calculated. If a distance falls between 0 and 1, the Wendland kernel function is applied; otherwise, it is

set to 0. These derived values populate a matrix that serves as the feature space for subsequent steps.

(3) The RF occurs in the context of this study in three model variants. Therefore, the basic configuration is described first, whereas only the differentiating steps for the other variants are highlighted. To address the large dataset issues highlighted by [He18] and to meet our web-based DSS needs, we opted for RAPIDS [Ve21], a GPU-based framework, instead of the CPU-based sklearn for RF. This choice aimed to expedite computation. Initially, the RF model is defined by two parameters significantly influencing both computational time and prediction accuracy: “n\_estimator”, representing the number of trees in the forest, and “max\_depth”, indicating the tree’s maximum depth or number of branches. To find the optimal parameter combination, hyperparameter testing was employed for optimization, focusing on the Field 1 dataset. The resulting values were 508 for “n\_estimator” and 85 for “max\_depth”. To maintain comparability, this parameterization was consistently applied across all RF models and all data sets, while the other parameters were left at their default values also for the purpose of model comparison. After setting the parameters, the fit method is used to create the forest based on the training dataset. For this, the x- and y-coordinates and the corresponding yield as target values are needed. Then, based on the given x and y coordinates of the test data set, the predict-method allows the prediction of the yield value. The prediction leads to an array of target values, which are then evaluated against the actual test targets.

(4) To enhance learning in the RFsp, spatial covariates, emphasizing distances as features for spatial context, must be generated alongside x and y coordinates. This could be done by determining the distance from each point to every other point and storing this as a feature. This approach would result in a full-rank matrix, making training on this data possible. However, this method leads to a large feature space and, especially because this model is based on RF, it would result in lengthy training times. Instead, a grid of evenly distributed points is placed over the field. The density of this grid, i.e., the number of points per field, is treated as a hyperparameter in the following. Subsequently, the Euclidean distances from these generated anchor points to all datapoints are calculated [He18]. The model parameters, especially the number of estimators and the maximum depth, remain the same as described for RF to ensure comparability. However, the consideration of spatial features leads to the introduction of two additional parameters: the “Density”, which determines the density of anchor points on the field, and the “Radius”, which determines the consideration of points within a certain radius. Both parameters were optimized for each data set and a split ratio of 0.5. The optimized values for Density range from 10 to 50, which corresponds to the number of points between the field boundaries on the x and y axes. The optimized range of values for Radius is between 5 and 15 and refers to the quantile of distances considered for the analysis. With the corresponding optimized data set, the RF model is fitted. Subsequently, the prediction of the target values in the test data set is performed.

(5) The RFspco model, expanding on the RFsp, includes altitude as an additional explanatory variable, thereby enriching the feature space. It follows parameter settings from the

previous model, undergoes training with the “fit” method, and predicts target values in the test dataset.

Hyperparameter optimization was managed using the Optuna [Ak19] framework. The process unfolds in multiple stages. First, an “Objective” function is defined, which encompasses model specification, training, and evaluation. This is where target hyperparameters for optimization are identified. Using the “trial.suggest” method, a value range for these parameters is set, including those pertinent to model specifics and data preparation. Model performance is evaluated using the MSE, which is then returned by the function. After setting up the optimization framework, an Optuna study is initiated with a unique identifier to oversee the process. Results are stored in a database for record-keeping. The optimization direction is set, aiming to minimize the MSE value in this case. Finally, the optimization runs through a pre-defined number of trials. The optimized parameters for different models are summarized in Tab. 22.

| <b>Model</b>                             | <b>Parameter</b>                        |
|--|---|
| Ordinary Kriging (OK)                    | Weight (bool); variogram-model          |
| DeepKriging (DK)                         | Learning rate; epochs                   |
| Random Forest (RF)                       | n_estimator; max_depth                  |
| Random Forest spatial (RFsp)             | n_estimator; max_depth; density; radius |
| Random Forest spatial covariate (RFspco) | n_estimator; max_depth; density; radius |

Tab. 2: Overview of parameters optimized in this study

In the process of creating yield maps, yield monitoring data are typically interpolated into a grid. However, for the grid cells, no true values are known, which makes them unsuitable for model comparison in interpolation because error calculation is not possible. To enable a comparison nonetheless, only the data with known ground-truth values is available and must be used for both training and comparison of prediction results. For that purpose, this data is split into a training set (70%) and a test set (30%). The algorithms are then learned exclusively on the training data. Thus, the test dataset contains points that the algorithm did not see during training and that it can now predict for. These predictions are then compared to the observed yield values and the prediction errors are determined. To stabilize the results, such a split is conducted multiple times, i.e. a 5-fold cross-validation was performed. Model performance was evaluated using the metrics MSE and  $R^2$ .

The second approach is designed to examine how machine learning (ML)-based models react to changes in data density and availability. This is achieved by varying the training-to-test data ratio. Experiments are conducted using these different splits to simulate various data scenarios. The `train_test_split` function is used for dividing the dataset accordingly. The ratio under investigation dictates the data split. Shuffling the data is crucial to avoid bias – like training only on a specific field area, which would ignore other spatial patterns. A random seed is set to ensure experiment repeatability. For a nuanced look at the results, the test size varies from 0.1 to 0.95 in 0.05 increments, resulting in 17 different scenarios, and MSE serves as the evaluation metric.

In the grid interpolation phase, the final step of the study, only the most suitable model was used for comparison with OK. Yield data from Field 7, which was excluded from the initial model comparisons, served as the basis. The data was processed as before. A 10 x 10-meter grid was initialized, and features were created as previously described. Finally, the model was trained on the complete training dataset, and yield values for the grid points were predicted.

### 3 Results

In the model comparison, ML-based methods consistently outperform OK, indicated by lower MSE and higher  $R^2$  values. The performance across the six fields is also more stable for the ML-based models, as shown by the narrower ranges between their minimum and maximum values, compared to OK (Tab. 33). When comparing DK and RF, DK shows a slightly better performance, reducing the MSE by 0.024 and increasing the  $R^2$  by 0.018. It also offers more consistent results in both these areas compared to RF. After adding the spatial feature into the RFsp model, the ranking changes. RFsp now takes the lead, offering both lower error rates and more consistent results compared to both RF and DK. Adding DTM data as a covariate to RFspco reveals no significant performance difference compared to the original RFsp model.

| Model                                    | Stats | Mean  | Min   | Max   |
|--|-------|-------|-------|-------|
| Ordinary Kriging (OK)                    | MSE   | 0.599 | 0.255 | 0.948 |
|  | $R^2$ | 0.595 | 0.431 | 0.824 |
| DeepKriging (DK)                         | MSE   | 0.318 | 0.174 | 0.475 |
|  | $R^2$ | 0.783 | 0.662 | 0.831 |
| Random Forest (RF)                       | MSE   | 0.342 | 0.259 | 0.524 |
|  | $R^2$ | 0.765 | 0.660 | 0.813 |
| Random Forest spatial (RFsp)             | MSE   | 0.278 | 0.163 | 0.398 |
|  | $R^2$ | 0.806 | 0.672 | 0.857 |
| Random Forest spatial covariate (RFspco) | MSE   | 0.278 | 0.165 | 0.398 |
|  | $R^2$ | 0.806 | 0.672 | 0.857 |

Tab. 3: Results of the model comparison, based on 0.3 test size and 5-fold cross-validation

During simulations that varied the availability or density of sample data, the ML models were evaluated with diminishing training data and increasing test data sizes. The results indicate that error rates, represented by MSE, increase as training data decreases (Fig. 1). Notably, this is not a linear relationship but rather appears to follow a parabolic curve, suggesting a roughly quadratic functional relationship. Relative to their respective baselines, the RF models show consistent behavior across different levels of data availability.

DeepKriging, on the other hand, displays a less smooth functional curve and non-continuous performance. For example, it exhibits the smallest error of all models at a test size of 0.75, but the error rate rises slightly at a test size of 0.70. Despite these fluctuations and the fact that the data is split, the overall error rates for both the plain RF, the RFsp and RFspco models remain consistent with the findings from the cross-validation study.




Fig. 1: Mean squared error of ML models across test size split ratios from 0.1 to 0.95

Based on the presented results, RFsp seems to be the most promising candidate for implementation into the DSS. This assumption is further underlined by a visual inspection of the outcome, when employing the RFsp model to interpolate the combine harvesters yield data from Field 7 into a  $10 \times 10$  meter grid (6446 yield data points to 2488 grid cells, i.e. 0.72 to 0.28). For comparative evaluation, OK was also utilized (Fig. 2).

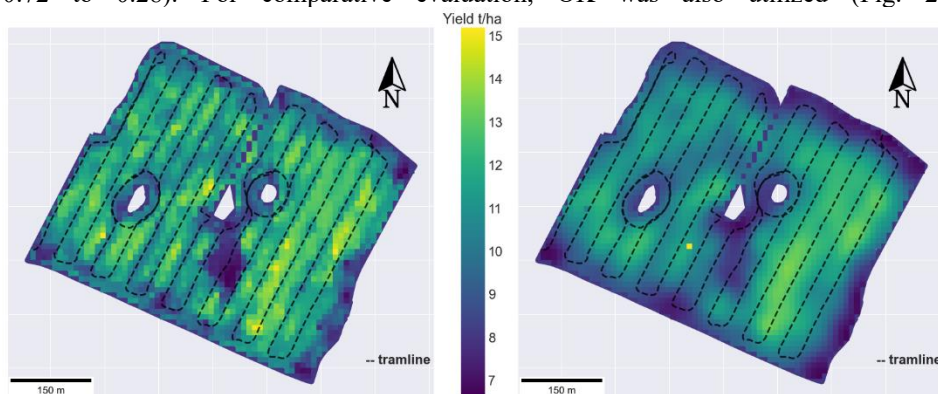


Fig. 2: Comparison of RFsp (left) and OK (right) interpolation of wheat yield into a  $10 \times 10$  meter grid

In line with the objective, the interpolation method must be capable of generating yield maps that accurately reflect the spatial variability of crop yields. Upon visual inspection, it is evident that the OK method generates a considerably smoother map compared to the RFsp model, which displays more localized variability. It becomes evident that the RFsp model-based map reveals distinct parallel structures in the field. By overlaying the yield map with the GPS position data from mineral fertilizer application, which mark the tramlines in the field (36 meters apart), it becomes clear that the parallel structures on the map correspond to the tramlines which are leading to a local decrease in yield. Thus, the yield map generated with the RFsp model seems to be more in line with the agronomic reality than the yield map generated with OK.

## 4 Discussion and Conclusions

The primary objective of this study was to identify an interpolation method suitable for integration into a web-based DSS that demands high accuracy and automation. The machine learning methods from [He18] and [Ch20] were successfully employed for yield mapping. The key conclusion drawn from this study is that ML-based yield data interpolation methods can achieve higher accuracy compared to traditional OK. In contrast to Hengl et al.'s assertion [He18], unmodified RF yielded noteworthy results, raising questions about the necessity of extending it to RFsp. However, RFsp clearly excelled in prediction accuracy, so RFsp emerged as the most promising candidate for implementation in the DSS, minimizing the error most effectively.

The cornerstone of this work lies in the creation of spatial variables, crucial for both the RFsp and DK models. Inspired by prior studies [Ch20; He18], we utilized these spatial variables in our existing yield datasets. By fine-tuning these parameters, the RFsp model showed improved performance, an approach that could potentially be adapted for DK. The validity of this methodology remains to be verified in future studies. For grid-based analysis, it remains to be seen whether the number of anchor points should align with grid dimensions.

Interestingly, the DTM as additional covariate used in this study did not provide significant explanatory power in RFspco. As for the DTM, it is possible to derive additional parameters from the altitude values and location, such as slope and its orientation. These values may provide further physiological explanations for yield [ZT87]. These features could be revisited in future projects that employ similar methodologies for mapping field-specific data. This raises questions about whether similar behavior would be observed in other models, such as DK.

The machine learning models' behavior when faced with shifting ratios of training to test data was unanticipated, given the absence of those examinations in existing literature. It is notable that the error rate rises disproportionately when there is a scarcity of training data. Yet, it remains relatively stable until the proportion of test data exceeds half of the



dataset, as shown in Figure 1. These observations lead to the question of whether the functional relationship between split-train-ratio and error rate observed in Figure 1 can be translated into an empirical error equation. Such an error equation could be used to derive the smallest possible cell size for a grid, given a predefined acceptable level of error. This will be one of the hypotheses for further investigations. However, the spatial distribution of points is a variable that represents an unknown in the error equation and requires further investigation.

The dataset in this study, which includes yield data from seven fields within a single natural area, serves as a foundational test but is limited in terms of broader implications. In subsequent research, models should be validated using a more comprehensive dataset, featuring yield data from different combine harvester models, multiple natural areas, and a larger scope.

The quality of yield maps generated via interpolation hinges on both the chosen interpolation method and the raw data's integrity. While RFsp might react less sensitive to data quality, it is vital to refine not only the interpolation techniques but also the yield data preprocessing. In this work, a basic rule-based filter was used. While it undoubtedly eliminates some plausible data points, it falls short in catching all errors. Concurrently, we are looking into leveraging machine learning to enhance this filtering process.

The primary objective of finding an interpolation method that meets the needs of the forthcoming farmer DSS – focused on spatially optimizing climate and environmental protection measures – has been successfully met.




**Acknowledgements:** The project „KI-Anbauplanung: Räumliche Optimierung landwirtschaftlicher Öko-Regelungen auf Basis heterogener Feldinformationen“ is funded by the Schleswig-Holstein federal state under grant number 220 22 006.

## Bibliography

- [Ak19] Akiba, T. et al.: Optuna: A next-generation hyperparameter optimization framework. In (Teresesai, A. Eds.): Proc. 25th ACM SIGKDD Int. Conf. on Knowledge Discovery & Data Mining, New York. Association for Computing Machinery, pp. 2623–2631, 2019.
- [BI03] Blackmore, S.: The role of yield maps in Precision Farming. PhD thesis, Silsoe, 2003.
- [BM23a] BMEL, Bundesministerium für Ernährung und Landwirtschaft: Den Wandel gestalten! Zusammenfassung zum GAP-Strategieplan 2023-2027, 2023.
- [BM23b] BMEL, Bundesministerium für Ernährung und Landwirtschaft: Neue GAP: Förderung gut angenommen, Zurückhaltung bei Ökoregelungen. Nr. 72/2023, 2023.
- [BSR01] Beck, A. D.; Searcy, S. W.; Roades, J. P.: Yield data filtering techniques for improved map accuracy. *Applied Engineering in Agriculture* 4/17, 423-431, 2001.

- [Ch20] Chen, W. et al.: DeepKriging: Spatially Dependent Deep Neural Networks for Spatial Prediction. arXiv preprint, 2020.
- [He18] Hengl, T. et al.: Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. *PeerJ* 6, e5518, 2018.
- [LV22] LVermGeo SH, Landesamt für Vermessung und Geoinformation Schleswig-Holstein: Downloadportal - Offene Geobasisdaten des LVermGeo SH (OpenGBD). [https://geo-daten.schleswig-holstein.de/gaialight-sh/\\_apps/dl/download/](https://geo-daten.schleswig-holstein.de/gaialight-sh/_apps/dl/download/), accessed 14 Oct 2023.
- [Mo17] Moravec, D. et al.: Digital elevation models as predictors of yield: Comparison of an UAV and other elevation data sources. *Agronomy Research* 1/15, pp. 249–255, 2017.
- [Mu14] Murphy, B. S.: PyKrige: Development of a Kriging Toolkit for Python. In: AGU Fall Meeting 2014, American Geophysical Union, Abstract: H51K-0753, San Francisco, 2014.
- [Pa19] Paszke, A. et al.: PyTorch: An Imperative Style, High-Performance Deep Learning Library. In (Wallach, H. et al. Eds.): Proc. 33rd Conference on Neural Information Processing Systems (NeurIPS 2019), Vancouver, pp. 8026–8037, 2019.
- [Pe12] Pedregosa, F. et al.: Scikit-learn: Machine Learning in Python, *Journal of Machine Learning Research*, 12/2011, pp. 2825-2830, 2011.
- [Ve21] Vega, J. et al.: Reproducible Analysis Pipeline for Data Streams: Open-Source Software to Process Data Collected With Mobile Devices. *Frontiers in digital health*, pp. 769-823, 2021.
- [RJR23] Ramm, S.; Johannsen, L.; Reckleben, Y.: Data to Decisions: Efficient Implementation of Eco-Schemes, a Use Case for AI in Agriculture. In (Canavari, M.; Vitali, G.; Mattetti, M. Eds.): Proc. 14th European Conference on Precision Agriculture, ECPA2023 - Unleashing the potential of precision agriculture - Book of Abstracts (Posters), Bologna, pp. 121-122, 2023.
- [Si23] Sijia, J. et al.: Spatial prediction using random forest spatial interpolation with sample augmentation: a case study for precipitation mapping. *Earth Science Informatics* 1/16, pp. 863–875, 2023.
- [Te23] TensorFlow Developers: TensorFlow. [tensorflow.org](https://www.tensorflow.org/), accessed 27 Oct 2023.
- [vKC20] van Klompenburg, T.; Kassahun, A.; Catal, C.: Crop yield prediction using machine learning: A systematic literature review. *Computers and Electronics in Agriculture* 177, 105709, 2020.
- [We20] Wei, M. C. F. et al.: Carrot Yield Mapping: A Precision Agriculture Approach Based on Machine Learning. *AI* 2/1, pp. 229–241, 2020.
- [WO07] Webster, R.; Oliver, M. A.: *Geostatistics for environmental scientists*. Wiley, Chichester, 2007.

## Compliance of agricultural AI systems – app-based legal verification throughout the development

Niklas Kruse <sup>1</sup>, Paul Wachter <sup>2</sup> and Julius Schöning <sup>3</sup>


**Abstract:** Significant advances in artificial intelligence (AI) have been achieved; however, practical implementation in agriculture remains limited. Compliance with emerging regulations, such as the EU AI Act and GDPR, is now vital, even for non-critical AI systems. Developers need tools to assess legal compliance, which is complex, often requiring full legal advice. To address this issue, we are developing a support app that simplifies the legal aspects of AI system development, covering the entire lifecycle, from conception to distribution. The current app, which covers the key legal area of copyright and will soon include GDPR and the AI Act, aims to bridge the gap between AI research and agriculture. An evaluation of our app by experts from both the legal and the IT domains shows that the app assists the developers so that they make legally correct statements. Consequently, it promotes legal compliance and awareness among developers, contributing to the seamless integration of AI into agriculture. The need for compliant AI systems in various industries, including agriculture, will only increase as regulations evolve.


**Keywords:** AI, compliance, agriculture, decision support application, law, ethical AI


### 1 Introduction

Artificial Intelligence (AI) systems have gained considerable importance in agricultural use [E119; Sh21; We20] and are already applied on many farms today. Despite this development, some essential legal questions regarding the use of AI systems have largely gone unresolved in the past [Bu23; Ha20]. The European Commission (EC) especially wants to use the current legislative period to create a legal framework to establish trustworthy and ethical AI [Ha20], making AI systems mandatory to comply with the relevant standards. Many national and supranational regulations affect the field of agriculture, so complex legal issues arise in many core topics. However, a legally compliant development of AI systems is becoming increasingly important, as the requirements in this area are becoming much stricter [Bu23; Va23]. A lawfully compliant design can be challenging to implement if a design that complies with the relevant laws is not considered and adhered to right from

---

<sup>1</sup> Osnabrück University of Applied Sciences, Faculty of Engineering and Computer Science, Albrechtstr. 30, 49076 Osnabrück, niklas.kruse@hs-osnabrueck.de,  <https://orcid.org/0009-0001-7080-6662>

<sup>2</sup> Osnabrück University, Institute of Cognitive Science, Neuer Graben 29, 49074, pwachter@uni-osnabrueck.de,  <https://orcid.org/0000-0002-6224-6140>

<sup>3</sup> Osnabrück University of Applied Sciences, Faculty of Engineering and Computer Science, Albrechtstr. 30, 49076 Osnabrück, j.schoening@hs-osnabrueck.de  <http://www.orcid.org/0000-0003-4921-5179>

the start of development [Ma20]. A later conversion of the AI system can be difficult or impossible if the platform's performance is already exhausted [Va16]. The regulations in question are complicated for developers to access and hard to understand. As a result, many innovations have never left the academic testing environment, especially in agriculture, since these new technologies are incompatible with legal standards [Ca20; SF23]. Thus, to bring AI-based systems to a wide range of agricultural applications, developers need to be equipped with tools that facilitate the implementation of AI in a legally compliant manner [Fi19; Ga18]. The importance of the legal conformity of AI systems in agriculture can be illustrated by an existing concept. If a farmer uses an AI-supported tool to optimize his crop rotation, for example, he must inevitably disclose data about himself and the conditions on his farm [SWT23]. This data is regularly personal data within the meaning of Art. 4 No. 1 GDPR, which is then processed by the AI system within the meaning of Art. 4 No. 4 GDPR. In practice, such a system would then have to comply with the principles of the GDPR, which has far-reaching consequences, especially in the case of automated decision-making within the meaning of Art. 22 GDPR. There is also the question of explainability if the AI system provides expert advice regarding crop rotation [SR21]. In the future, such systems could be high-risk AI systems within the meaning of the future AI Act so that far-reaching requirements are placed on explainability. This work aims to develop an app that promotes the production of lawfully compliant AI systems. Note that our app will not replace legal advice but rather create awareness for the developers that AI can have a variety of possible collisions with applicable law. At the same time, our app should enable developers to get started with the legally compliant implementation of AI systems without consulting a considerable amount of specialist literature. Assistance for legal decision-making or overall digital tools for legal work has only been found to a limited extent or primarily aimed at lawyers or people mainly based in the legal field. The advancing regulation, the conversion costs in case of a rule violation, and the importance of AI in agriculture make it necessary for non-lawyers to have a supporting app at their disposal to develop legally compliant and ethical AI systems.

## **2 State of the Art**

Getting into the topic of AI regulations in agriculture, this section first reviews the current and future regulations, followed by an overview of tools to support regulatory decision-making.

### **2.1 Current and future regulation of AI in agriculture**

The current legal assessment of AI systems is characterized by AI systems affecting many different areas of law [Ge21] without the regulations in question having been developed specifically for AI systems [Ha20; Va23]. The dynamic development of AI and the abstract nature of the German legal system lead to the fact that, especially in agriculture, many laws and regulations can and must be applied to AI, even if the laws were derived

and enacted by the legislator far before this technological development. However, AI is a technology that is difficult to compare with previous technological leaps [Ma17] in terms of its degree of effectiveness and fields of application, so the scientific discourse on which regulations should be applied to AI systems and to what extent has not yet been concluded to a large extent [Ge21; Ha20; Va23]. At the same time, the EC is very active at the supranational level in creating a legal framework for regulating AI systems to avoid fragmentation of the internal market by the individual member states [Va23]. Since AI systems can be used in many possible application areas, even if the scope of the consideration is limited to an agricultural context, many relevant regulations can nevertheless be found so that the following will be limited only to the most concise ones for agriculture.

One area of law that has received little attention in legal discourse but is extensive is data protection law. If, for example, images of real people are used in the training of an autonomous agricultural machine, the AI system is subject to the GDPR, as these images are usually personal data within the meaning of Art. 4 No. 1 GDPR. However, the scope of the GDPR goes far beyond collision detection and processing of images. All sensors that only collect data together with a human user and use the Internet for communication use IP addresses so that all agricultural AI systems that process this data also result in the processing of personal data within the meaning of Article 4 No. 2 of the GDPR, since an IP address regularly constitutes personal data. In this respect, the design of an unobjectionable AI system under data protection law must begin with the conceptual design. Due to the applicability of the GDPR through the processing of personal data, the prohibition with reservation of permission from Art. 6 I GDPR applies. At the same time, the principles of data protection from Article 5 of the GDPR must also be considered, such as the purpose limitation principle and the principle of data minimization.

The German Copyright Act (UrhG) has manifold meanings for AI systems in the agricultural sector. First, copyrighted data is often used for training. For example, suppose images are collected for a dataset to recognize certain plants or other products to use them for training an AI. In that case, the question arises whether the images are subject to copyright protection and thus require consent or the realization of specific legal permissions. In this respect, downloading training data from a copyright-protected source can lead to an infringement of §16 I UrhG, or sharing the data can constitute an infringement of §19a or §15 II UrhG. When using generative systems that generate synthetic data, for example, which are used to expand a data set with landscape images, the question arises not only about the copyright use of the training data but also about the meaning of copyright for the generated works, if the original work can still be found to a sufficiently high degree in the newly generated images. However, the UrhG is also relevant to the questions of whether the training data collected by a farmer himself, e.g., is worthy of protection in itself, or whether the AI developed by an agricultural machinery manufacturer has copyright protection as such since this cannot usually be formed by the German Patent Act (PatG).

At supranational level, two regulations in particular play a significant role for developers and users of AI systems. On the one hand, the Data Act is particularly relevant for agriculturally used AI, although its scope is limited to non-personal data (see Art. 1 III Data Act). In this area, however, it enables significantly simplified data transmission but also imposes obligations on the manufacturers of AI systems that process data for their part, as they will also have to make this data usable for third parties in the future. For agricultural AI systems, this could play a role in the context of weather data, for example, so that under the Data Act, this data could be significantly more accessible. Art. 3 Data Act states that, on the other hand, data must also be processed by the AI system in a manner that is accessible to third parties. The AI Act is being finalized at European level, representing the first specific AI regulation developed by a legislator. Part of the AI Act is a risk-based categorization of AI systems, which imposes different requirements depending on the risk to safety and fundamental rights of shareholders. Systems in agriculture are not explicitly named as high-risk systems in Annex III, but they can qualify as such if they are used as security components in one of the products listed in Annex II, according to Art. 6 I lit. b AI Act. Here, however, there is the restriction that according to Art. 2 II AI Act, AI systems used in agricultural machinery according to Regulation (EU) No. 167/2013 are only subject to the regulations of the AI Act to a limited extent. In the future, however, it can be expected that the corresponding harmonization standards of the EU, which impose requirements on agricultural machinery, will be adapted in such a way that they adopt the regulations of the AI Act. Accordingly, it can be assumed that AI in autonomous agricultural machinery will also have to meet the requirements currently in the AI Act and represent specific requirements for high-risk systems. Parts of these requirements are, among others, certain data governance procedures, logging, and systems for human supervision. In addition to the extensive laws mentioned, many other secondary laws are relevant to agriculture, e.g., the German General Equal Treatment Act (AGG) or various sector-specific regulations, such as for keeping farm animals.

## **2.2 Tools to support legal decision-making**

Techniques used for legal decision-making can be grouped under the term legal tech [Wa20], whose primary purpose is to facilitate particularly time-consuming and cost-intensive tasks [RV19; Wa20]. Although the approach of legal tech to date has also been to facilitate access to law, this approach is limited only to facilitating indirect access for third parties to persons who enable the exercise of law on their behalf [Wa20]. In the domain of legal tech, the online libraries Juris and Beck-Online are essential in the German market [MW07]. Although these websites make it considerably easier to access a large number of legal commentaries and case law, the access costs for the solutions are very high and, therefore, the sites are not very accessible to a broad public, especially not to full-time lawyers. Other legal tech solutions are mainly in the domain of digitizing access to legal advice through comparison and evaluation portals, although the majority of technological development is to be found in the digitization of internal law firm processes [Wa20]. Few tools allow individuals to gain deeper insight into specific legal issues in academia or the

free market. The only tools that exist are those that enable individuals to file a class action in an easier way [RV19]. However, developing Large Language Models (LLM) also significantly dislocates legal decision-making tools [Ch23; Pe23].

In contrast to the legal tech tools mentioned so far, LLM offers the possibility of being used by people who are not primarily active in the legal field. In particular, the intuitive use of communication with these tools [Ka23] allows access to core legal topics to people who previously had no connection to the relevant issues. However, applying LLM poses several problems [Ha23; Ni23] that have not yet been addressed. Liability issues, in particular, are primarily unresolved in using AI systems, inhibiting the development of these technologies. In this respect, no LLM solutions are specifically tailored to the legal sector, so experience with them is limited to ChatGPT [Ch23; Li23].

### **3 Methodology**

A progressive web app (PWA) will be used primarily on mobile devices and computers to implement the app-based legal verifications. The app aims to use the information the user requests to provide advice on areas where legal problems could arise. The goal of the application is not to offer binding legal advice. Instead, the user should be trained as early as possible in the development process of the AI where legal problems could exist to solve them later in a targeted manner or to implement solutions intuitively.

The app is structured to cover as many areas of law relevant to AI in agriculture as possible, especially those described in Section 2. The assessment simulates the usual course of subsumption of the facts in jurisprudence. In the first step, comprehensive information is gathered from users in a framework that is as short and comprehensive as possible. If the app determines that the scope of specific laws is opened due to the information and, in addition, a violation of a right, law, or regulation is in question, it is finally examined whether there is a justification for this violation. The app will provide the user with comprehensive information on the breach if such a violation does not exist. However, if the information retrieval shows that a breach is legitimized by legal permission, the app will inform the user of this. To avoid the appearance of legal advice, this information is not related to the individual case but has a general character to emphasize the app's sensitization function.

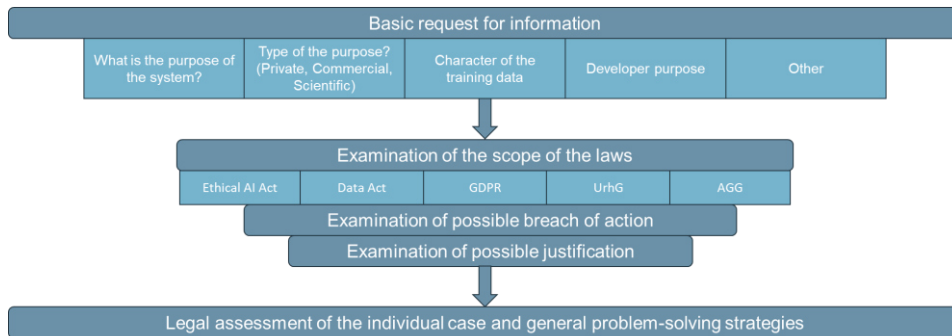


Fig. 1: Process of assessing legal admissibility within the progressive web app. First, information about the app and developer is collected, which is then used for a legal assessment. Ultimately, an individual risk assessment can be carried out, which gives the developer an impression of what legal problems are possible

However, assessing the legality of the AI system is subject to some difficulties. On the one hand, there is the problem that the quality of the evaluation is directly related to the mass of information obtained. However, this problem is very ambivalent. On the one hand, the validity and reliability of the app increase the more extensive the information acquisition phase, but at the same time, the user's willingness to use the app decreases. This problem could be solved by creating an application with many different modules and letting the user select the areas of law he wants to study one by one.

Nevertheless, this leads to overall lengthy information retrieval since a large amount of information, such as the location of the developer's headquarters, would be frequently queried. Instead of following this modular approach, in which specific areas of law are selected initially, the app follows a holistic approach, examining all areas of law from the start while using one question to evaluate multiple legal problems. In this respect, synergies between the areas can be used to assess questions of different regions during information retrieval. The question of the type of use of the AI system's training data exemplifies this. The information obtained can be used to investigate whether a copyright-relevant reproduction according to §15 et seq. of the German Copyright Act has occurred and whether a processing according to Art. 4 No. 2 GDPR has occurred. Even though this can significantly reduce the amount of information gathering, this approach also has a drawback.

On the one hand, there is a risk that specific questions will become too complex if they are aimed at assessing different areas of law. On the other hand, the questions are strongly interwoven, and a change in the legal situation makes the application conversion time-consuming. A problem independent of the system structure is that the user is inevitably confronted with legal terms that often seem confusing in some places. Many terms are



close to each other at first glance or include exceptional cases that are not obvious to untrained persons. This problem is initially solved by providing answer options that are as concrete and distinct from each other as possible. In addition, information fields are included in some selected places, which explain a legal term in question to the user in simple wording.

Figure 2 shows an example of how complex the user can query legal issues in a simple way without the need for technical terms. The user first defines the scope of the inquiry by selecting, for example, that only the data set of the AI is to be examined. If the app concludes, as shown in Figure 2 (c), that a violation has occurred but is covered by a legal norm, it informs the user of the scope of action in which the data can be used without causing a legal violation.

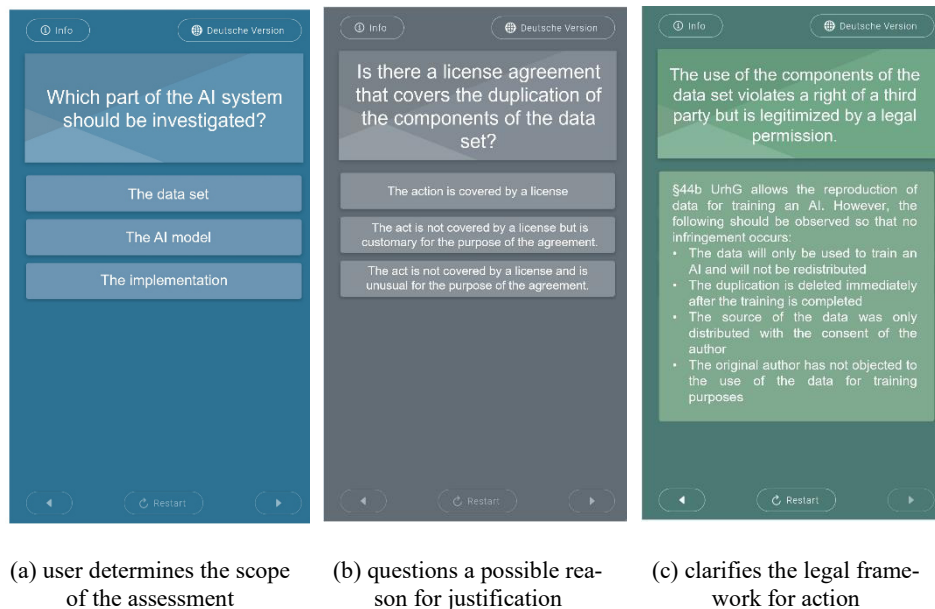


Fig. 2: Screenshots of the progressive web app for legal verification throughout the development. Questioning and assessment of legality through intuitive user information where (a) to (c) is the guided dialog for the users

No representative user test could be carried out within the scope of this work. Instead, the app was presented to two groups of experts, who then completed a system usability scale (SUS) [BKM08; Br96]. One of the groups consisted of five experts who worked with AI systems in the computer science domain; the other group of experts had extensive legal knowledge in digitalization law or worked in this area. The expert group of computer sci-

entists all work in software development and have extensive technical experience in implementing AI solutions. The group of legal experts have particular expertise in the field of copyright law and other relevant areas of law, such as data protection law. This qualitative survey aimed to determine whether the app is legally correct and coherent, but at the same time whether it is formulated simply enough not to deter developers and provide valuable legal assistance. The subjects will act out a legally problematic use of an agricultural AI system within the user task and apply the app to this use case. After using the app, the group of experts who work with AI systems in the computer science domain were asked to fill out the SUS and express their experiences with the app. The group of people with legal knowledge was not questioned by means of a SUS but was asked by qualitative questioning [B113; SB02] whether the assessment of the facts was correct.

Within the framework of the SUS, the experts had to evaluate the user-friendliness on the one hand and the applicability of the app, which is represented by ten different questions, each of which can be evaluated with one of five Likert scales. The answers range from “strongly agree” to “disagree strongly”. The questions of the SUS are based on the classic structure of this test procedure [Br96], but have been adapted in some places. To investigate the app's user-friendliness, the experts had to state, among other things, whether they would also like to use the app in the future and whether the app's system was structured unnecessarily complex. To measure the actual added value in terms of making developers aware of legal problems, the experts were also asked whether they could understand the legal terminology and whether the app could provide them with knowledge about a previously unknown legal problem.

## 4 Results and Discussion

The expert group of computer scientists was the first to perform the user test. All experts were able to solve the problem correctly. The results of the SUS were positive. As shown in Figure 3, the app received high scores from all test subjects, with an average score of 82, indicating a high level of usability [BKM08; Br96; Le18]. However, it is essential for the app's added value that it is not only user-friendly but can also help developers in their work by training them in their perception of legal problems. If we look at the question of whether the app could help evaluate the problem, all respondents at least agreed that the app could assist them in solving the specific case. Another critical metric, whether they would like to use the app more in the future, was strongly agreed upon by four out of five respondents and agreed upon by one respondent. Looking at the low scores, there were some difficulties in making certain legal terms clear. For example, one expert gave only a neutral rating on whether the app could present the facts of the case straightforwardly, while the other experts agreed that the app could concisely clarify legal problems. Ultimately, however, participants in the survey strongly agreed that the app had provided new knowledge about the legality of AI that had previously been not known to them.




Fig. 3: Final scores of the individual SUS results for the subjects 1 to 5 on a scale from 0 to 100, where 100 is the best possible rating and 0 is the worst

The qualitative questioning of the expert group of persons with extensive legal knowledge also achieved positive results. Firstly, all the test experts stated that the legal questions were correct in their formulation. In addition, all participants in the expert group found that the specific questions of the test were simply formulated and made little use of legal terminology but were nevertheless correct and suitable for gathering the necessary information and assessing the facts.

Overall, the SUS and the qualitative survey of the respective group revealed that the experts rated the app as positive to very positive, resulting in an average value of 82. The survey of the expert group of lawyers shows that the app can clarify the facts correctly if the user enters the information accurately. A high level of user-friendliness can also be assumed, which is demonstrated by the test with the computer scientists, which also indicates that they can make the correct entries, as the technical terms in question are explained understandably. The questioning of the computer scientists clearly showed that the app could support them in investigating legal problems. The supporting property also indicates that the app could clarify new knowledge for the developers, as they were shown legal problems and solution strategies in the test that were previously unknown to them.

## 5 Conclusion

The first results of the evaluation showed that the progressive web app for legal verification throughout the development significantly added value in the context of the development of AI systems concerning their legality. The evaluation of the computer scientists' subjects group showed that through using the app, all subjects who develop AI systems learned about legal problems they were previously unaware of. The app's aim – to make developers more aware of the legal implications of the AI systems they develop – has been achieved. The evaluation of this user group also showed that the computer scientists were unaware of the specific legal violations and the circumstances under which the use of training data, for example, is subject to legal permissions and is, therefore, legally permissible. Consequently, the aim of the app can also be realized to reduce the probability of restructuring the AI system in the evaluation phase by showing developers at an early stage and providing them with the knowledge of which uses are legally permitted under which conditions.

The evaluation with the expert group of lawyers mainly checked that the respective questions were legally correct. The subjects' comments here revealed that the app simplifies complex legal questions to an appropriate but correct factual situation because it primarily serves training purposes and not advisory purposes. However, concerns were expressed that extending the app to various areas of law could lead to long questions that might have to be split up and prolong the information retrieval. The evaluation of the expert group of lawyers also showed that this user group could also benefit from such an app, as the topic of AI is also very demanding for lawyers due to its technicality.

In summary, the user evaluation highlighted the app's potential to develop AI-based systems in agriculture. The set aims of the application, to train developers on the legal issues of AI in agriculture and to promote the development of legitimate AI, could be realized exemplarily on the UrhG, as shown by the results of the qualitative interviews. Further work now consists of conducting a representative usability test and expanding the app to include other areas of law, such as GDPR, EU AI Act, Regulation (EU) 2023/1230 for machines, and others.

### Bibliography

- [BKM08] Bangor, A.; Kortum, P.T.; Miller, J.T.: An Empirical Evaluation of the System Usability Scale. *International Journal of Human-Computer Interaction* 24(6), p. 574-594, 2008.
- [Bl13] Blandford, A. E.: *Semi-structured qualitative studies*. 2013, Interaction Design Foundation: Denmark, 2013.
- [Br96] Brooke, J.: SUS: A quick and dirty usability scale. *Usability evaluation in industry*, 3, p. 189-194, 1996.

- [Bu23] Busche, D.: Einführung in die Rechtsfragen der künstlichen Intelligenz. *Juristische Arbeitsblätter*, 6, p. 441-446, 2023.
- [Ca20] Carmela Annosi, M. et al.: Digitalization in the agri-food industry: the relationship between technology and sustainable development. *Management Decision*, 58(8), p. 1737-1757, 2020.
- [Ch23] Choi, J.H., et al. : ChatGPT goes to law school. SSRN preprint 10.2139/ssrn.4335905, 2023.
- [El19] Eli-Chukwu, N. C.: Applications of Artificial Intelligence in Agriculture: A Review. *Engineering, Technology & Applied Science Research*, 9(4), p. 4377-4383, 2019.
- [Fi19] Finley, T. K.: The Democratization of Artificial Intelligence: One Library's Approach. *Information Technology and Libraries*, 39(1), p. 8-13, 2019.
- [Ga18] Garvey, C.: A Framework for Evaluating Barriers to the Democratization of Artificial Intelligence. In *Proceedings of the AAAI Conference on Artificial Intelligence*, 32(1), 2018.
- [Ge21] Geminn, C.: Die Regulierung künstlicher Intelligenz. *Zeitschrift für Datenschutz*, 7, p. 354-359, 2021.
- [Ha20] Hacker, P.: Europäische und nationale Regulierung von Künstlicher Intelligenz. *Neue Juristische Wochenschrift*, 30, p. 2142-2147, 2020.
- [Ha23] Hartung, M.: Smartlaw, ChatGPT und das RDG. *Recht Digital*, 5, p. 209-217, 2023.
- [Ka23] Kasneci, E., et al.: ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, p. 102274, 2023.
- [Le18] Lewis, J.R.: The System Usability Scale: Past, Present, and Future. *International Journal of Human-Computer Interaction*, 34(7), p. 577-590, 2018.
- [Li23] Li, Z.: The Dark Side of ChatGPT: Legal and Ethical Challenges from Stochastic Parrots and Hallucination. arXiv preprint arXiv:2304.14347, 2023.
- [Ma17] Makridakis, S.: The forthcoming Artificial Intelligence (AI) revolution: Its impact on society and firms. *Futures*, 90, p. 46-60, 2017.
- [MW07] Mielke, B.; Wolff, C.: Juristische Informationskompetenz: Freie Quellen im WWW vs. professionelle Informationsdienste. *Tagungsband des 10. International Legal Informatics Symposium*, 2007.
- [Ma20] Madaio, M.A., et al.: Co-Designing Checklists to Understand Organizational Challenges and Opportunities around Fairness in AI. In *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, p. 1-14, 2020.
- [Ni23] Nickl, A.: ChatGPT als Rechtsdienstleister. *Multimedia und Recht*, 5, p. 328-333, 2023.
- [Pe23] Pettinato Oltz, T.: ChatGPT, Professor of Law. SSRN preprint 10.2139/ssrn.4347630, 2023.
- [RV19] Rehder, B.; Van Elten, K.: Mobilisierung von Recht durch Legal Technologies *Handbuch Digitalisierung in Staat und Verwaltung*. Springer Fachmedien, Wiesbaden, p. 1-10, 2019.

- [SB02] Sandelowski, M.; Barroso, J.: Finding the Findings in Qualitative Studies. *Journal of Nursing Scholarship*, 34(3), p. 213-219, 2002.
- [SF23] Sadjadi, E.N.; Fernández, R.: Challenges and Opportunities of Agriculture Digitalization in Spain. *Agronomy*, 13(1), p. 259, 2023.
- [SWT23] Schöning, J.; Wachter, P; Trautz, D.: Crop rotation and management tools for every farmer?: The current status on crop rotation and management tools for enabling sustainable agriculture worldwide. *Smart Agricultural Technology*, 3 p. 100086, 2023.
- [SR21] Schöning, J.; Richter, M.L.: AI-based crop rotation for sustainable agriculture worldwide. In *2021 IEEE Global Humanitarian Technology Conference*, IEEE, p. 142-146, 2021.
- [Sh21] Sharma, R.: Artificial Intelligence in Agriculture: A Review. In *2021 5th International Conference on Intelligent Computing and Control Systems*, IEEE, p. 937-942, 2021.
- [Va16] Varghese, B., et al.: Challenges and Opportunities in Edge Computing. *2016 IEEE International Conference on Smart Cloud*, p. 20-26, 2016.
- [Va23] Vasel, J.J.: Künstliche Intelligenz und die Notwendigkeit agiler Regulierung. *Neue Zeitschrift für Verwaltungsrecht*, 17, S. 1298-1303, 2023.
- [Wa20] Wagner, J.: *Legal Tech und Legal Robots: Der Wandel im Rechtswesen durch neue Technologien und Künstliche Intelligenz*. Springer Fachmedien, Wiesbaden, 2020.
- [We20] Wennker, P.: *Künstliche Intelligenz in der Landwirtschaft*. Springer Fachmedien, p. 141-149 Wiesbaden, 2020.

## Non-behavioral variables on the acceptance of AI-based camera systems

### A contextual analysis of acceptance among German pig farmers

Alexander Kühnemund<sup>1</sup> and Guido Recke<sup>1</sup>

**Abstract:** This study investigated the contextual factors for the acceptance of AI camera technologies. For this purpose, 185 pig farmers were interviewed in an online survey. The regression model investigated whether technology acceptance is influenced by the variables age, education, region, digitalization experience, and farm size. The statistical analysis showed that a higher perceived level of digitalization on the farm and the geographical location of the farm are predictors of technology acceptance. This shows that acceptance, and thus adoption, is determined by factors other than behavioral ones.

**Keywords:** AI, surveillance, camera, pig, observation, technology acceptance

## 1 Introduction

Technologies supported by artificial intelligence (AI) are entering almost all parts of our society. The enhancement of sustainability can be supported by such digital solutions and therefore technologies are also tested and used in precision pig farming. In precision livestock farming (PLF), camera-based AI technologies are increasingly developed to monitor and assess animal behavior [Ar21; BX22]. Research in implementing such technologies has produced some promising methods to support farmers. This varies from camera-based intelligent climate interpretation [Na17] and control to liveweight monitoring [Ka14; TGB22] to early warning systems for diseases [Ma17] – the range of applications is diverse. These systems are suitable for autonomous monitoring and interventions in the barn as well as for supporting the farmer in barn management. The aim of these support functions of AI camera systems is to provide farmers with the information they need to make decisions and improve overall farm management. Such technologies can be categorized as intelligent management systems that focus on the individual needs of animals [Jh19].

However, like all systems that support management, they must also be used by the users. Only in this way can the technologies develop their full potential and as promising as some approaches are, the acceptance of such technologies by farmers in their own stables is still

---

<sup>1</sup> Hochschule Osnabrück, Fachgebiet Landwirtschaftliche Betriebslehre, Oldenburger Landstraße 24, 49090 Osnabrück, alexander.kuehnemund@hs-osnabrueck.de

questionable. In addition to the behavioral factors that are investigated in technology acceptance models, like perceived ease of use, perceived usefulness, and explain a part of the acceptance, other influencing variables also play a role in whether acceptance exists or not [ASG12]. These parameters include both determinants of the individual, such as age and gender, and attributes assessed by the individual themselves or their company. Especially in relation to AI-based visual surveillance, there is a gap in understanding which factors, besides behavior, explain the acceptance or rejection of such technologies. For technology adoption, German farmers are considered as pioneers in the field of smart farming [RKR20]. However, especially in animal husbandry, the adoption and acceptance of artificial intelligence is underexplored [RM22]. Previous research investigated the potential adoption and acceptance of different smart farming technologies. For example, Michels et al. (2021) investigated the intention to use drones in agriculture including the role of contextual factors due to the acceptance. According to smart technologies in livestock farming, another research team investigated in their cluster analysis the importance of different personal and environmental factors that determine the readiness for smart technologies [SH21]. However, the intention to use AI-camera systems as a specific surveillance technology still needs to be explored. The identification of drivers, barriers and demographic factors that influence the acceptance is of great importance for the development of AI-based cameras. In addition, the knowledge about it will improve the development of market-ready systems adjusted for the needs of the users. AI and camera surveillance are both critical objects of investigation on their own, due to the visual observation and possible interpretation of animals and humans. Therefore, this research provides information on the contextual factors of such systems in terms of the anticipated framework conditions. The main objective of this study is firstly to derive possible factors of influence theoretically and, in a second step, to empirically evaluate the contextual determinants of the acceptance of AI camera systems for livestock farmers.

## **2 Theoretical Framework and Hypothesis Deviation**

Several studies investigated the technology acceptance in models explaining the user's attitude towards the intention to use [Mi21; MK219]. But beside the behavioral factors, contextual factors emerge that may promote or hinder the potential adoption of technology. A technical ability to use the technology must be given. Otherwise, the potential acceptance is just a concept without the ability to use it. For example, the use of mobile technology such as smartphones depends not only on factors such as utility or expected ease of use. It also depends on the network coverage that enables the technology to be used in the first place. A potential user may be receptive to the technology, i.e. have a high level of acceptance but in order to draw conclusions about usage it is also necessary to consider whether usage is possible at all. The example of the smartphone shows that without sufficient knowledge of the mobile internet, adaptation does not make sense. The assessment of the acceptance of AI camera systems was gauged using three factors. These metrics were adapted from [Mi21] concerning the use of drones in contemporary agriculture and a study regarding the acceptance of AI systems in agriculture [MK21]. The



questions were adjusted to align with the objectives of this study. Acceptance indicates the intention to use a technology, derived from the technology acceptance model [Da89].

At the individual level, there are two main factors that determine the possible rejection or acceptance of technology. The first factor is the age of the person who decides to adopt the technology. Literature assumes that with increasing age, the rate of adoption of new technologies decreases [Va20]. Especially in a working context, age hinders the adoption of new or improved technologies in operating processes [Me11]. The second individual-level determinant is educational status. People with higher education use internet services and smart technologies more often [St22] from which it is possible to deduce that higher educated persons tend to be more accepting of new technologies. In summary, these potential factors can be summarized as the following hypotheses defining the personal characteristics.

*H1: Younger age has a positive influence on the acceptance of AI camera systems.*

*H1a: Higher education has a positive effect on the acceptance of AI camera systems.*

At farm level, there are other factors affecting farmers that can influence the adoption of technologies. For example, larger farms tend to be more adaptable to technology [LX06; Na23] due to various factors such as costs or organizational structure. Especially in the early stages of technologies, the adoption rate of large farms is higher [LX06]. In the livestock sector, several factors can be used to measure the size of the holding. Depending on the structure and type of farm, the number of animals and the size of the farm in hectares can provide information on the size structure. An examination of these variables leads to the following two hypotheses:

*H2: A higher number of animals has a positive effect on the acceptance of AI camera systems.*

*H2a: A high level of land ownership in hectares has a positive influence on the acceptance of AI camera systems.*

In addition, it can be assumed that not only the size of the farm has an influence, but also whether it is engaged in agriculture in addition to livestock farming. Farmers in Germany are at the forefront of adopting new technologies [RKR20], but the majority of precision farming technologies in use are in the field of arable farming and agricultural machinery [GG23]. Therefore, this variable can indicate whether there is an openness to new technologies as kinds of technologies are already used in other parts of the enterprises' own value creation. This leads to the following hypothesis:

*H3: Arable farming has a positive impact on the acceptance of AI monitoring systems in pig production.*

Among the most important contextual variables in the adaptation of AI camera systems are the factors that enable their use. In this case, the questionnaire asks for the level of digitization on the farm. The higher the level of digitization in a company, the more likely aspects of handling, such as complexity and reliability, are seen as an obstacle [GG21]. Without a sufficient level of digitalization in other areas of the farm, the conditions for adapting AI surveillance technologies in the barn are rarely fulfilled. Thus, the hypothesis regarding the appropriate adoption possibility is as follows:

*H4: A high level of perceived digitalization on the farm has a positive effect on the acceptance of AI camera systems.*

The last factor that can have a contextual impact on the adoption of AI camera systems is the location of the farm. The location of the farm has historical, infrastructural and societal influences on farmers that determine potential adoption. Farm structures vary greatly from region to region in Germany [WB11]. This is likely to be related to the acceptance of such technologies. Therefore the hypothesis is derived as follows:

*H5: The geographical location of the farm has an influence on the acceptance of AI camera systems.*

### **3 Material and Methods**

#### **3.1 Study design and structure of the questionnaire**

The questionnaire was distributed through an agricultural panel to reach a sufficient number of pig farmers throughout Germany. This selection also ensured that the survey was only addressed at the target group. The survey was carried out between January and March 2023. The part of the survey used for this study asked participants about socio-demographic, individual and farm-specific factors as well as for their technology acceptance. A written description of AI camera systems was presented to the farmer to elicit acceptance of the subject of the study. This description characterizes the functionality and possible applications of the camera systems. This was used for better understanding and classification of the technology. Acceptance was measured using three variables. The acceptance statements were assessed using a five-point Likert scale, ranging from 1 = do not agree to 5 = fully agree. This survey was conducted as part of an investigation into a technology acceptance model that examines behavioral and contextual factors. In this study, only the contextual factors are considered because there is still a research gap in this area.

#### **3.2 Statistical analysis**

For the statistical analysis of the effect of contextual factors on the acceptance of AI camera systems, the target variable acceptance was formed as a sum score of the three manifest variables (0 = no acceptance to 100 = total acceptance). First, descriptive analyses were performed and contingency tables were calculated to consider the correlations between two dichotomous variables. A t-test for independent samples and univariate variance analyses/ANOVA were performed to determine differences in means. On the one hand, the variance analyses were used to calculate the level of technology acceptance as a function of region, level of education and farming method. On the other hand, significant differences in farm size and region should be identified to support the interpretation of the results. For nominal scaled variables with more than two values, dummy variables were

created for the regression model. A multiple linear regression was calculated to determine the relationship between contextual factors and technology acceptance (dependent variable). The independent variables resulted from the theoretical derivation: age, education, farm size (ha), farm size (number of animals), level of digitalization, internet access, region, and arable farming. The examination of the prerequisites revealed that all independent variables can be included in the regression model. The significance level was set at  $\alpha < 0.05$ . The statistical calculation was done with IBM SPSS Statistics 22.0.

#### 4 Results


At the end of the survey, 185 people had completed the questionnaire. The gender distribution in the survey was 90.7% male and 9.3% female. The average age of the respondents was 43.5 years. A large proportion of respondents had a high level of education. The sociodemographic data are shown in Table 1.

| <b>N=185</b>                                  |                 |
|---|-----------------|
| Gender, N (%)                                 |                 |
| <i>Female</i>                                 | 17 (9.2)        |
| <i>Male</i>                                   | 166 (89.7)      |
| <i>Other</i>                                  | 2 (1.1)         |
| Age [in years], mean (range)                  | 43.5 (20-72)    |
| Vocational education, N (%)                   |                 |
| <i>No formal agricultural degree</i>          | 12 (6.5)        |
| <i>Vocational or technical school</i>         | 126 (68.1)      |
| <i>University degree</i>                      | 47 (25.4)       |
| Number of animals, median (Q1-Q3)             | 1350 (469-2590) |
| Number of acres [in hectares], median (Q1-Q3) | 85 (50-130)     |

Legend: N: number, Q1 – Q3: interquartile range (25%; 75%)

Tab. 1: Sample description

In the sample, a median acceptance of 75 points (Q1-Q3: 50-91.67) is reported. The level of digitalization on the farm is rated as good or very good by a third (35.1%), as bad or very bad by 7.6% and as average by the majority (57.3%). A quarter of respondents do not have access to a fast internet connection (25.9%). Half of the respondents agree or strongly agree that they have access to fast internet on their farm. The remaining 23.8% are undecided about their own access to broadband internet. The three variables on the acceptance of AI camera systems were answered positively by the majority (56%–64%, agree or rather agree). The exact response behavior is shown in Figure 1.



Legend: AC1: I can imagine observing my animals additionally with cameras; AC2: I can imagine using cameras on my farm in the future.; AC3: I can imagine using cameras on my farm.

Fig. 1: Frequencies of the three variables for technology acceptance

The regression analysis shows that the variables used in the procedure statistically significantly predict the predictor acceptance  $F(9, 174)=2.431$ ,  $p = 0.013$ . However, the model as a whole has only a low goodness of fit with an  $R^2=0.112$  (corrected  $R^2 = 0.066$ ) [Co88]. Table 2 shows the detailed results of the regression and the characteristics of the individual variables.

|                         | B       | SE     | $\beta$ | T      | p    | 95% CI      |             |
|-------------------------|---------|--------|---------|--------|------|-------------|-------------|
|                         |         |        |         |        |      | Lower bound | Upper bound |
| Age                     | -.077   | 0.183  | -.033   | -.422  | .674 | -.439       | .284        |
| Farm size (ha)          | .006    | .006   | .077    | .945   | .346 | -.007       | .019        |
| Farm size (no. animals) | .000    | .001   | -.027   | -.344  | .731 | -.002       | .001        |
| Arable farming yes/no   | 7.360   | 4.882  | .112    | 1.508  | .133 | -2.275      | 16.995      |
| Digitalization          | 6.096   | 3.075  | .146    | 1.983  | .049 | .027        | 12.165      |
| Education               | 3.367   | 4.144  | .061    | .813   | .418 | -4.811      | 11.546      |
| Region: East            | -1.582  | 13.584 | -.010   | -.116  | .907 | -28.394     | 25.229      |
| Region: West            | -2.530  | 5.699  | -.036   | -.444  | .658 | -13.778     | 8.718       |
| Region: South           | -13.961 | 5.192  | -.229   | -2.689 | .008 | -24.209     | -3.712      |
| Constant                | 40.749  | 17.070 | 2.387   | 2.387  | .018 |             |             |

Legend: B: unstandardized coefficient B,  $\beta$ : regression coefficient, p: p-Value, SE: standard error, t: t-Value, CI: confidence interval. The variable "region: North" was used in the model as a reference category for the dummy variables.

Tab. 2: Results of the regression model

The analysis showed that the perceived digitalisation of one's own company has a statistically significant influence ( $p=0.049$ ) on the acceptance of AI camera systems. Therefore, hypothesis H4 can be confirmed. The higher the level of digitization in the company, the higher the acceptance of the technology. In addition, the region was found to have a statistically significant influence on acceptance. In relation to the reference variable region North, farmers in the South have a significantly lower acceptance ( $p=0.008$ ). Farmers from Southern Germany give an acceptance value of 55.6, while in Western Germany (69.3), Northern Germany (70.1) and Eastern Germany (72.2) there is a significantly higher acceptance. However, there are also large differences between the German regions with regard to the farm properties. While farms in Southern Germany have an average size of 84 ha, farms in the West and the North have 113 ha and 119 ha, respectively, while the eight farmers from Eastern Germany report a size of 1031 ha. For the other contextual factors, there was no significant influence on the acceptance of AI camera systems. The factors age, education, farm size at both measured levels and relevance of farming activity show no relevant influence in this model. Therefore, the hypotheses cannot be confirmed. However, a separate analysis of the independent samples t-test shows that farmers who also practice arable farming have a ten-point higher acceptance of AI camera systems, which reveals an underlying trend but did not become significant in the model.

## 5 Discussion

The aim of this research was to identify potential factors which influence the acceptance of AI camera systems outside the behavioral level. Considering these factors, it is necessary to explain acceptance because behavior-based acceptance models only explain a part of the potential adaptation. Studies that have investigated the behavior-based acceptance phenomenon in agriculture have often found a moderate explanation only. By adding contextual and personal factors, some of the unexplained variance can be clarified.

The respondents in this survey represent the German average in terms of age with a majority of 53.1% aged between 35 and 54 [Fe23]. The gender distribution in this survey is strongly dominated by men (90.3%). This differs from the average gender distribution in Germany where around a third of employees are female. However, as this study was primarily aimed at decision-makers on farms, the distribution in this group is in line with the German average [St23]. In terms of the education of the respondents, farmers with a professional education are over-represented. In a survey by the German Ministry of Agriculture, around 80% of farmers had a vocational or higher level of education [Fe20]. However, the discrepancy between the representative survey and this sample can also be explained by the target group of decision-makers.

The rapid development of precision livestock farming makes it necessary to analyze the willingness to use such technologies. Under the umbrella of such systems, it is also important to examine each technology in detail, as each feature is valued differently by

potential users. It is undisputed that the behavioral factors in technology acceptance models are methodologically well suited to the potential adoption of technologies. However, this study has shown that there are other factors which influence acceptance. This has been shown in other research on new technologies. The use of smartphones is strongly influenced by personal factors and farm characteristics in smartphone adoption [Mi20]. [He17] describe in their research the importance of data visualization for adopting new smart technologies beside the behavioral factors. Together with this study, the research findings show the importance of looking beyond established models.

The regression model identified the previous digitalization (H4) on the farm as an important factor. As other acceptance research studies have shown, previous experience with technology is a factor that has a positive influence [MH06]. In this case, the own digitalization shows a higher openness towards the new technology. This is often mentioned as a moderating variable in connection with the benefit assessment and the simplicity of the technology to be used [AW15]. However, this effect could not be demonstrated in all studies. In addition, the assessment of the digitalization of the person is a subjective parameter. This variable cannot be operationalized easily because it depends on the context of the subject of the study and the individual's own perception may differ from an objective measurement. However, since different degrees of digitalization in the subjective assessment reflect the digital competencies of the company, this factor is still useful for the provision of new AI technologies. The second factor influencing acceptance is the region (H5). However, this variable should not be considered as a mere geographic predictor. It should be noted here that the distribution of companies corresponds to the general distribution, but only a small number of companies from Eastern Germany are included in the analysis (N=6). Geographic location is a moderator of adoption for a variety of possible predictors. For example, farms differ in structure, size, and type of operation, as does the structure of decision makers in each region.

Another important finding comes from the fact that the hypotheses formulated cannot be confirmed for several variables. In particular, the age of the respondents did not play a role in the acceptance of the technology. In their study, [Ve03] showed the moderating effect of age on technology acceptance (H1). [Ho13], on the other hand, did not describe the effect of chronological age but of cognitive age on acceptance. Both studies showed an indirect influence of age on the acceptance of technologies. In this study, this effect could not be demonstrated. It could be assumed that age per se is becoming less and less important after decades of rapid digitization. Moreover, the studies in which age still played a role are already outdated in context of agricultural technology adoption. Furthermore, farm size is not relevant to the adoption of AI camera systems in this study (H2, H2a). This may be due to the fact that in the case of AI camera systems, economies of scale are not the main driver of acceptance. Other interests such as labor savings, animal welfare, or management benefits may be considered as reasons for acceptance or rejection. The study of pig farmers only has a limiting effect in terms of generalization. Like all forms of livestock production, pig production has its own characteristics that are not shared by other livestock producers. Therefore, the generalizability of the results to other

livestock producers is limited. The transferability of the results to other countries is also limited. Cultural peculiarities and different legal and infrastructural possibilities for digitalization are often only applicable to German farmers. In addition, the results must be viewed in the light of the fact that the survey is an online survey. Firstly, people who were not part of the panel had little opportunity to participate and secondly, there is a possibility that more technophile individuals took part in the survey (selection bias). Despite the limitations, this study contributes to the understanding of the acceptance of AI monitoring systems in barns. As these are sensitive technologies, this is an important aspect for development and marketing. In general, however, there is a high acceptance of AI camera systems for the observation of animals in this sample. In addition, this knowledge promotes successful implementation and gives companies, policy makers, and regulators important clues for evaluation. Future development should consider the specificities of individual farms. In addition, companies should be enabled to digitize themselves in order to better implement new technologies in the market.

## 6 Conclusion

The goal of this study was to explain the acceptance of AI camera systems in addition to behavioral factors. It was shown that contextual and individual factors of individuals and companies also influence the intention to use them. Furthermore, the regression model analyzed which non-behavioral factors do not influence acceptance. In summary, this can help in the development of new technologies and their successful implementation in the market. Artificial intelligence in general and in animal monitoring in particular has a great potential to support animal owners. However, success depends on the acceptance of potential users. For future research, the behavioral factors of the survey will be examined to gain a better understanding of the acceptance of such systems.

### Bibliography

- [AW15] Alomary, A., Woollard, J.: How is technology accepted by users? A review of technology acceptance models and theories. The IRES 17th International Conference, 2015.
- [Ar21] Arulmozhi, E. et al.: The Application of Cameras in Precision Pig Farming: An Overview for Swine-Keeping Professionals. *Animals*, 11(8), 2021.
- [ASG12] Aubert, B. A., Schroeder, A., & Grimaudo, J.: IT as enabler of sustainable farming: An empirical analysis of farmers' adoption decision of precision agriculture technology. *Decision Support Systems*, 54(1), 510-520, 2012. <https://doi.org/10.1016/j.dss.2012.07.002>
- [BX22] Bao, J., Xie, Q.: Artificial intelligence in animal farming: A systematic literature review. *Journal of Cleaner Production*, 331, 2022. <https://doi.org/10.1016/j.jclepro.2021.129956>

- [Co88] Cohen, J.: *Statistical power analysis for the behavioral sciences* (2nd ed ed.). L. Erlbaum Associates Hillsdale, N.J., 1988.
- [Da89] Davis, F.D.: Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. *MIS Quarterly*, 13(3), 319-340, 1989. <https://doi.org/10.2307/249008>
- [Fe20] Federal Ministry of Food and Agriculture: *Arbeitsmarkt Landwirtschaft in Deutschland - Aktuelle und zukünftige Herausforderungen an die Berufsbildung*. Bundesministerium für Ernährung und Landwirtschaft, 2020.
- [Fe23] Federal Ministry of Food and Agriculture: *Altersgliederung der landwirtschaftlichen Betriebsinhaber*. <https://www.bmel-statistik.de/landwirtschaft/tabellen-zur-landwirtschaft>, Stand: 26.10.2023
- [GG23] Gabriel, A., Gandorfer, M.: Adoption of digital technologies in agriculture—an inventory in a european small-scale farming region. *Precision Agriculture*, 24(1), 68-91, 2023. <https://doi.org/10.1007/s11119-022-09931-1>
- [GGS21] Gabriel, A., Gandorfer, M., Spykman, O.: Nutzung und Hemmnisse digitaler Technologien in der Landwirtschaft. *Zeitschrift für Agrarpolitik und Landwirtschaft*, 99 (1), 2021.
- [Ho13] Hong, S.-J. et al.: How old are you really? Cognitive age in technology acceptance. *Decision Support Systems*, 56, 122-130, 2013. <https://doi.org/10.1016/j.dss.2013.05.008>
- [Jh19] Jha, K. et al.: A comprehensive review on automation in agriculture using artificial intelligence. *Artificial Intelligence in Agriculture*, 2, 1-12, 2019. <https://doi.org/10.1016/j.aiaa.2019.05.004>
- [Ka14] Kashiha, M. et al.: Automatic weight estimation of individual pigs using image analysis. *Computers and Electronics in Agriculture*, 107, 38-44, 2014. <https://doi.org/10.1016/j.compag.2014.06.003>
- [LX06] Lee, G., & Xia, W.: Organizational size and IT innovation adoption: A meta-analysis. *Information & Management*, 43(8), 2006. <https://doi.org/10.1016/j.im.2006.09.003>
- [Ma17] Matthews, S.G. et al.: Automated tracking to measure behavioural changes in pigs for health and welfare monitoring. *Scientific Reports*, 7(1), 17582, 2017. <https://doi.org/10.1038/s41598-017-17451-6>
- [MH06] McFarland, D. J., & Hamilton, D.: Adding contextual specificity to the technology acceptance model. *Computers in Human Behavior*, 22(3), 427-447, 2006. <https://doi.org/10.1016/j.chb.2004.09.009>
- [Me11] Meyer, J.: Workforce age and technology adoption in small and medium-sized service firms. *Small Business Economics*, 37(3), 305-324, 2011. <https://doi.org/10.1007/s11187-009-9246-y>
- [Mi20] Michels, M. et al.: Smartphone adoption and use in agriculture: empirical evidence from Germany. *Precision Agriculture*, 21(2), 403-425, 2011. <https://doi.org/10.1007/s11119-019-09675-5>



- [Mi21] Michels, M. et al.: The adoption of drones in German agriculture: a structural equation model. *Precision Agriculture*, 22(6), 1728-1748, 2021. <https://doi.org/10.1007/s11119-021-09809-8>
- [MK21] Mohr, S., & Köhl, R.: Acceptance of artificial intelligence in German agriculture: an application of the technology acceptance model and the theory of planned behavior. *Precision Agriculture*, 22(6), 1816-1844, 2021. <https://doi.org/10.1007/s11119-021-09814-x>
- [Na23] Na, S. et al.: Firm Size and Artificial Intelligence (AI)-Based Technology Adoption: The Role of Corporate Size in South Korean Construction Companies. *Buildings*, 13(4), 2023. <https://www.mdpi.com/2075-5309/13/4/1066>
- [Na17] Nasirahmadi, A. et al.: A new approach for categorizing pig lying behaviour based on a Delaunay triangulation method. *animal*, 11(1), 131-139, 2017. <https://doi.org/10.1017/S1751731116001208>
- [RKR20] Rohleder, B., Krüsken, B., & Reinhardt, H.: Digitalisierung in der Landwirtschaft 2020. Bitcom, Deutscher Bauernverband, & Rentenbank, 2020. [https://www.bitkom.org/sites/main/files/2022-01/27.04.20\\_digitalisierung-in-der-landwirtschaft-2020.pdf](https://www.bitkom.org/sites/main/files/2022-01/27.04.20_digitalisierung-in-der-landwirtschaft-2020.pdf), Stand: 26.10.2023
- [RM22] Rohleder, B., & Meinel, T. Die Digitalisierung der Landwirtschaft. Bitcom. <https://www.bitkom.org/sites/main/files/2022-05/Bitkom-Charts%20Landwirtschaft.pdf>, Stand: 24.10.2023
- [SH21] Schukat, S., & Heise, H.: Smart Products in Livestock Farming—An Empirical Study on the Attitudes of German Farmers. *Animals*, 11(4), 2021.
- [St22] Statistisches Bundesamt: Private Haushalte in der Informationsgesellschaft – Nutzung von Informations- und Kommunikationstechnologien. 2022.
- [St23] Statistisches Bundesamt: Arbeitskräfte: Deutschland, Jahre, Geschlecht, Altersgruppen, Rechtsformen, Art der Arbeitskräfte, Beschäftigungsumfang. <https://www-genesis.destatis.de/genesis//online?operation=table&code=41141-0027&bypass=true&levelindex=1&levelid=1690281844084#abreadcrumb>, Stand: 20.05.2023
- [TGB22] Taylor, C., Guy, J., & Bacardit, J.: Prediction of growth in grower-finisher pigs using recurrent neural networks. *Biosystems Engineering*, 220, 114-134, 2022 <https://doi.org/10.1016/j.biosystemseng.2022.05.016>
- [He17] van Hertem, T. et al.: Appropriate data visualisation is key to Precision Livestock Farming acceptance. *Computers and Electronics in Agriculture*, 138, 1-10, 2017. <https://doi.org/10.1016/j.compag.2017.04.003>
- [Va20] Vahdat, A. et al.: Would you like to shop via mobile app technology? The technology acceptance model, social factors and purchase intention. *Australasian Marketing Journal*, 29 (2), 187-197, 2020. <https://doi.org/10.1016/j.ausmj.2020.01.002>
- [Ve03] Venkatesh, V. et al.: User Acceptance of Information Technology: Toward a Unified View. *MIS Quarterly*, 27(3), 425-478, 2003. <https://doi.org/10.2307/30036540>

- [WB11] Windhorst, H.-W., Bäurle, H.: Analysen zu Strukturen und Entwicklungen in der Schweine-und Sauenhaltung in Deutschland. ISPA Mitteilungen, 7, 1-59, 2011.

## Explainable AI in grassland monitoring: Enhancing model performance and domain adaptability

Shanghua Liu<sup>1</sup>, Anna Hedström<sup>1,2,3</sup>, Deepak Hanike Basavegowda<sup>1,2</sup> , Cornelia Weltzien<sup>1,2</sup> and Marina M.-C. Höhne<sup>1,3,4</sup>

**Abstract:** Grasslands are known for their high biodiversity and ability to provide multiple ecosystem services. Challenges in automating the identification of indicator plants are key obstacles to large-scale grassland monitoring. These challenges stem from the scarcity of extensive datasets, the distributional shifts between generic and grassland-specific datasets, and the inherent opacity of deep learning models. This paper delves into the latter two challenges, with a specific focus on transfer learning and eXplainable Artificial Intelligence (XAI) approaches to grassland monitoring, highlighting the novelty of XAI in this domain. We analyze various transfer learning methods to bridge the distributional gaps between generic and grassland-specific datasets. Additionally, we showcase how explainable AI techniques can unveil the model's domain adaptation capabilities, employing quantitative assessments to evaluate the model's proficiency in accurately centering relevant input features around the object of interest. This research contributes valuable insights for enhancing model performance through transfer learning and measuring domain adaptability with explainable AI, showing significant promise for broader applications within the agricultural community.


**Keywords:** XAI, deep learning, indicator detection, domain adaptation, grassland monitoring

### 1 Introduction

Grasslands, covering 34% of the agricultural landscape in Europe [Eu20], have recently gained significant attention due to their vital role in conserving local biodiversity, ensuring food production, and impacting ecological processes like water and climate regulation [Be19]. However, these ecosystems have been steadily declining due to intensive agricultural practices, high livestock density, abandonment, and afforestation [Sc22].

The new Green Architecture, integrated into the Common Agricultural Policy (CAP) of the European Union, places increased emphasis on halting the loss of farmland biodiversity through the protection and restoration of landscape features and semi-natural areas, including grasslands [Pe21]. For example, as part of the Green Architecture,

---

<sup>1</sup> Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB), Max-Eyth-Allee 100, 14469 Potsdam, Germany {SLiu; AHedstroem; DBasavegowda; CWeltzien; MHoehne}@atb-potsdam.de,   
<https://orcid.org/0000-0003-1692-2256>

<sup>2</sup> Technische Universität Berlin, Straße des 17. Juni 135, 10623 Berlin, Germany

<sup>3</sup> Understandable Machine Intelligence Lab (UMI Lab), ATB, Max-Eyth-Allee 100, 14469 Potsdam

<sup>4</sup> Universität Potsdam, An der Bahn 2, 14476 Potsdam, Germany

Germany has introduced Eco-Scheme 5 to preserve biodiversity in permanent grasslands. The scheme is a result-based approach to support farmers for their contribution to promoting biodiversity in grasslands. The only decisive factor for the payment of financial incentives is the presence of at least four indicator species typical for the region [Eu23]. While this scheme provides a strong motivation for farmers to improve grassland biodiversity, it also comes with a significant monitoring cost, as manual assessment of indicator species consumes both time and resources. Hence, it is crucial to develop efficient and reliable detection methods for these indicator species, to facilitate broader applications in grassland monitoring.

However, the development of indicator species detection methods poses significant challenges. First, the scarcity of large-scale grassland datasets arises from the labor-intensive and time-consuming nature of data collection and annotation, particularly in wild grassland settings. Second, due to the data distributional shifts, deep learning models initially trained on generic datasets like COCO should be adapted with agricultural data to match the grassland context. Third, the black-box nature of deep learning models impedes the ability of researchers to understand their predictive behaviors, limiting their practicality. Against this backdrop of challenges, our contributions are as follows:

- First, we present an indicator species detection method that harnesses the power of EfficientDet [TPL20] and leverages a grassland dataset proposed by [Ba22], including the data from greenhouse, an experimental grassland, and semi-natural grasslands. To tackle the data distributional shift between generic datasets and grassland scenarios, we investigate the impact of different transfer learning methods on the model performance.
- Second, we reveal the black box characteristic of the deep learning object detection models by applying cutting-edge explainable AI techniques [He23a; Se17; He23b] to the grassland domain. Furthermore, by employing localization metrics [Ko20; TME22], we provide novel insights into model behavior and assess its adaptability to other domains, such as grassland habitats.

## 2 Preliminaries

### 2.1 EfficientDet

EfficientDet [TPL20] models are a family of versatile and efficient object detectors with network parameters ranging from 3.9M to 52M, depending on the number of network layers within each model. For example, EfficientDet-D0, with its shallow layers and minimum network parameter of 3.9M, exhibits the fastest inference speed but relatively low accuracy. As illustrated in Fig. 1, EfficientDet comprises three integral architecture components: (i) a feature extraction network that takes image inputs and produces a series of feature maps derived from various network depths, (ii) a weighted Bi-directional

Feature Pyramid Network (BiFPN), which combines multi-scale feature maps from the preceding network, assigning them weights based on the learned importance, and (iii) a detection head network that employs the input fused feature maps for object detection.

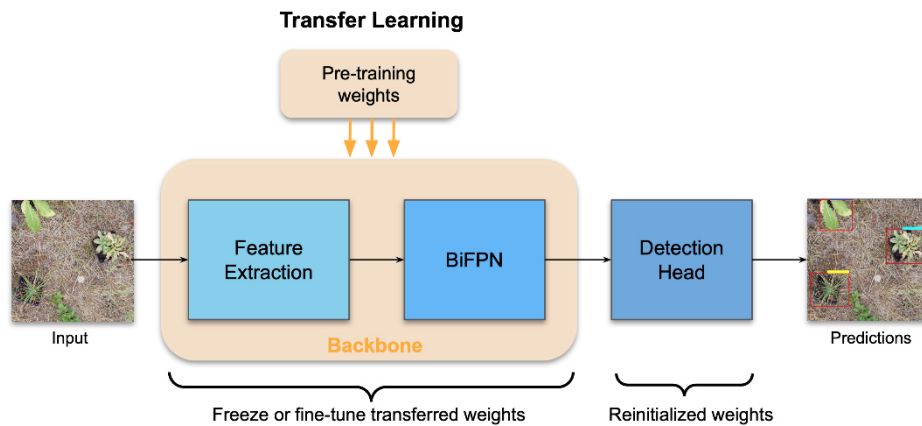


Fig. 1: EfficientDet Architecture (blue) & Transfer Learning Pipeline (orange). From left to right: EfficientDet consists of Feature Extraction Net, BiFPN, and Detection Head Net. From top to bottom: illustration of the transfer learning process where the backbone is initialized with pre-training weights and the detection head is randomly initialized. The transferred weights can be frozen or further fine-tuned with the target dataset

EfficientDet has seen extensive applications in the field of agriculture, spanning tasks such as crop monitoring [Ba21; Ba22; Ca20], plant disease detection [KS21], and pest management [Či23; AU22]. Specifically, [Ba21] applied EfficientDet-D0 to detect vineyard trunks, and the experimental results revealed its superiority over other detection methods like MobileNets [Ho17] and YOLOv5 [Jo21] in terms of both accuracy and running time. For disease detection tasks, [KS21] conducted a comprehensive study using three different benchmark object detection models, including EfficientDet-D2 to automatically detect leaf diseases in apples and grapes. [Či23] harnessed EfficientDet-D4 to detect pest populations in apple production for early damage detection. The wide-ranging applications of EfficientDet in agriculture serve as compelling motivation for our own utilization of EfficientDet for indicator species detection.

## 2.2 Transfer learning

In real-world scenarios, amassing substantial datasets can be challenging due to the labor-intensive and time-consuming nature of dataset preparation. Here, transfer learning enables the use of large deep learning models that were trained on a source domain with extensive dataset, such as ImageNet [De09], comprising 1.2 million images across 1000 categories, and adapted to a target domain with no or limited amount of labeled data.

Hence the underlying principle is to enhance learning within the target domain by leveraging knowledge from a source domain. Fig. 1 illustrates the pre-training and fine-tuning pipeline in the context of transfer learning. In this process, the weights of the backbone layer are initialized with pre-training weights learned from a substantial amount of data in the source domain. In contrast, the remaining layers are initialized randomly. Subsequently, these randomly initialized layers are trained on a relatively smaller target dataset, with the flexibility to freeze or fine-tune the parameters of the backbone layer. Freezing the parameters entails maintaining the pre-training weights unchanged, without updates during the backpropagation process of training. The pretrained weights used in our work were initially trained on the COCO dataset.

[AA22] conducted an insightful investigation into transfer learning in the agricultural domain, introducing a plant-domain-specific dataset, AgriNet. They fine-tuned deep learning models such as Inception [Sz16] and Xception [Ch17], which were initially pre-trained on the ImageNet (source domain), using the AgriNet dataset (target domain). This approach involved freezing the first several layers as fixed feature extractors and randomly initializing the remaining layers. The study demonstrated the substantial performance improvements attainable through transfer learning when classifying 423 plant species, diseases, pests, and weeds. Given the demonstrated potential of transfer learning, our research seeks to investigate how different transfer learning strategies impact model performance in the context of grassland scenarios.

### 2.3 eXplainable Artificial Intelligence (XAI)

In agriculture applications such as cereal plant head detection [Sa23], citrus pest detection [Qi23], and leaf disease recognition [TLN23], the use of artificial intelligence has witnessed a remarkable increase over the past few years. Nevertheless, the pervasive use of deep learning models often presents a challenge: these models operate as enigmatic black boxes, concealing the rationale behind their predictions. In certain contexts, the ability to provide interpretable predictions holds far more significance than the relentless pursuit of accuracy through opaque models [Ru22]. This is where XAI emerges as a pivotal player, endeavoring to augment the interpretability of intricate models while retaining the fidelity of their predictions [CPC19].

Recent advancements in this research domain are exemplified by the works of [We22] and [Ak20]. The former harnessed deep learning models to classify leaf diseases, and the latter focused on the classification of calyx-end cracking in persimmon fruits. Both researchers integrated XAI tools to probe the depths of the models' feature extraction capabilities. However, it is noteworthy that their analysis of attention distribution within inputs remained predominantly qualitative, relying on visualization, without a quantitative evaluation. Quantus [He23a] offers a comprehensive XAI evaluation framework, equipped with quantitative evaluation metrics that provide profound insights into model behavior, delivered in an easy-to-use API. In this paper, beyond offering qualitative visualizations, we take a step forward and pioneer Quantus to species identification. We

mainly focus on the localization metrics, namely *Attribution Localization* [Ko20] and *Top-K Intersection* [TME22], which provide valuable insights into the model's adaptability to other domains. The exploration of additional metrics is reserved for future research work.

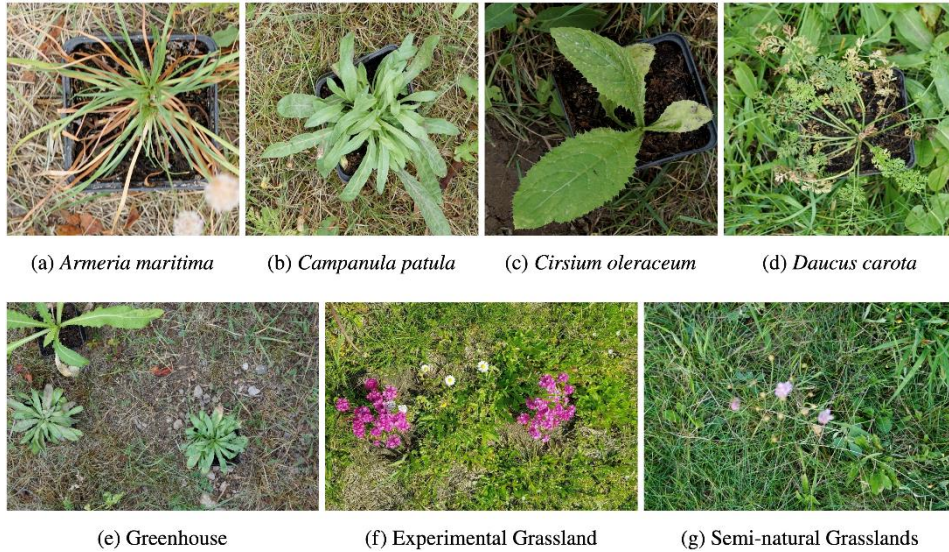


Fig. 2: The dataset consists of four indicator species (a-d) from three different sources (e-g)

### 3 Materials and Methods

#### 3.1 Data and modeling setup

The dataset employed in our experiments was proposed by [Ba22] and their subsequent collection endeavors. This dataset consists of RGB images captured from three different sources: greenhouse, an experimental grassland, and semi-natural grasslands, featuring four indicator species: *Armeria maritima*, *Campanula patula*, *Cirsium oleraceum*, and *Daucus carota*. An overview of the dataset is presented in Fig. 2.

In our experiments, the dataset was randomly divided into three subsets: a training set, a validation set, and a test set, as shown in Tab. 1. This partitioning followed the common distribution practice, allocating roughly 60% for the training set, 20% for the validation set, and another 20% for the test set. We employed a range of data augmentation techniques, including rotation, clipping, and flipping, which infuse the dataset with variations in image viewpoints and orientations, enhancing its diversity.

|                | Semi-natural grassland | Experimental grassland | Greenhouse |
|----------------|------------------------|------------------------|------------|
| Training set   | 2485                   | 2440                   | 7515       |
| Validation set | 529                    | 388                    | 1687       |
| Test set       | 514                    | 401                    | 2043       |
| All            | 3528                   | 3229                   | 11245      |

Tab. 1: Dataset partition for training, validation, and testing

All experiments were executed using 4 NVIDIA Tesla V100 GPUs over 200 training epochs with a batch size of 16. We employed an AdamW [LH19] optimizer with an initiate learning rate of 1e-3, complemented by a learning rate plateau scheduler with a patient threshold of 5. The pretrained weights used in the experiments were initially trained on the COCO dataset.

### 3.2 Metric

**Average Precision (AP)** is the crucial metric that offers a comprehensive evaluation of the model's object detection performance and is employed to determine the challenge winner in datasets like COCO. Calculating AP across all IoU thresholds and across all categories entails two steps:

$$CAP_i = \frac{1}{N} \sum_{k=1}^N CAP_i(IoU_k) \quad (1)$$

Firstly, calculating class average precision at different IoU thresholds in equation (1), where  $CAP_i$  represents the class average precision for class  $i$ ,  $N$  is the number of IoU thresholds, and  $CAP_i(IoU_k)$  denotes the class average precision for class  $i$  at threshold  $IoU_k$ .  $CAP_i(IoU_k)$  value is calculated as the area under the precision-recall curve. We employ the same IoU threshold settings as COCO, ranging from 0.5 to 0.95 with a step size of 0.05 (i.e.,  $N = 10$ ).

$$AP = \frac{1}{C} \sum_{i=1}^C CAP_i \quad (2)$$

Secondly, in equation (2), calculating the overall average precision (AP) by averaging the class average precision (CAP) over all different classes, where  $AP$  represents Average Precision metric and  $C$  stands for the total number of classes.

**Attribution Localization (AL)** [Ko20] measures the ratio of positive attributions within the targeted object to the total positive attributions, computed as follows. Here,  $R_{box}$  is the sum of positive relevance in the bounding box and  $R_{tot}$  is the sum of positive relevance in the image.

$$AL = \frac{R_{box}}{R_{tot}} \quad (3)$$



**Top-K Intersection (TKI)** [TME22] computes the intersection between a bounding box and the binary explanation at the top k feature locations, where pixel-wise intersection is defined as  $TKI$  between the binary bounding box mask  $M$  and the binary mask of top-k features  $E^k$ . Here,  $w$  and  $h$  represent the width and height of the input image.

$$TKI = \frac{1}{k} \sum_{i=1}^w \sum_{j=1}^h M_{ij} \wedge E_{ij}^k \quad (4)$$

We employed GradCAM [Se17] as an explanation tool for model predictions. This assessment involved measuring the alignment of features employed in the model predictions with the ground true position of the target (bounding box).

### 3.3 Methods

**Transfer Learning.** We trained our detection model EfficientDet-D2 with different transfer learning settings: (i) without leveraging pretrained weights; (ii) using pretrained weights with a frozen feature extraction network; and (iii) utilizing pretrained weights with fine-tuning. All these experiments were trained with the combination of three training sets and were uniformly tested on the semi-natural test set. In this paper, we abbreviate semi-natural grassland as sNat, experimental grassland as Expt, and greenhouse data as Green.

**Explainable AI.** In our quest to demonstrate the application of XAI in the field of grassland monitoring, we conducted the following three different experiments, where for each experiment the EfficientDet model was trained on a different dataset: (i) exclusively semi-natural grassland data; (ii) a combination of semi-natural and experimental data; and (iii) an amalgamation of semi-natural, experimental, and greenhouse data. Our primary objective was to gain deeper insights into the decision-making processes of deep learning models in grassland species detection. To this end, we employed Gradient-weighted Class Activation Mapping (GradCAM) [Se17], a technique that reveals the most critical regions in input images influencing the model's prediction.

## 4 Results and Discussion

**Transfer Learning.** The experimental evaluation in Tab. 2 revealed that fine-tuning the model with pretrained weights and without freezing any layers achieved the highest AP of 66.4, AL of 0.828, and TKI of 0.899. Notably, this setting exhibited a remarkable 28% improvement in AP, providing valuable insights for agricultural applications, specifically emphasizing the significance of incorporating pretrained weights and fine-tuning on the agricultural target dataset.

| Transfer Learning Method      | Training / Validation Set | Test Set | AP $\uparrow$ | AL $\uparrow$                    | TKI $\uparrow$                   |
|-------------------------------|---------------------------|----------|---------------|----------------------------------|----------------------------------|
| Freezing pretrained weights   | sNat+Expt+Green           | sNat     | 38.3          | 0.347 $\pm$ 0.09                 | 0.344 $\pm$ 0.21                 |
| None pretrained weights       | sNat+Expt+Green           | sNat     | 57.3          | 0.713 $\pm$ 0.10                 | 0.690 $\pm$ 0.21                 |
| Fine-tuning pretrained weight | sNat+Expt+Green           | sNat     | <b>66.4</b>   | <b>0.828<math>\pm</math>0.05</b> | <b>0.899<math>\pm</math>0.08</b> |

Tab. 2: Evaluation results of experiments with different transfer learning methods, tested on the semi-natural grassland test set. Higher values are preferred for all metrics, where  $\pm$  indicates variance.

**Explainable AI.** In Fig. 3, we showcased two examples from the semi-natural grassland test set. The first example (row 1) clearly illustrated the prowess of the model trained with the entire grassland training datasets. This experiment excels at emphasizing target features while minimizing focus on the background. In contrast, the model trained with semi-natural and experimental grassland data failed to detect the indicator plant, primarily due to significant focus on background, as shown in (1b). The second example (row 2) showed again the advantage of utilizing the entire grassland data, allowing the model to discern finer discriminative features, such as the unique leaf shape of indicator species. This is exemplified by the small circular area highlighted outside the predicted bounding box at the top right of (2c) in Fig. 3.

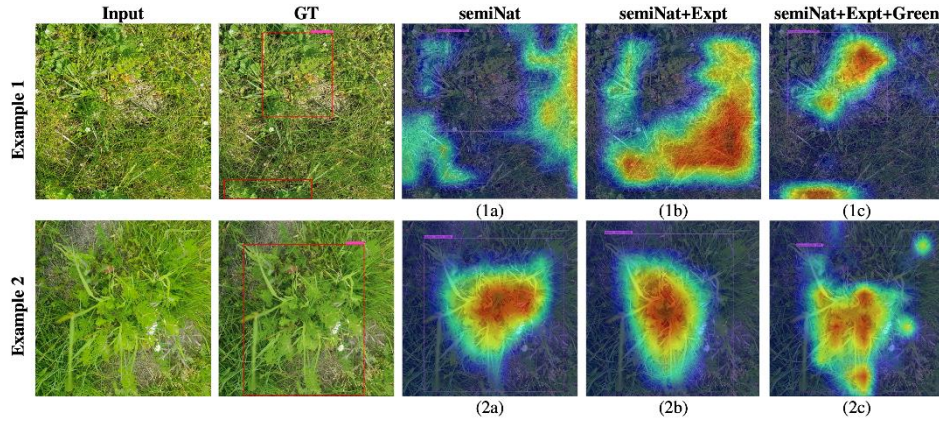


Fig. 3: First two columns represent input images and ground-truth annotations. Column 3-5 represent the predictions (purple bounding boxes) and explanations of experiments using different training data. In the explanation heat maps, the most relevant areas are highlighted in red and the less relevant areas in blue.

In addition to qualitative visualizations, we quantitatively evaluated these experiments considering accuracy metrics such as *Average Precision* (AP) and localization metrics, specifically *Attribution Localization* (AL) and *Top-K Intersection* (TKI), as detailed in

Tab. 3. The inclusion of experimental and greenhouse data alongside semi-natural grassland data led to performance improvements in all metrics, elevating AP from 61.8 to 66.4, AL from 0.71 to 0.828, and TKI from 0.697 to 0.899.

| Training /<br>Validation Set | Test<br>Set | Transfer<br>Learning | AP $\uparrow$ | AL $\uparrow$                    | TKI $\uparrow$                   |
|------------------------------|-------------|----------------------|---------------|----------------------------------|----------------------------------|
| sNat                         | sNat        | Fine-tuning          | 61.8          | 0.710 $\pm$ 0.14                 | 0.697 $\pm$ 0.21                 |
| sNat+Expt                    | sNat        | Fine-tuning          | 63.6          | 0.735 $\pm$ 0.16                 | 0.764 $\pm$ 0.18                 |
| sNat+Expt+Green              | sNat        | Fine-tuning          | <b>66.4</b>   | <b>0.828<math>\pm</math>0.05</b> | <b>0.899<math>\pm</math>0.08</b> |

Tab. 3: Evaluation result of experiments with different training data, tested on the semi-natural grassland test set for fair comparison.

Our innovative incorporation of localization metrics into the evaluation framework expanded the spectrum of model evaluation. This extension allowed us not only to evaluate the detector's accuracy in identifying indicator species in the current test set, i.e. the semi-natural grassland scenario, but also to assess its adaptability in detecting indicator species in other areas characterized by diverse backgrounds, such as the wild natural grassland scenario.

## 5 Conclusion

In this work, we addressed two main shortcomings of developing a deep learning model for grassland monitoring: the distributional shift between generalized and grassland-specific datasets and the inherent opacity of deep learning models. Our research highlights the remarkable potential of pretrained models, especially when combined with fine-tuning, to significantly boost model performance. By leveraging XAI, we gained a deeper understanding of the decision-making processes of deep learning models in the context of grassland scenarios, where features like the unique leaf shape of indicator species play an important role in decision-making. Furthermore, the utilization of localization metrics within XAI broadens the scope of model performance assessment, offering valuable insights into the model's generalizability and adaptability to other domains where the background is not necessarily class-informative. These findings hold significant implications for agricultural applications characterized by limited data and the need for domain adaptation. For future work, we will conduct experiments including additional XAI metrics and explore how their insights can incorporate model and dataset development in advancing AI-driven agricultural solutions.

**Acknowledgments:** This work was partly funded by the German Ministry for Education and Research (BMBF) through the project Explaining 4.0 (ref. 01IS200551) and the project Digital Agricultural Knowledge and Information System (DAKIS). The dataset used in this work was funded by DAKIS project.

## Bibliography

- [Ak20] Akagi, T. et al.: Explainable Deep Learning Reproduces a ‘Professional Eye’ on the Diagnosis of Internal Disorders in Persimmon Fruit. *Plant and Cell Physiology*, 61(11):1967–1973, 08 2020.
- [AA22] Al Sahili, Z.; Awad, M.: The power of transfer learning in agricultural applications: AgriNet. *Frontiers in Plant Science*, 13, 2022.
- [AU22] Arun, R.A.; Umamaheswari, S: Effective and efficient multi-crop pest detection based on deep learning object detection models. *Journal of Intelligent & Fuzzy Systems*, 43(4):5185–5203, 2022.
- [Ba21] Badeka, E. et al.: Vision-based vineyard trunk detection and its integration into a grapes harvesting robot. *International Journal of Mechanical Engineering and Robotics Research*, 10(7):374–385, 2021.
- [Ba22] Basavegowda, D. et al.: Indicator plant species detection in grassland using EfficientDet object detector. In: 42. GIL-Jahrestagung, Künstliche Intelligenz in der Agrar- und Ernährungswirtschaft, pp. 57–62. Gesellschaft für Informatik e.V., Bonn, 2022.
- [Be19] Bengtsson, J. et al.: Grasslands—more important for ecosystem services than you might think. *Ecosphere*, 10(2):e02582, 2019.
- [Ca20] Cao, L. et al.: The Field Wheat Count Based on the Efficientdet Algorithm. In: 2020 IEEE 3rd International Conference on Information Systems and Computer Aided Education (ICISCAE). pp.557–561, 2020.
- [Ch17] Chollet, F.: Xception: Deep Learning With Depthwise Separable Convolutions. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. July 2017.
- [CPC19] Carvalho, D.V; Pereira, E.M.; Cardoso, J.S.: Machine learning interpretability: A survey on methods and metrics. *Electronics*, 8(8):832, 2019.
- [De09] Deng, J. et al.: ImageNet: A large-scale hierarchical image database. In: 2009 IEEE Conference on Computer Vision and Pattern Recognition. pp. 248–255, 2009.
- [Eu20] Eurostat: Share of main land types in utilised agricultural area (UAA) by NUTS 2 regions. 2020.
- [Eu23] Eurostat: Umsetzung der Gemeinsamen Agrarpolitik der Europäischen Union 2023 in Deutschland. 2023.
- [He23a] Hedström, A. et al.: An Explainable AI Toolkit for Responsible Evaluation of Neural Network Explanations and Beyond. *Journal of Machine Learning Research*, 24(34):1–11, 2023.
- [He23b] Hedström, A. et al.: The Meta-Evaluation Problem in Explainable AI: Identifying Reliable Estimators with MetaQuantus. *Transactions on Machine Learning Research*, 2023.
- [Ho17] Howard, A. et al.: MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *CoRR*, abs/1704.04861, 2017.

- [Jo21] Jocher, G. et al.: ultralytics/yolov5: v7. 0-yolov5 sota realtime instance segmentation. Zenodo, 2021.
- [Ko20] Kohlbrenner, M. et al.: Towards best practice in explaining neural network decisions with LRP. In: 2020 International Joint Conference on Neural Networks (IJCNN). IEEE, pp. 1–7, 2020.
- [LH19] Loshchilov, I.; Hutter, F.: Decoupled Weight Decay Regularization. In: International Conference on Learning Representations. 2019.
- [Pe21] Pe'er, G. et al.: The Common Agricultural Policy post-2020: Views and recommendations from scientists to improve performance for biodiversity. Volume 2 - Annexes. Thünen Working Paper 175 - Volume 2, Braunschweig, 2021. urn:nbn:de:gbv:253-202105-dn063618-4
- [Qi23] Qiang, J. et al.: Detection of citrus pests in double backbone network based on single shot multibox detector. *Computers and Electronics in Agriculture*, 212:108158, 2023.
- [KS21] Kavitha Lakshmi, R.; Savarimuthu, N.: Investigation on Object Detection Models for Plant Disease Detection Framework. In: 2021 IEEE 6th International Conference on Computing, Communication and Automation (ICCCA). pp. 214–218, 2021.
- [Ru22] Rudin, C. et al.: Interpretable machine learning: Fundamental principles and 10 grand challenges. *Statistic Surveys*, 16:1–85, 2022.
- [Sa23] Sanaeifar, A. et al.: Advancing precision agriculture: The potential of deep learning for cereal plant head detection. *Computers and Electronics in Agriculture*, 209:107875, 2023.
- [Sc22] Schils, R.L.M. et al: Permanent grasslands in Europe: Land use change and intensification decrease their multifunctionality. *Agriculture, Ecosystems & Environment*, 330:107891, 2022.
- [Se17] Selvaraju, R. et al.: Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. In: 2017 IEEE International Conference on Computer Vision (ICCV). pp. 618–626, 2017.
- [Sz16] Szegedy, Christian; Vanhoucke, Vincent; Ioffe, Sergey; Shlens, Jon; Wojna, Zbigniew: Rethinking the Inception Architecture for Computer Vision. In: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). pp. 2818–2826, 2016.
- [TLN23] Thai, H.-T.; Le, K.-H.; Nguyen, N.L.-T.: FormerLeaf: An efficient vision transformer for Cassava Leaf Disease detection. *Computers and Electronics in Agriculture*, 204:107518, 2023.
- [TME22] Theiner, J.; Müller-Budack, E.; Ewerth, R.: Interpretable Semantic Photo Geolocation. In: Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). pp. 750–760, January 2022.
- [TPL20] Tan, M.; Pang, R.; Le, Q.V.: EfficientDet: Scalable and Efficient Object Detection. In: 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). pp. 10778–10787, 2020.
- [We22] Wei, K. et al: Explainable deep learning study for leaf disease classification. *Agronomy*, 12(5):1035, 2022.

- [Či23] Čirjak, D. et al.: EfficientDet-4 Deep Neural Network-Based Remote Monitoring of Codling Moth Population for Early Damage Detection in Apple Orchard. *Agriculture*, 13(5), 2023.

## UAV-gestütztes Spot-Spraying zur schwellwertbasierten Beikrautregulierung im Mais

Konstantin Nahrstedt<sup>1</sup>, Tobias Reuter<sup>2</sup>, Felix Wierling<sup>3</sup>, Dieter Trautz<sup>2</sup> und  
Thomas Jarmer<sup>1</sup>



**Abstract:** Beikräuter werden in der landwirtschaftlichen Praxis flächendeckend reguliert. Da sich signifikante Ertragsverluste in Maisbeständen jedoch erst ab einer bestimmten Beikrautbesatzdichte ergeben, ist eine flächendeckende Bekämpfung nicht immer erforderlich. Die teilflächenorientierte Ausbringung von Pflanzenschutzmitteln (PSM) mittels Spot-Spraying bietet durch selektiven Mitteleinsatz ökonomische sowie ökologische Vorteile. Für die hierzu erforderliche präzise Erfassung des Beikrautbesatzes eignen sich drohnengestützte Kamerasysteme. Im vorgestellten Versuchsvorhaben wurde eine Maisfläche kurz vor der PSM-Applikation befliegen und der Beikrautbestand klassifiziert. Mit einer Gesamtgenauigkeit von 92 % bzw. 93 % konnten Maispflanzen, Beikräuter und offener Boden differenziert werden. In randomisiert angelegten Parzellen wurden anschließend Applikationspolygone nach unterschiedlichen Schwellwerten für eine Mittelausbringung erstellt. In einer Erfolgskontrolle wurde die Verteilung behandelter und unbehandelter Beikräuter erfasst, um die Applikation zu evaluieren. Dabei zeigte sich eine hohe Übereinstimmung zwischen der drohnengestützten Applikationskarte und der Terminalapplikationskarte der Landmaschine. Anhand der Ertragskartierung wurden nur geringfügige Unterschiede im Maisertrag zwischen vollständig behandelten und schadschwellbehandelten Parzellen festgestellt.



**Keywords:** Beikrautererkennung, Spot-Spraying, Precision Agriculture, Remote Sensing, UAV

### 1 Einleitung

In der Praxis werden Pflanzenschutzmittel (PSM) zur Beikrautregulierung meist flächendeckend ausgebracht. Da sich Beikräuter jedoch räumlich ungleichmäßig verteilen und erst ab einer bestimmten Beikrautbesatzdichte und -art zu signifikanten Ertragsverlusten

---

<sup>1</sup> Universität Osnabrück, Institute of Computer Science, Remote Sensing Group, Wachsbleiche 27,  
49090 Osnabrück, konstantin.nahrstedt@uni-osnabrueck.de,  <https://orcid.org/0000-0002-8116-3412> ;  
thomas.jarmer@uni-osnabrueck.de,  <https://orcid.org/0000-0002-4652-1640>

<sup>2</sup> Hochschule Osnabrück University of Applied Sciences Faculty of Agricultural Sciences and Landscape  
Architecture, Am Krümpel 31,49090 Osnabrück, tobias.reuter@hs-osnabrueck.de,  <https://orcid.org/0000-0002-2860-5613>; d.trautz@hs-osnabrueck.de,  <https://orcid.org/0009-0005-8359-2172>

<sup>3</sup> Competence Center ISOBUS e. V., Hamburger Straße 24, 49084 Osnabrück, felix.wierling@cc-isobus.com

bei der Nutzpflanze führen, ist dies in der Regel nicht notwendig [Fe14]. Ferner wird durch eine flächendeckende Regulierung die Boden- und Grundwasserbelastung erhöht [Sc01] sowie die Biodiversität vermindert, da Beikräuter Lebensraum und Nahrungsgrundlage für zahlreiche Insekten darstellen [Pe18]. Vor dem Hintergrund des zunehmenden Rückgangs von Wildpflanzen- und Insektenarten kann z. B. bei der chemischen Beikrautregulierung ein bedarfsorientiertes Applizieren von PSM mittels Spot-Spraying einen Beitrag zur Biodiversität liefern, wenn erst ab Überschreitung eines vorgegebenen Beikrautschwellwertes gespritzt wird [Al22]. Aus ökonomischer Perspektive können zudem Betriebskosten durch die Mitteleinsparungen gesenkt werden [RK20].

Der Einsatz von Spot-Spraying bedingt eine detaillierte Kartierung der zu behandelnden Fläche. Unmanned Aerial Vehicle (UAV) bieten eine kosteneffiziente Möglichkeit, große landwirtschaftliche Flächen effizient zu erfassen und die Zusammensetzung des Bestandes räumlich darzustellen [TBS19]. Die Eignung von UAV-Daten zur Beikrautererkennung wurde bereits in unterschiedlichen Studien kulturunabhängig [Pe16; Hu18] wie auch im Speziellen im Mais [Pe13; Ga22] diskutiert. Untersuchungen zur Integration UAV-basierter Beikrautkartierungen in ein Spot-Spraying-System unter Berücksichtigung unterschiedlicher Schadschwellen und deren technischer Analyse liegen jedoch kaum vor.

Daher wurde in der vorliegenden Arbeit eine Methodik zur teilflächenorientierten PSM-Ausbringung mittels Spot-Spraying auf Grundlage einer UAV-gestützten Beikrautererkennung entwickelt. Dabei sollten technische Aspekte des Datentransfers zwischen Drohne und Landmaschine sowie phänologische Auswirkungen unterschiedlicher Beikrautbelastungsgrade auf den Maisertrag in die Methodik involviert werden. In mehreren Parzellen wurden hierzu unterschiedliche Schadschwellwerte als Basis für die Applikation getestet.

## 2 Material und Methoden

### 2.1 Versuchsaufbau und Material

Für die vorgestellte Untersuchung wurde auf einer Maisfläche südwestlich der Stadt Münster (51°49'56"N, 7°31'50"E) ein Versuch zur teilflächenspezifischen Beikrautregulierung angelegt. Zur Evaluierung des Einflusses des Beikrautbesatzes auf den Maisbestand wurde das Versuchsfeld in sechs randomisiert angeordnete Parzellen untergliedert. Je zwei Parzellen wurden teilflächenspezifisch mit Schwellwerten von 4 % und 8 % reguliert. Bei zwei Kontrollparzellen erfolgte die Behandlung flächendeckend (Abb. 1).

Mithilfe einer DJI Phantom Multispectral (Blau: 450 nm, Grün: 560 nm, Rot: 650 nm, RedEdge: 730 nm, NIR: 840 nm) wurden Multispektraldaten in einer Flughöhe von 25 m (vor der Regulierungsmaßnahme) bzw. 18 m (nach der Maßnahme) aufgezeichnet. Dies resultierte in einer räumlichen Auflösung von 1,2 cm bzw. 1 cm pro Pixel. Die höhere Auflösung wurde zum zweiten Befliegungstermin gewählt, um präziser zwischen behandelten und unbehandelten Beikräutern unterscheiden zu können. Die Prozessierung der



aufgenommenen Multispektraldaten wurde mithilfe der Software Agisoft Metashape (Version 1.5.3) umgesetzt. Zur Exaktverortung der UAV-Bilddaten erfolgte eine geometrische Korrektur unter Einsatz von Ground Control Points, die mit einem Stonex S900A GNSS-Receiver eingemessen wurden. Mittels Lichteinstrahlsensor konnten Unterschiede in den Belichtungsbedingungen während der Befliegungen korrigiert werden. Für die visuelle Differenzierung von Mais und Beikräutern wurden insgesamt zwölf Messstellen pro Parzelle (Größe 1 m<sup>2</sup>) ausgewählt und ebenfalls per GNSS-Empfänger eingemessen. Je Messstelle wurden Beikrautaufkommen und -art dokumentiert sowie ein hochaufgelöstes Foto der Mais- und Beikrautpflanzen als Referenz für die Bestimmung der Trainings- und Validierungsdaten für die Klassifikation aufgenommen.




Abb. 1: Versuchsdesign mit Parzellen mit unterschiedlichen Regulierungsschwellwerten und Messstellen

Abbildung 2 skizziert den Versuchsablauf. Die Aussaat erfolgte am 06.05.2023 mit einem Reihenabstand von 75 cm. Im Voraufbau wurde das Bodenherbizid Stomp Aqua (BASF Agrar) verwendet. Am 01.06.2023 wurden eine erste Befliegung des Bestandes im Zwei- bis Dreiblattstadium des Mais durchgeführt und die Messstellen beprobt. Hieraus wurde eine Beikrautbesatzkarte generiert, welche in eine maschinenlesbare Applikationskarte im ISOXML-Format konvertiert wurde. Anschließend erfolgte am 06.06.2023 parzellenspezifisch die PSM-Ausbringung. Acht Tage später wurde nach Einwirken des PSM eine Er-

folgskontrolle durch eine wiederholte Befliegung und Beprobung der Messstellen durchgeführt. Die abschließende Auswertung der Ertragskarte von der Ernte am 27.09.2023 ermöglichte eine Analyse der Ertragsunterschiede zwischen den Parzellen.

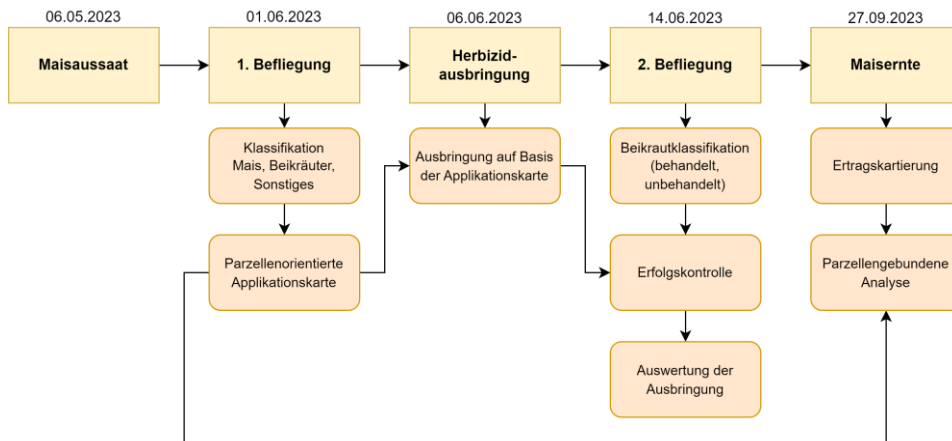


Abb. 2: Ablauf des Versuchs

Zur Mittelausbringung wurde eine Amazone Anbaufeldspritze UF mit Einzeldüsen-schaltung (Baujahr 2016) eingesetzt und mittels CCI 1200 Terminal angesteuert. Über das Terminal konnten anhand der UAV-Applikationskarte die Standorte der Beikräuter während der Überfahrt ausgelesen und an die Düsen übermittelt werden, sodass immer dann appliziert wurde, wenn auf dem Terminal ein Polygon für erhöhtes Beikrautaukommen erschien. Das applizierte Mittel setzte sich aus einem Gemisch aus Daneva (Rotam Germany GmbH) und Peak (Syngenta Agro GmbH) im Verhältnis 1:50 zusammen.

## 2.2 Entwicklung der Beikrautapplikationskarte

Um die Klassifikationsergebnisse aus den UAV-Bilddaten auf die Landmaschine überführen zu können, wurde ein Workflow entwickelt, der neben der Bilddatenprozessierung auch die Beikrautklassifikation sowie die Übersetzung der resultierenden Karte in ein maschinenlesbares Format umfasste (Abb. 3). Zur räumlich differenzierten Identifikation von Beikräutern im Maisbestand wurde ein Random-Forest (RF)-Klassifikator trainiert. Auf Grundlage von Trainingsbeispielen werden die Klassifikationsentscheidungen einer Vielzahl von Entscheidungsbäumen kombiniert. Nach dem Mehrheitsprinzip wird anschließend jeder Pixel einer Klasse zugeordnet. Durch diesen Mehrheitsentscheid gilt der Algorithmus als robust gegenüber Überanpassung an die Trainingsdaten [Br01]. In der vorliegenden Arbeit wurde der RF mit der Software-Bibliothek scikit-learn in Python (Version 3.8.5) implementiert. Bei der Parametrisierung wurde die Anzahl der Bäume auf 50 festgelegt, da eine höhere Anzahl an Bäumen keinen signifikanten Einfluss auf den Schätzfehler zeigte und zeitgleich die Rechenzeit gegenüber der Standardeinstellung

(100 Bäume) reduziert werden konnte. Da der RF in der Literatur zumeist in den Standardeinstellungen die besten Ergebnisse erzielt [Fe14], wurden die übrigen Parameter nicht verändert.

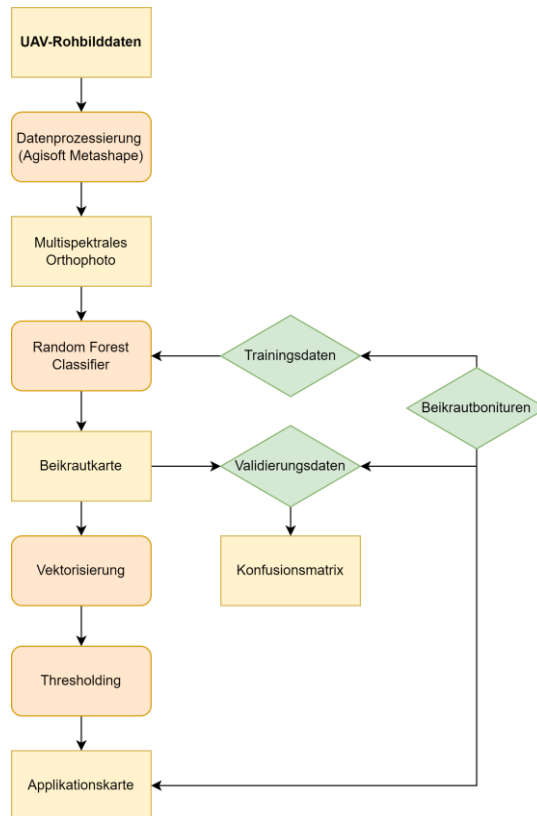


Abb. 3: Workflow zur UAV-basierten Beikrautapplikationskarte

Bei der Bildklassifikation der Daten des ersten Befliegungstermins wurde nach *Mais*, *Beikräutern* und *Sonstiges* unterschieden, wobei letzteres unbedeckten Boden und Erntereste umfasste. Da anhand der parzellenspezifischen Schwellwerte einzelne Beikräuter bewusst nicht behandelt werden sollten, wurde im zweiten Befliegungstermin zusätzlich nach *Beikräutern (behandelt)* und *Beikräutern (unbehandelt)* differenziert. Die Sammlung der Trainings- und Validierungsdaten erfolgte räumlich unabhängig voneinander, wobei in beiden Datensätzen je Klasse 1.000 Pixel zufällig zum Training bzw. Validieren gezogen wurden. Als Validierungsparameter wurde die Gesamtgenauigkeit (OA) über alle Klassen berechnet. Die Bewertung der Klassifikationsgenauigkeit der einzelnen Klassen erfolgte anhand des F1-Scores.

Zur Konvertierung der Klassifikationsergebnisse in ein maschinenlesbares Format wurde zunächst eine binäre Beikrautkarte (Beikraut/kein Beikraut) erstellt und in ein Vektordatenformat überführt. Dazu wurde ein Polygongrid definiert, in dem pro Zelle das Beikrautkommen anteilig bestimmt wurde. Die Größe jedes Polygons richtet sich nach der gewünschten Arbeitsbreite und der Reihenweite der Kultur und kann frei gewählt werden. Im vorliegenden Versuch wurde eine Arbeitsbreite von 1,5 m zur Applikation gewählt. Um verschiedene Arbeitsbreiten bedienen zu können, wurde der Beikrautanteil prozentual aus dem Flächenanteil klassifizierter Beikräuter in Relation zur Gesamtfläche eines Applikationspolygons bestimmt. Anschließend erfolgte die Selektion zu applizierender Polygone anhand der je Parzelle festgelegten Schadschwellen. Diese wurden mit 4 % und 8 % so gewählt, dass eine ausreichende Menge behandelter Beikräuter und zeitgleich ein sichtbarer Unterschied in der Applikationsmenge zwischen den Parzellen garantiert wird. Je Polygon sollte das PSM nur dann appliziert werden, wenn der Beikrautanteil innerhalb des Polygons den festgelegten Schwellwert überschreitet. Zum Import in das Landmaschinenterminal wurde die Applikationskarte in das ISOXML-Format konvertiert.

Die Bewertung des skizzierten Vorgehens erfolgte sowohl auf technischer als auch pflanzenbaulicher Ebene. Hierzu wurde die UAV-basierte Applikationskarte mit der infolge der tatsächlichen Ausbringung generierten Terminalkarte verglichen. Anhand des Klassifikationsergebnisses des zweiten Überfluges konnte der Applikationserfolg hinsichtlich tatsächlich behandelter und unbehandelter Beikräuter analysiert werden. Die bei der Ernte generierte Ertragskarte wurde anschließend parzellenspezifisch ausgewertet, um Unterschiede im Maisertrag in Abhängigkeit von der Beikrauttoleranz ermitteln zu können.

### 3 Ergebnisse und Diskussion

#### 3.1 Klassifikationsergebnisse

Tabelle 1 zeigt die Konfusionsmatrix zu den Ergebnissen der Bestandsklassifikation vor der Regulierungsmaßnahme. Mit einer Genauigkeit von 93,35 % (F1-Score) wurden Beikräuter zum Zeitpunkt vor der Maßnahme richtig identifiziert. Maispflanzen wurden mit einer Genauigkeit von 87,97 % korrekt bestimmt.

|                  | <b>Mais</b>  | <b>Beikraut</b> | <b>Sonstiges</b> | <b>F1-Score [%]</b> |
|------------------|--------------|-----------------|------------------|---------------------|
| <b>Mais</b>      | 819          | 79              | 102              | 87,97               |
| <b>Beikraut</b>  | 41           | 947             | 12               | 93,35               |
| <b>Sonstiges</b> | 2            | 3               | 995              | 94,36               |
| <b>OA [%]</b>    | <b>92,03</b> |                 |                  | <b>N = 1000</b>     |

Tab. 1: Konfusionsmatrix Klassifikationsmerkmale (vor der Maßnahme); OA = Overall Accuracy

In der Erfolgskontrolle nach der Maßnahme (Tab. 2) konnten Beikräuter (behandelt) und Beikräuter (unbehandelt) mit einer Genauigkeit von 90,59 % und 96,61 % (F1-Score) richtig erkannt werden. Auch hier konnten die Maispflanzen bei einem F1-Score von 90,36 % präzise erfasst werden. Zu beiden Terminen war dabei mit einer Genauigkeit von 94,36 % bzw. 97,20 % eine deutliche Abgrenzung von den verbliebenen Bedeckungsarten (Klasse *Sonstiges*) möglich.

|              | Mais         | Beikraut<br>(B) | Beikraut<br>(U) | Sonstiges | F1-Score<br>[%] |
|--------------|--------------|-----------------|-----------------|-----------|-----------------|
| Mais         | 942          | 30              | 8               | 20        | 90,36           |
| Beikraut (B) | 128          | 862             | 10              | 0         | 90,59           |
| Beikraut (U) | 14           | 10              | 968             | 8         | 96,61           |
| Sonstiges    | 1            | 1               | 18              | 980       | 97,20           |
| OA [%]       | <b>93,80</b> |                 |                 |           | <b>N = 1000</b> |

Tab. 2: Konfusionsmatrix Klassifikationsmerkmale (nach der Maßnahme);  
Beikraut (B) = Beikraut (behandelt), Beikraut (U) = Beikraut (unbehandelt),  
OA = Overall Accuracy

Die Klassifikationskarten beider Befliegungen zeigen die Verteilung der Beikräuter in Relation zu den Maispflanzen (Abb. 4). Beikräuter konnten sowohl zwischen den Maisreihen als auch innerhalb der Reihen erkannt werden. Starke Variationen in den Beleuchtungsverhältnissen traten vorwiegend zum ersten Befliegungstermin auf und sind anhand des hellen Flecks in Abbildung 4 (links) erkennbar. Diese konnten durch den Beleuchtungssensor nicht vollständig kompensiert werden. Durch gezielte Trainingsdatenselektion wurden die Unterschiede jedoch in der Klassifikation berücksichtigt. Zu beachten ist, dass die Form der Maispflanzen zumeist realitätsnah aber nicht immer vollständig korrekt abgebildet werden konnte. Dies ist auf die räumliche Auflösung der Bilddaten zurückzuführen. Dennoch konnten Maispflanzen, Beikräuter und sonstige Bedeckungsarten mit hoher Genauigkeit voneinander unterschieden werden, da die reduzierte Pixelauflösung durch die Spektralinformationen kompensiert werden konnte. Hierbei erwiesen sich insbesondere die Reflexion im RedEdge und Nahen Infrarot als hilfreich zur Unterscheidung der Pflanzen [Pe13] und zur Abgrenzung vom Boden [Ha18].

Die spektralen Unterschiede wurden auch zum zweiten Befliegungstermin genutzt, um in der Erfolgskontrolle zwischen behandelten und unbehandelten Beikräutern differenzieren zu können. Die mit dem PSM behandelten Pflanzen zeigten Seneszenzerscheinungen und damit andere Reflexionseigenschaften im Infrarotbereich als die nicht behandelten Beikräuter [GC23]. Somit wäre auch eine räumlich differenzierte Bewertung des Applikationserfolges sowie der technischen Umsetzung der UAV-Applikationskarte auf der Fläche in Zentimetergenauigkeit möglich. In der vorliegenden Untersuchung wurde die Analyse auf die vorgegebene Arbeitsbreite von 1,5 m beschränkt, um belastbare Aussagen

für die eingesetzte Technik treffen zu können. Die laut UAV-Applikationskarte zu applizierenden Bereiche und die tatsächlich behandelten und unbehandelten Beikräuter sind in Abbildung 4 (rechts) dargestellt. Die Kontrollparzellen bleiben hierbei unberücksichtigt, da hier eine konventionelle Behandlung beider Bereiche durchgeführt wurde, um diese später auf Ertragsunterschiede zu den schwellwertbasiert behandelten Parzellen zu prüfen.

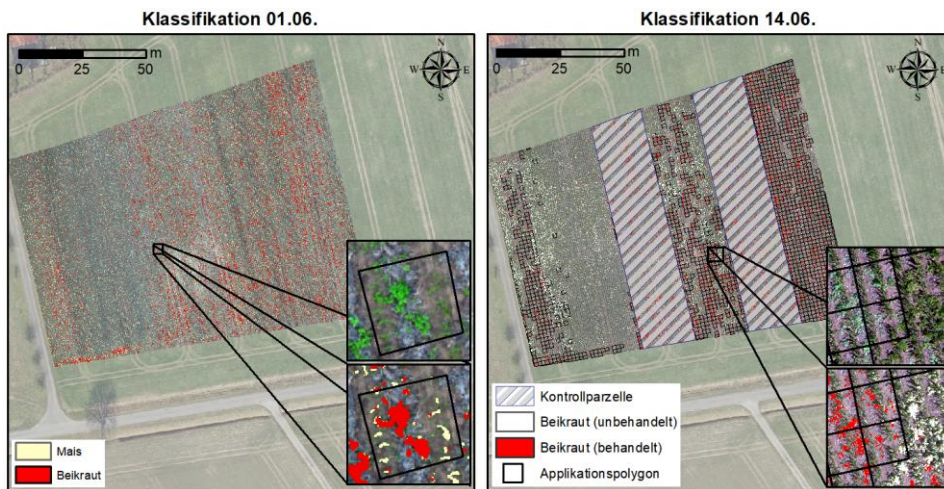


Abb. 4: Ergebniskarten der Beikrautklassifikation vor (links) und nach (rechts) der Regulierungsmaßnahme

Durch das fortgeschrittene phänologische Stadium der Pflanzen zum zweiten Befliegungstermin ist zu beachten, dass vereinzelt Maispflanzen durch (unbehandelte) Beikräuter verdeckt wurden und umgekehrt. Dies führte stellenweise zu Klassifikationsungenauigkeiten bei der Erkennung des Mais. Ferner zeigte sich in der westlichen Randparzelle zum zweiten Termin eine deutliche Zunahme des Beikrautaufkommens in Relation zu den übrigen Parzellen. Dies ist sowohl durch einen verstärkten Aufwuchs der Beikräuter zwischen dem ersten Befliegungstermin und der Durchführung der Maßnahme als auch durch den angesetzten Schwellwert von 4 % zu erklären. Dieser führte dazu, dass insbesondere zum Zeitpunkt der ersten Befliegung sehr kleine Beikräuter in dieser Region nicht berücksichtigt wurden. Vergleichsweise kühle Temperaturen und späte Niederschläge führten überdies zu einer verzögerten Keimung einzelner Beikräuter.

### 3.2 Analyse der Applikation

Das Vorgehen zur Auswertung technischer Aspekte der Beikrautapplikation ist in Abbildung 5 dargestellt. Die Gegenüberstellung der UAV-Applikationskarte (Abb. 5, oben links) und der formatierten Terminalapplikationskarte (Abb. 5, oben rechts), die im Anschluss an die Mittelausbringung durch das Terminal bereitgestellt wurde, zeigte eine weitgehende Übereinstimmung und damit verlustarme Übersetzung. Alle im Vorfeld der



Maßnahme ausgewiesenen Applikationspolygone, die mit der tatsächlichen Applikation laut Terminal übereinstimmten, wurden als *Behandelt, wie erwartet* klassifiziert (Abb. 5, unten rechts). Polygone, die durch Unterschreitung der Schadschwellwerte nicht behandelt werden sollten, wurden als *Unbehandelt, wie erwartet* kategorisiert. Diese beiden Klassen dominierten in der Applikationsanalyse und unterstreichen daher eine grundlegend gelungene Beikrautapplikation.

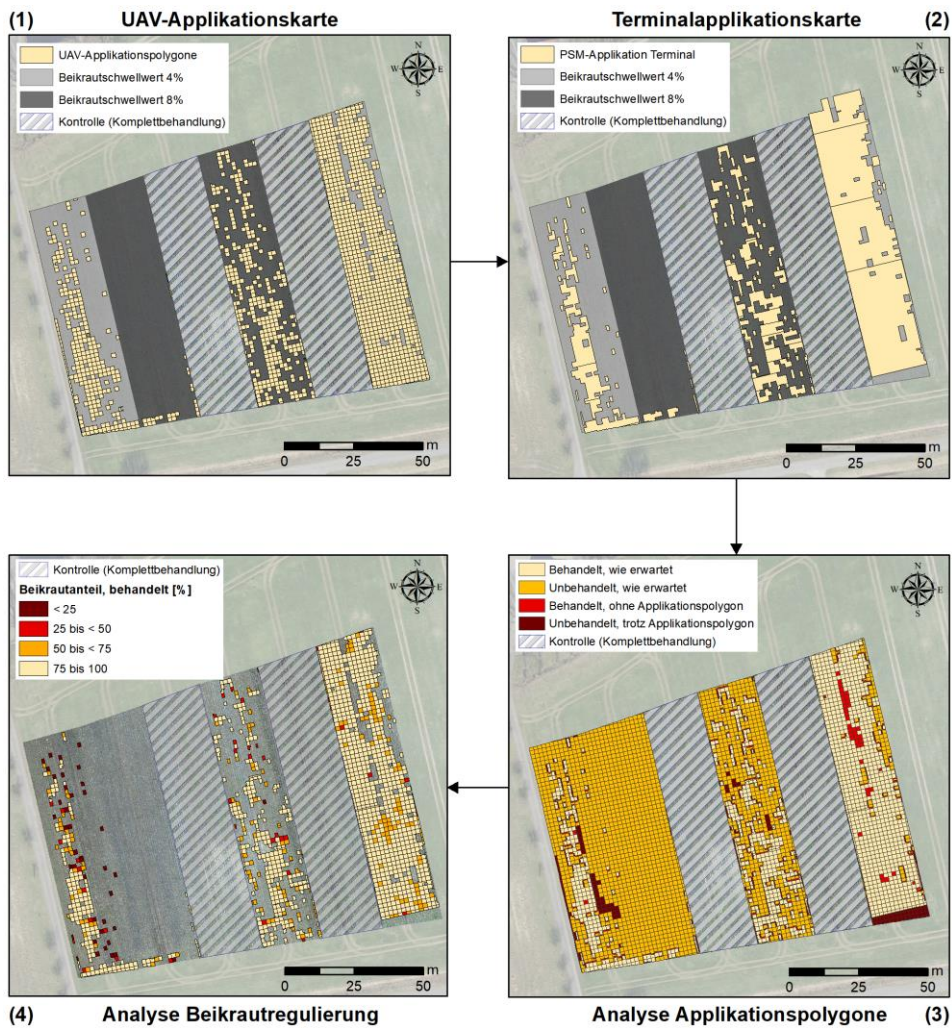


Abb. 5: Auswertung der Beikrautapplikation

Zu beachten sind jedoch fehlerhafte Applikationen (*Behandelt, ohne Applikationspolygon*), die insbesondere in der östlichen Randparzelle auftraten. Diese sind höchstwahrscheinlich auf einen technischen Fehler durch vertikalen Versatz der Terminalkarte in dieser Parzelle zurückzuführen. Dieser Fehler trat in den übrigen Parzellen nicht auf, da die Applikationskarten anhand der Parzellen aufgeteilt und sequenziell in das Terminal importiert wurden. Ferner zeigte die Klasse *Unbehandelt, trotz Applikationspolygon*, dass insbesondere in der westlichsten Parzelle einige Bereiche nicht behandelt wurden, obwohl die UAV-Applikationskarte dies ausgewiesen hatte. Dieser Fehler ist möglicherweise auf Verluste bei Konvertierung und Import der Karte in die Terminalarchitektur zurückzuführen. Hier sind Anpassungen in der Konvertierung der Datenformate erforderlich.

Auf Basis des Klassifikationsergebnisses der zweiten Befliegung wurde in einem zweiten Schritt eine Analyse der Beikrautregulierung anhand der tatsächlich behandelten Pflanzen (*Beikräuter (behandelt)*) vorgenommen (Abb. 5, unten links). Darin wurde für alle Polygone der Klasse *Behandelt, wie erwartet* aus der Applikationsanalyse der Anteil der behandelten Beikräuter berechnet. Dieser ergibt sich je Polygon aus dem Verhältnis zwischen behandelten und unbehandelten Beikräutern und soll den tatsächlichen Applikationserfolg des PSM abbilden. In wie erwartet applizierten Bereichen wurden dabei in rund 73 % der Polygone mindestens 75 % aller Beikräuter in einem Polygon behandelt. Ausnahmen hiervon waren unsystematisch über alle Parzellen verteilt und traten vorwiegend in Randlagen größerer zusammenhängend applizierter Bereiche auf. Dabei können einzelne Pflanzen entweder nicht vollständig durch das PSM getroffen worden sein oder sind erst nach der Mittelausbringung aufgewachsen.

### 3.3 Auswertung der Ertragsdaten

Infolge der am 27.09.2023 durchgeführten Ernte wurde vom ausführenden Lohnunternehmer eine Ertragskarte erstellt. Aus Gründen der Datensicherheit und -kompatibilität liegt diese nur als Screenshot vor (Abb. 6).

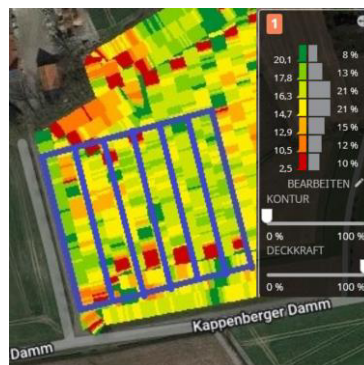


Abb. 6: Screenshot der Ertragskarte, blau umrandet sind die Parzellengrenzen, Legende: Trockenmasse in t/ha



Die visuelle Analyse der Kartierung zeigte nur geringfügige Unterschiede im Trockenmasseertrag zwischen den Parzellen. Geringere Erträge waren lediglich auf den zwei westlichsten Parzellen zu beobachten. Diese sind vermutlich auf die vergleichsweise hohe Nährstoffkonkurrenz durch den erhöhten Beikrautzuwachs nach Durchführung der Applikation zurückzuführen. Diese Beikräuter konnten durch das verspätete Aufkeimen nicht in der UAV-Applikationskarte berücksichtigt werden. Mit Blick auf die zwei verbliebenen behandelten Parzellen zeigten sich keine signifikanten Ertragsunterschiede gegenüber den Kontrollparzellen, in denen flächendeckend Beikraut reguliert wurde. Des Weiteren ließ sich kein signifikanter Unterschied im Trockenmasseertrag zwischen der mit einem Schwellwert von mindestens 4 % Beikrautbesatz bearbeiteten Parzelle und der toleranteren Variante mit 8 % Besatz pro Polygon feststellen. Dies spricht dafür, dass eine höhere Beikrauttoleranz zugunsten der Biodiversität ohne unmittelbaren Einfluss auf den Maisertrag im Bestandesmanagement erwogen werden kann.

#### **4 Schlussfolgerungen und Ausblick**

Das vorgestellte Vorgehen zur teilflächenspezifischen Beikrautregulierung mittels Spot-Spraying konnte aufzeigen, dass UAV-basierte Bilddaten geeignet sind, um zuverlässig Beikräuter frühzeitig zu erkennen und räumlich zu verorten. Die Gegenüberstellung der UAV-Applikationskarte vor Ausbringung mit der Terminalapplikationskarte nach Ausbringung zeigte nur geringfügige räumliche Unterschiede, sodass die Übersetzung der Klassifikation in die Landmaschine als weitgehend gelungen betrachtet werden kann.

Durch die gezielte Regulierung waren deutliche PSM-Einsparungen möglich. Zudem zeigte sich anhand der getesteten Beikrautregulierungsschwellwerte, dass auch bei höherer Toleranz der Einfluss auf den Trockenbiomasseertrag gering ausfällt. Die vorgestellte Methodik liefert somit eine Möglichkeit, Beikräuter bedarfsorientiert zu regulieren, wobei zeitgleich unter Berücksichtigung einer bestimmten Beikrauttoleranz Potenzialbereiche für mehr Biodiversität auch innerhalb des Maisbestandes erhalten werden können. Die UAV-basierte Beikrautklassifikation ermöglicht zudem vor der Befahrung eine Bewertung des PSM-Bedarfs. Maisreihen oder Parzellen mit sehr geringem Beikrautdruck unterhalb des Schwellwertes könnten bei der Überfahrt gänzlich ausgelassen werden, sodass in diesen Bereichen sowohl der PSM-Eintrag in den Boden als auch die Bodenbelastung durch die Landmaschine reduziert werden können.


Zur Optimierung der Beikrautapplikation besteht weiteres Verbesserungspotenzial in der Klassifikation der Einzelpflanzen (z. B. durch Einbeziehung von Formparametern). Unter Berücksichtigung der aufgekeimten Beikräuter nach Erstellung der Applikationskarte muss bei Witterungsumschwüngen die Applikation im Bedarfsfall ein zweites Mal durchgeführt werden. Zudem sollten die Abstände zwischen der ersten Befliegung, der Erstellung der UAV-Applikationskarte und PSM-Ausbringung auf dem Feld möglichst kurz gehalten werden. Ferner ist bei der Auswahl der Schadschwellen die Zusammensetzung der Beikrautarten zu beachten und muss bei Bedarf geringfügig angepasst werden.

**Förderhinweis:** Die Förderung des Vorhabens erfolgt aus Mitteln des Bundesministeriums für Ernährung und Landwirtschaft (BMEL) aufgrund eines Beschlusses des deutschen Bundestages. Die Projektträgerschaft erfolgt über die Bundesanstalt für Landwirtschaft und Ernährung (BLE) im Rahmen der Förderung der Digitalisierung in der Landwirtschaft mit dem Förderkennzeichen 28DE103C22.

#### Literaturverzeichnis

- [Al22] Allmendinger, A. et al.: Precision Chemical Weed Management Strategies: A Review and a Design of a New CNN-Based Modular Spot Sprayer. *Agronomy*, 12, S. 1620-1641, 2022.
- [Br01] Breiman, L.: Random Forests. *Machine Learning*, 45/1, S. 5-32, 2001.
- [Fe14] Fernandez-Delgado, M. et al.: Do we Need Hundreds of Classifiers to Solve Real World Classification Problems? *Journal of Machine Learning Research*, 15, S. 3133-3181, 2014.
- [Ga22] Gao, J. et al.: Transferring learned patterns from ground-based field imagery to predict UAV-based imagery for crop and weed semantic segmentation in precision crop farming. *arXiv*, 2210/11545, 2022.
- [GC23] Garcia, A. A.; Campana, J. W. C.: Identification of pathogens in corn using near-infrared UAV imagery and deep learning. *Precision Agriculture*, 24, S. 783-806, 2023.
- [Ha18] Hall, O. et al.: Classification of Maize in Complex Smallholder Farming Systems Using UAV Imagery. *Drones*, 2/3, S. 22-30, 2018.
- [Hu18] Huang, H.: A fully convolutional network for weed mapping of unmanned aerial vehicle (UAV) imagery. *PLoS ONE*, 13/4, 2018.
- [Sc01] Schulz, C. U.: Pestizide im Grundwasser – Das Wasser- und pflanzenschutzrechtliche Instrumentarium zum Schutz des Grundwassers gegen Verunreinigung durch Pflanzenschutzmittel. *Natur und Recht*, 23, S. 311-321, 2001.
- [Pe13] Pena, J. M.: Weed Mapping in Early-Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. *PLoS ONE*, 8/10, 2013.
- [Pe16] Pérez-Ortiz, M. et al.: Selecting patterns and features for between- and within- crop-row weed mapping using UAV-imagery. *Expert Systems with Applications*, 47, S. 85-94, 2016.
- [Pe18] Petit, S. et al.: Biodiversity-based options for arable weed management. A review. *Agronomy for Sustainable Development*, 38/48, S. 1-21, 2018.
- [RK20] Rajmis, S.; Karpinski, I.: Ökonomische Bewertung der teilflächenspezifischen Unkrautbekämpfung. 29. Deutsche Arbeitsbesprechung über Fragen der Unkrautbiologie und –bekämpfung, *Julius-Kühn-Archiv*, 464, S. 36-46, 2020.
- [TBS19] Tsouros, D. C.; Bibi, S.; Sarigiannidis, P. G.: A Review on UAV-Based Applications for Precision Agriculture. *Information*, 10, S. 349-375, 2019.

## Image-based activity monitoring of pigs

Jan-Hendrik Witte <sup>1</sup> and Jorge Marx Gómez<sup>1</sup>

**Abstract:** In modern pig livestock farming, animal well-being is of paramount importance. Monitoring activity is crucial for early detection of potential health or behavioral anomalies. Traditional object tracking methods such as DeepSort often falter due to the pigs' similar appearances, frequent overlaps, and close-proximity movements, making consistent long-term tracking challenging. To address this, our study presents a novel methodology that eliminates the need for conventional tracking to capture activity on pen-level. Instead, we segment video frames into predefined sectors, where pig postures are determined using YOLOv8 for pig detection and EfficientNetV2 for posture classification. Activity levels are then assessed by comparing sector counts between consecutive frames. Preliminary results indicate discernible variations in pig activity throughout the day, highlighting the efficacy of our method in capturing activity patterns. While promising, this approach remains a proof of concept, and its practical implications for real-world agricultural settings warrant further investigation.


**Keywords:** precision livestock farming, deep learning, computer vision, activity monitoring

### 1 Introduction

In conventional pig livestock farming, monitoring pig activity stands as a crucial tool for ensuring animal health and welfare. Recently, the use of video analytics and advanced Deep Learning (DL) techniques, especially those from the domain of Computer Vision (CV), has markedly advanced the field of pig Precision Livestock Farming (PLF). These advancements highlight the potential for image-based activity monitoring of pigs.

Early research in this area concentrated on using image data as well as different CV tasks like Object Detection (OD), Image Classification (IC) or Keypoint Detection (KD) for the detection and classification of pigs alongside discerning their respective postures. The outcomes of these initial studies illuminated the potential of image-based methodologies in capturing nuanced pig activity. More recently, the emphasis has shifted towards leveraging Object Tracking (OT) techniques to derive pig activity. In contrast to previous methods, OT and Multiple Object Tracking (MOT) techniques enable the tracking of individual pigs, making it possible to capture distinct movements and trajectories. When aggregated, these tracks could present a comprehensive activity score at specific timestamps within a given pen.

---

<sup>1</sup> Carl von Ossietzky Universität Oldenburg, Abteilung VLBA, Ammerländer Heerstraße 114-118,  
26129 Oldenburg, jan-hendrik.witte@uni-oldenburg.de,  <https://orcid.org/0000-0002-7275-5168>;  
jorge-marx.gomez@uni-oldenburg.de

However, implementing MOT in pig PLF is not without its challenges. Pig farming presents unique obstacles, primarily stemming from the frequent overlapping and occlusion of pigs, often due to behaviors like piling. Coupled with the inherent lack of distinct visual features among pigs, these factors significantly hinder successful long-term tracking, a persistent challenge in pig PLF research.

While research in this domain is ongoing, this paper introduces an alternative approach for image-based activity monitoring of pigs that reduces the reliance on MOT for activity derivation. Instead, our approach divides each video frame of a given sequence into predefined sectors. Within these sectors, the number of pigs and their individual postures are counted using YOLOv8 for pig detection and EfficientNetV2 for posture classification. The overall activity inside a pen between consecutive frames is determined by calculating the differences between the sector counts for each frame at each timestamp.

The paper is structured as follows: The *Related Work* section offers a comprehensive review of existing literature on image-based methodologies in pig activity monitoring. *Materials and Methods* delves deeper into the technicalities of our approach, detailing the data acquisition process, model selection, datasets used, as well as the training and testing environments. In the *Results* section, we present our model's performance, describe our activity derivation method, and draw comparisons with earlier approaches. The *Discussion* section critically analyzes our proposed approach and points out limitations in its application. Finally, the *Conclusion* section encapsulates the paper's key contributions and points toward potential future research avenues.

## 2 Related Work

In contemporary literature, image-based activity monitoring of pigs has garnered notable attention. While some studies directly focus on activity monitoring, others have approached the topic tangentially. Works by Nasirahmadi et al. [Na19], Rieckert et al. [Ri20], and Luo et al. [Lu21] spotlight the potential of determining activities like feeding and resting by monitoring pig postures using OD methods.

A prevalent perspective within these studies is that pig posture can serve as an indicator of anomalous behavior patterns, thus potentially signaling farmers about emerging issues. However, solely monitoring posture limits the scope, as it doesn't account for pig movement. For instance, feeding times, characterized by a high number of standing pigs, may not be differentiated from periods with significant movement inside the pen, such as staff visits or other events that are characterized by a high degree of movement.

A potential solution to capture movement inside the pen lies in OT methods. Unlike OD, which focuses on detection, OT additionally assigns unique identifiers to objects, allowing their trajectories to be predicted across frames [Wa19]. OT can be distinguished into Single Object Tracking (SOT) and Multiple Object Tracking (MOT). In SOT, only individual objects within images are tracked, while MOT aims to track multiple objects of

the same or different classes [Lu14]. In the case of activity monitoring of pigs, the latter is especially relevant.

In terms of MOT, the most common approach breaks the process down into two steps: A *detection* step, in which defined objects are detected and located, and an *association* step, where the detected objects are “[...] assigned and connected to existing trajectories” [Wa19]. This two-stage approach is currently the most common for MOT in the pig PLF domain. Cowton et al. [CKB19] implemented this methodology using Faster R-CNN as a *detection* baseline and Deep SORT for the *association* step with notable success, albeit consistent tracking over extended durations remains a challenge. While using different methods for the *detection* step, other studies, such as those by [Zh19] and [Bh21], reinforce these findings.

In more recent studies, [Pa23] presented a nuanced approach for monitoring group-housed pigs. They employed a graph structure to adeptly handle false negatives within frame batches. This method not only enhanced reidentification but also minimized ID-switches, proving its efficacy for MOT in farm settings. [Me23] used a combination of YOLOv7 and ByteTrack as well as subsequent process mining to analyze and understand the behavioral sequences of fattening pigs. This combination allowed for a comprehensive and detailed study of pig behavior, providing insights that can be crucial for animal welfare and management.

[Wu21] took a divergent approach, using keypoints combined with a Kalman filter for pig body contact detection, showing potential in mitigating challenges posed by overlapping objects in MOT.

While various methodologies and techniques have been explored in the literature for pig activity monitoring, each comes with its own set of challenges. The following section will summarize the specific challenges identified in the current state of the art for pig activity monitoring.

## 2.1 Identified challenges

Literature predominantly highlights two methodologies for pig activity monitoring: one that relies solely on OD and another that integrates both OD and OT. Each approach presents its unique set of challenges. With an exclusive reliance on OD, capturing the dynamic movement of pigs within the pen becomes a limitation, rendering certain activity patterns indistinct. On the other hand, while MOT offers a more comprehensive view, a consistent theme across various studies, despite differences in datasets and methodologies, is the struggle to maintain long-term, error-free tracking.

Recognizing these challenges, our paper introduces a novel method specifically designed to capture pig movement without the reliance on conventional tracking techniques. In the following section, we will detail the materials and methods employed, encompassing data acquisition, model selection, datasets as well as the train and test environment.

### 3 Materials and Methods

In this section, we detail the data acquisition process, followed by the criteria and rationale behind our model selection for the pig detection and classification tasks. We then delve into the specifics of the datasets used, highlighting their sources and the unique challenges they address. Lastly, we describe the computational environment and parameters chosen for training and testing our models.

#### 3.1 Data acquisition

Data was gathered at Lower Saxony Chamber of Agriculture's research farm in Wehnen, Germany, as part of the DigiSchwein project. Video recordings were made in piglet-rearing pens with 24 pigs using an AXIS M3206-LVE camera and in fattening pens with 15 pigs using an AXIS M3116-LVE camera. Cameras were mounted beneath the ceiling to capture the entire pen from a top-down perspective. Piglet rearing recordings began at 20 FPS with a  $2304 \times 1728$  resolution, later reduced to 10 FPS and  $1920 \times 1080$  resolution. Fattening pens were recorded at 20 FPS with a  $2688 \times 1512$  resolution.

#### 3.2 Model selection

In our study, the method of [WJ22], which combines OD for pig detection with IC for posture classification, was employed. The model selection was guided by key criteria derived from PLF system requirements outlined in literature: *Prediction accuracy* [No19], *prediction speed* [Le19] and *cost-effectiveness* for potential deployment on low-end hardware [Ba12].

Given its history in PLF, its balance of speed, accuracy, and resource efficiency, and its robust documentation and community support, the YOLO architecture was selected as our baseline. As of this paper's writing, YOLOv8 is the latest iteration, though without an official paper. YOLOv7, backed by a publication, currently stands as the state-of-the-art for real-time object detection on the COCO dataset due to its new modules and optimization techniques called bag-of-freebies, which enhanced the accuracy compared to previous instalments [WBL22]. Comparing the official implementations of both versions resulted in the selection of YOLOv8 [JAJ23]. For posture classification, we employed EfficientnetV2, which aligns well with our selection criteria, balancing performance and model size [TL21].

#### 3.3 Datasets

Our pig detection model was trained on a dataset of 9,218 images with 146,359 bounding box (BB) annotations, sourced from various projects and public databases. The breakdown of these sources is provided Table 1. Specifically:

| Sources                |             |              |           |          |                |                |
|------------------------|-------------|--------------|-----------|----------|----------------|----------------|
| Source                 | DigiSchwein | Psote et al. | InnoPig   | KoVeSch  | Alameer et al. | Riekert et al. |
| #                      | 3,907       | 2,000        | 1,268     | 720      | 600            | 305            |
| Datasets               |             |              |           |          |                |                |
| Training               |             |              |           |          |                |                |
| Name                   | Task        | Type         | Class     | # images |                |                |
| pig detection          | OD          | full img     | pig       | 9,218    |                |                |
| posture classification | IC          | crop         | lying     | 52,177   |                |                |
|                        |             |              | not lying | 37,871   |                |                |
| Evaluation             |             |              |           |          |                |                |
| pig posture detection  | OD          | full img     | lying     | 2,000    |                |                |
|                        |             |              | not lying |          |                |                |

Tab. 1: Datasets

- 2,000 images were adapted from [Ps19], where we manually added BBs due to the original dataset only having keypoint annotations.
- The KoVeSch (GN 2819109817) and InnoPig (GN 2817205413) projects contributed 720 and 1,268 images respectively, while datasets from [AKB20] and [Ri20] added 600 and 305 images.
- The remaining 3,907 images came from the DigiSchwein project, containing images from various stages of piglet rearing and fattening, capturing a range of sizes and behavioral patterns.

The objective when curating this dataset was to ensure diverse backgrounds, camera angles, lenses as well as lighting conditions, and to address specific challenges in pig livestock farming, like overlapping or occlusion. The dataset includes a limited number of night images, and all images containing persons have been excluded. For the posture classification task, every BB from the detection dataset was cropped, leading to 146,359 images. Of these, 90,048 were labeled either *lying* or *not lying*, split as 52,177 and 37,871 for each class respectively. A total of 2,000 images from the pig detection dataset were relabeled with *lying* and *not lying* annotations to evaluate the performance of the combination of the OD and IC model pipeline for pig posture detection.

### 3.4 Training and testing environment

Model training utilized a workstation with dual Nvidia RTX 3090s (24 GB VRAM each), a Threadripper 3960X, and 64 GB RAM. For pig detection, the YOLOv8 implementation by Jocher et al. [JAJ23] was employed with standard parameters. Augmentations included image mosaic, mix-up, flip, rotation, scaling, and HSV adjustments. Training spanned 300 epochs with a  $640 \times 640$  resolution and a batch size of 128, utilizing the YOLOv8s checkpoint.

| Pig Detection                             |            |           |           |        |             |                  |
|---|------------|-----------|-----------|--------|-------------|------------------|
| Model                                     | Image size | Class     | Precision | Recall | $mAP^{0.5}$ | $mAP^{0.5-0.95}$ |
| YOLOv8s                                   | 640 × 640  | pig       | 0.990     | 0.986  | 0.994       | 0.957            |
| Pig Posture Classification                |            |           |           |        |             |                  |
| Model                                     | Image size | Class     | Precision | Recall | F1-Score    |                  |
| EfficientNetV2 <sub>B0</sub>              | 224 × 244  | lying     | 0.96      | 0.99   | 0.97        |                  |
|   |            | not lying | 0.98      | 0.96   | 0.97        |                  |
| Combination                               |            |           |           |        |             |                  |
| Model                                     | Image size | Class     | Precision | Recall | $mAP^{0.5}$ | $mAP^{0.5-0.95}$ |
| YOLOv8s +<br>EfficientNetV2 <sub>B0</sub> | 640 × 640  | all       | 0.985     | 0.983  | 0.985       | 0.944            |
|   |            | lying     | 0.988     | 0.979  | 0.987       | 0.937            |
|   | 224 × 244  | not lying | 0.982     | 0.987  | 0.984       | 0.950            |

Tab. 2: Model results

For posture classification (*lying*, *not lying*), the EfficientNetV2's PyTorch implementation was adopted, specifically its B0 variant. Augmentation techniques encompassed horizontal flipping, auto contrast, rotation, color jitter, and sharpness adjustments. Cropped images were resized to 224 × 244, adding black borders to retain the original aspect ratio. Model training was conducted over ten epochs, using PyTorch cross-entropy loss and the Adam optimizer. Both OD and IC datasets followed an 80/20 split for training and testing.

## 4 Results

### 4.1 Model performance

The provided Table 2 delineates the performance metrics of different models for given detection and classification tasks. For pig detection, the YOLOv8s model, with an image size of 640 x 640, achieved a precision of 0.990 and a recall of 0.986. The mean average precision (mAP) values, crucial for object detection tasks, stand at 0.994 and 0.957 for the respective thresholds.

When focusing on pig posture classification using the EfficientNetV2B0 model, images of size 224 x 244 were processed. For the *lying* class, the model achieved a precision of 0.96, a recall of 0.99, and a F1-Score of 0.97. Conversely, for the *not lying* class, the results were slightly better in terms of precision, marked at 0.98, but with a slightly lower recall of 0.96; the F1-Score remained consistent at 0.97.



Lastly, the combination of both YOLOv8s and EfficientNetV2B0 models was assessed, representing the model pipeline of pig detection based on OD and subsequent IC of the OD results by the EfficientNetV2. For overall detection (all classes), the precision was 0.985, and recall was 0.983, with mAP values of 0.985 and 0.944 for the two thresholds. Specific to the *lying* class, precision was slightly higher at 0.988, with recall at 0.979. For the *not lying* class, the precision slightly dropped to 0.982, but the recall showed a minor increment, reaching 0.987. We modified the *val.py* method of the YOLOv8 repository to include the EfficientNetV2 model for posture classification in the evaluation process.

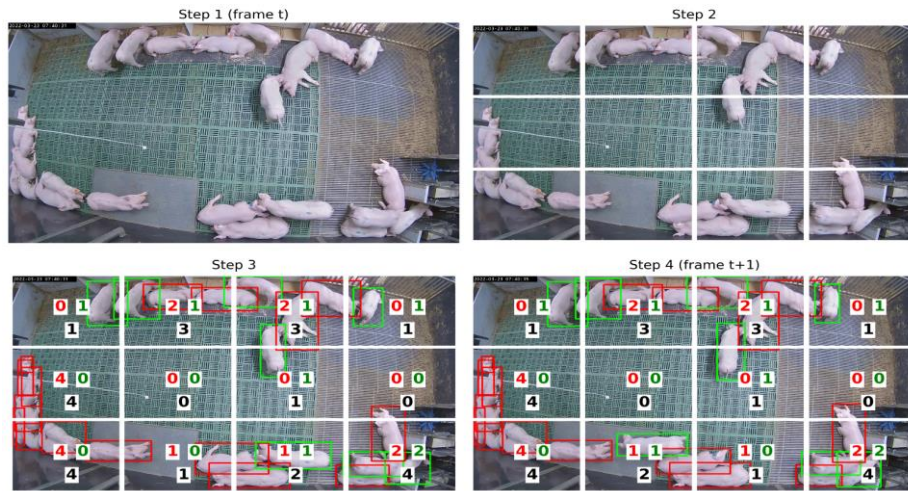


Fig. 1: Activity derivation example

## 4.2 Activity derivation

In this section, we detail the activity monitoring process derived from the model pipeline previously introduced. Our method refines the technique by [Co13], who utilized a software named “Eyenamic” for recognizing activity within pig pens. Rather than merely identifying pixel movements, our approach hinges on comparing successive frames, using outputs from the pig detection and posture classification stages. The step-by-step process for activity derivation is illustrated in Figure 1:

- **Input Frame (Step 1):** This displays the frame captured at timestamp  $t$  in a sequence.
- **Sector Division (Step 2):** The image is segmented into a  $3 \times 4$  grid, dividing it into 12 distinct sectors. While the grid's dimensions can be modified to suit various configurations, this specific size was chosen based on its performance with the applied video data.

- Model Pipeline Output Assignment (Step 3):** the Intersection over Union (IoU) between predicted bounding boxes (BBs) and the sectors guides the allocation. Each BB is linked to the sector it overlaps with the most, eliminating redundancy from BBs overlapping multiple sectors. For clarity, each sector's center displays the total pig count and the count of *lying* vs. *not lying* pigs, color-coded in black, red, and green respectively. The outcome of this stage sets the baseline for subsequent activity derivation.
- Activity Derivation (Step 4):** The process from Steps 1-3 is reiterated for the subsequent frame at timestamp  $t+1$ . The distribution of pigs and their postures from timestamp  $t$  is juxtaposed against  $t+1$ . For instance, in the depicted Step 4, the lower row's middle sectors experienced alterations in object counts. Sectors with changes update their counts, while unchanged sectors remain consistent. The discrepancy between sector counts from  $t$  and  $t+1$  quantifies activity and movement. This difference, denoted as  $d$ , aggregates changes across sectors. The final activity score for frames  $t$  and  $t+1$  is computed by multiplying  $d$  with the ratio of *not lying* to *lying* pigs. This nuanced calculation effectively differentiates high motion sequences from those with medium or low motion. The process is repeated for all sequence frames.

In the following section, we apply the proposed activity derivation method to a video sequence spanning over multiple hours to demonstrate the capabilities to capture different activity levels throughout the day.

### 4.3 Evaluation

Figure 2 demonstrates the results of applying the proposed activity derivation method to an exemplary video sequence spanning from 08:00 to 16:30. The x-axis shows the derived activity values for a given timestamp, normalized between values of 0 and 1. The normalization was conducted retrospectively and in the context of a timespan of multiple days, which is why the values shown in Figure 2 reach a max value of approximately 0.8. Video data is processed with 1 frame per second (FPS) and resampled to 1-minute intervals for better interpretability. Overall, the presented activity index efficiently




Fig. 2: Activity index results

captures the variances in activity over the day, allowing for a discerning interpretation of the activity. The activity level fluctuates between periods of calm and heightened activity. Four distinct sections, shaded in grey, are highlighted, which we retrospectively analyzed in the respective video material: in *Section 1*, the pen experienced its first significant surge in activity due to ambient noise from a neighboring pen. During this period, the pigs exhibited a variety of behaviors, with many engaged in feeding, standing, or exploring, while others were resting. Further into the day, the highlighted *Section 2* revealed a pronounced calm phase. Here, the majority of pigs were resting, punctuated by occasional feeding, or standing moments, indicating an overall state of inactivity. By the late afternoon, *Section 3* captured a marked increase in activity, attributed to episodes of chasing among the pigs. This time frame was the day's zenith of activity, and the sharp delineation of such heightened phases further emphasizes the precision of our index. Following closely, *Section 4* observed another spike in activity, mirroring the vigor of the previous peak, and reinforced the reliability and consistency of our activity monitoring index.

This graphical representation validates the efficacy of the proposed activity index. It discerns between periods with many standing pigs but minimal movement, displayed in the highlighted *Section 1*, and periods characterized by both high standing counts and significant movement, exemplified by the afternoon peaks. This shows the capability of the proposed method to address the limitations identified in Section 2.1 and enables the capturing of movement without applying MOT. In the following sections, we will discuss the remaining limitations of the proposed method.

## 5 Discussion

The introduction of our activity monitoring method has demonstrated potential in capturing activity on a pen-level basis without the use of OT. However, several limitations need to be addressed before it can be applied to agricultural practice.

First, our method, in its current state, serves primarily as a proof of concept. While the preliminary findings are promising, there's an imperative need for broader evaluations on a more extensive set of video data. This will ensure the method's robustness and generalizability. Future evaluations will encompass multiple video samples over extended durations, aiming to discern long-term shifts in pen-level activity.

Secondly, the method's scope is confined to specific scenarios and use cases. It's adept at capturing pen-level activity, making it suitable for monitoring prolonged activity changes in a pen. For instance, in the context of early tail-biting indicators in pigs, several studies have observed increased overall activity preceding an outbreak [La20; LJD20; Ur14]. Our proposed activity index could potentially be used as a foundation to detect such shifts, offering a tool that potentially enables early warnings when the risk of a tail biting outbreak is increasing. However, for use cases requiring individual health monitoring, such as early disease detection of pigs, the method's utility might be limited. While our

paper's intention was to bypass OT methods, integrating them could address this constraint and will be a consideration for future iterations. Due to the way the activity index works, there are instances where no activity can be captured, for example if two pigs simultaneously swap sectors, resulting in no activity change since no changes in the grid counts occurred. Integrating motion tracking could also address these challenges.

Another limitation is the method's inability to precisely locate changes in sector counts, hindering the interpretation of pig movement directions. Addressing this could unveil deeper insights into piglet behavioral patterns, differentiating events like staff visits to the pen from other activities. This aspect merits further exploration in subsequent research.

Lastly, the method's validation is predominantly based on video data from the DigiSchwein project. To ascertain its adaptability, it's pivotal to test it across diverse video datasets. Additionally, exploring the impact of varying grid sizes on the accuracy and precision of activity capture could offer valuable insights into optimizing the method for diverse settings. While the proposed activity monitoring method exhibits potential, it is crucial to acknowledge and address its current limitations to enhance its applicability and efficacy in future endeavors.

## 6 Conclusion

In this study, we developed a new image-based technique for monitoring pig activity at pen level, reducing reliance on traditional OT methods. Utilizing the YOLOv8 model for precise pig detection and EfficientNetV2 for classifying their postures, our approach segments images into predefined sectors. This enables tracking the movement and activity of pigs by comparing sector-based counts in consecutive frames. Our findings demonstrate that this method effectively discerns activity levels and addresses limitations of posture-based monitoring previously noted in OD methods. Future efforts will focus on applying this technique over extended video periods and its potential in detecting long-term behavioral shifts. Further studies are also planned to investigate how different grid dimensions within the pen affect the activity index and to allocate specific attributes to each sector, like identifying key areas for feeding or drinking. This could provide a more nuanced understanding of animal distribution and temporal activity patterns, thereby enriching the activity index's informational value.

**Acknowledgements:** The project is supported (was supported) by funds of the Federal Ministry of Food and Agriculture (BMEL) based on a decision of the Parliament of the Federal Republic of Germany. The Federal Office for Agriculture and Food (BLE) provides (provided) coordinating support for digitalisation in agriculture as funding organisation, grant number 28DE109A18.

The authors extend their gratitude to the project collaborators and the team at the experimental research farm of the Lower Saxony Chamber of Agriculture in Wehnen, Germany. Their invaluable support and provision of animals and accommodation for the project were instrumental.



### Bibliography

- [AKB20] Alameer, A.; Kyriazakis, I.; Bacardit, J.: *Automated recognition of postures and drinking behaviour for the detection of compromised health in pigs*, in: Scientific reports, 10, 2020, S. 13665.
- [Ba12] Banhazi, T. et al.: *Precision Livestock Farming: An international review of scientific and commercial aspects*, in: International Journal of Agricultural and Biological Engineering, 5, 2012, S. 1–9.
- [Bh21] Bhujel, A. et al.: *Deep-learning-based automatic monitoring of pigs' physico-temporal activities at different greenhouse gas concentrations*, in: Animals : an open access journal from MDPI, 11, 2021.
- [Co13] Costa, A. et al.: *The use of image analysis as a new approach to assess behaviour classification in a pig barn*, in: Acta Veterinaria Brno, 82, 2013, S. 25–30.
- [CKB19] Cowton, J.; Kyriazakis, I.; Bacardit, J.: *Automated Individual Pig Localisation, Tracking and Behaviour Metric Extraction Using Deep Learning*, in: IEEE Access, 7, 2019, S. 108049–108060.
- [JAJ23] Jocher, G.; Ayush, C.; Jing, Q.: *YOLO by Ultralytics*, 2023, <https://github.com/ultralytics/ultralytics>.
- [La20] Larsen, M.L.V. et al.: *Movement change detected by optical flow precedes, but does not predict, tail-biting in pigs*, in: Livestock Science, 240, 2020.
- [Le19] Lee, S. et al.: *Practical Monitoring of Undergrown Pigs for IoT-Based Large-Scale Smart Farm*, in: IEEE Access, 7, 2019, S. 173796–173810.
- [LJD20] Li, Y. Z.; Johnston, L. J.; Dawkins, M. S.: *Utilization of optical flow algorithms to monitor development of tail biting outbreaks in pigs*, in: Animals : an open access journal from MDPI, 10, 2020.
- [Lu14] Luo, W. et al.: *Multiple object tracking: A literature review*, 2014, <https://arxiv.org/pdf/1409.7618>.
- [Lu21] Luo, Y. et al.: *Posture detection of individual pigs based on lightweight convolution neural networks and efficient channel-wise attention*, in: Sensors, 21, 2021.
- [Me23] Melfsen, A. et al.: *Describing Behavior Sequences of Fattening Pigs Using Process Mining on Video Data and Automated Pig Behavior Recognition*, in: Agriculture (Switzerland), 13, 2023, S. 1639.
- [Na19] Nasirahmadi, A. et al.: *Deep Learning and Machine Vision Approaches for Posture Detection of Individual Pigs*, in: Sensors (Basel, Switzerland), 19, 2019.

- [No19] Norton, T. et al.: *Review: Precision livestock farming: building 'digital representations' to bring the animals closer to the farmer*, in: *animal*, 13, 2019, S. 3009–3017.
- [Pa23] Parmiggiani, A. et al.: *Don't get lost in the crowd: Graph convolutional network for online animal tracking in dense groups*, in: *Computers and Electronics in Agriculture*, 212, 2023, S. 108038.
- [Ps19] Psota, E. et al.: *Multi-Pig Part Detection and Association with a Fully-Convolutional Network*, in: *Sensors (Basel, Switzerland)*, 19, 2019, S. 852.
- [Ri20] Riekert, M. et al.: *Automatically detecting pig position and posture by 2D camera imaging and deep learning*, in: *Computers and Electronics in Agriculture*, 174, 2020, S. 105391.
- [TL21] Tan, M.; Le V, Q.: *EfficientNetV2: Smaller Models and Faster Training*, 01.04.2021, <https://arxiv.org/pdf/2104.00298>.
- [Ur14] Ursinus, W. W. et al.: *Tail biting behaviour and tail damage in pigs and the relationship with general behaviour: Predicting the inevitable?*, in: *Applied Animal Behaviour Science*, 156, 2014, S. 22–36.
- [Wa19] Wang, Z. et al.: *Towards Real-Time Multi-Object Tracking*, 27.09.2019, <https://arxiv.org/pdf/1909.12605>.
- [WBL22] Wang, C.-Y.; Bochkovskiy, A.; Liao, H.-Y. M.: *YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors*, 06.07.2022, <https://arxiv.org/pdf/2207.02696>.
- [WJ22] Witte, J.-H.; Marx Gómez, J.: *Introducing a new Workflow for Pig Posture Classification based on a combination of YOLO and EfficientNet*, in: Tung Bui (Hrsg.), *Proceedings of the 55th Hawaii International Conference on System Sciences*, Hawaii International Conference on System Sciences, 2022.
- [Wu21] Wutke, M. et al.: *Detecting animal contacts—A deep learning-based pig detection and tracking approach for the quantification of social contacts*, in: *Sensors*, 21, 2021.
- [Zh19] Zhang, L. et al.: *Automatic Individual Pig Detection and Tracking in Pig Farms*, in: *Sensors (Basel, Switzerland)*, 19, 2019, S. 1188.

# Converting data organised for visual perception into machine-readable formats

A new intuitive tool for data preparation and structuring

Alexander Aue <sup>1</sup>, Andrea Ackermann<sup>1</sup> and Norbert Röder <sup>1</sup>

**Abstract:** Spreadsheets are used to store an extraordinary amount of important data. The fact that spreadsheets are both easy to use and allow users a great deal of flexibility in how they store their data is a significant reason why they are so popular. Users often use a variety of layout techniques to make the data easy for humans to understand. But this layout also creates problems for traditional Extract-Transform-Load (ETL) tools. We propose a program that allows users to easily extract data from Excel files by selecting the cells containing the data and metadata thereby determining the data hierarchy. We have used this program to extract data of the Agricultural Structure Survey on land use and livestock in Germany, which does not follow a nationwide standard, leading to large differences in the structuring of the data between the federal states, making it a good benchmark.


**Keywords:** semi-structured data, ETL, no-code, Excel, spreadsheets, data harmonisation


## 1 Introduction

For regional or thematically comprehensive analyses, data must frequently be obtained from different data sources or providers, sometimes digitized, and structurally and contextually merged before analysis. Excel file formats are often used as the data format, as this software is widely available and has low entry barriers. One such use case in Germany is the data from the Agricultural Structure Survey on land use and livestock farming, regularly collected and provided by state agencies (e.g. [SB23]). These data are often not machine-readable because the design of the spreadsheets is optimized for complex structured data with multi-dimensional dependencies. This complexity is structured in a way that humans can understand the data when presented as two-dimensional tables. A variety of layout techniques are used to visually structure the spreadsheets. As the data structure does not follow any standard, leading to substantial differences in data structuring between federal states and sometimes over time, this

---

<sup>1</sup> Thünen-Institute of Rural Studies, Bundesallee 64, 38116 Braunschweig, alexander.aue@thuenen.de,

 <https://orcid.org/0009-0001-8683-3630>; andrea.ackermann@thuenen.de; norbert.roeder@thuenen.de,

 <https://orcid.org/0000-0002-2491-2624>

provision of data poses significant challenges for traditional Extract-Transform-Load (ETL) tools.

In Fig. 1, an example data subset of cattle farms at the state level in Germany is depicted. For the purposes of this demonstration, the original spreadsheet was modified to include only three rows per table, and the alignment of the state heading was adjusted to the left to simplify the visual complexity of the subsequent figures.

| Row no. | Farms with ... to ... Calves and Young Cattle | Farms    | Stock of Calves and Young Cattle | Stock of Cattle | Livestock Total | Agric. Utilised Area |          |
|---------|---|----------|----------------------------------|-----------------|-----------------|----------------------|----------|
|         |   | Quantity |                                  | LU              |                 | Hectares ha          |          |
|         |   | 1        | 2                                | 3               | 4               | 5                    | 6        |
| Germany |   |          |                                  |                 |                 |                      |          |
| 1       | 1 - 9   | 35 237   | 161 349                          | 48 405          | 608 150         | 759 225              | 1112 718 |
| 2       | 10 - 19                                       | 19 705   | 276 477                          | 82 943          | 823 569         | 908 351              | 1025 698 |
| 3       | 20 - 49                                       | 26 140   | 829 799                          | 248 940         | 2297 135        | 2453 837             | 2145 194 |
| Berlin  |   |          |                                  |                 |                 |                      |          |
| 1       | 1 - 9   | 5        | .                                | .               | .               | .                    | .        |
| 2       | 10 - 19                                       | 3        | 53                               | 16              | 231             | 259                  | 251      |
| 3       | 20 - 49                                       | 1        | .                                | .               | .               | .                    | .        |

Fig. 1: Example data subset of the Agricultural Structure Survey on land use and livestock in Germany [SB23]

The table is designed for easy comparison of the count of farms and animals, as well as the associated units, such as quantity, livestock units, and land area in hectares. For statisticians for whom this overview is intended, the data organization would not present any difficulties in understanding the worksheet. However, typical data analysis software encounters challenges with this organization as it typically requires data to be in a relational form. R and Python scripts can bring the data into a structured format, but due to the many special cases and exceptions in the data structures, script development can be very complex.

One of the most widely used no-code ETL tools, Microsoft Power Query, is not suitable for these data. The visual formatting used in the spreadsheets such as layout elements include combinations of wide and long formats in the same table, nested table headers, as well as vertical thematic or regional subdivisions in the worksheet make them non-transformable by Power Query. Additionally, empty cells are used to centre headers vertically and/or horizontally, creating the visual impression of a merged column header, even though the cells remain technically separate.

The problem we aim to address with this paper is to enable ordinary spreadsheet users without programming knowledge to transform spreadsheets organized for visual perception into a relational form. For this purpose, we present a program that allows users to describe the hierarchical and relational structures within a spreadsheet. Using the



description of the data structures, the program generates a relational representation of the data from the spreadsheet as a CSV file.

## 2 Related Work

Our program's closest research counterparts are the Senbazuru project and the FlashRelate project, both of which share the goal of extracting relational data from spreadsheets [Ch13; Ba15].

Senbazuru aims to automatically infer the hierarchical structure within spreadsheets through the creation of a classifier that identifies data frames in the document, along with another classifier that infers the intended hierarchy using a predefined set of features [Ch13]. While Senbazuru offers automated inference of the hierarchical structure, it may occasionally produce errors. In such cases, the tool allows the user to rectify these errors in the hierarchy by manually dragging and dropping nodes to their correct parent locations. Unlike Senbazuru, our program does not automatically infer the hierarchical structure. Instead, our program lets the user decide if the next selection is a child or a sibling of another selection. To speed up the process, selections can be duplicated and moved both horizontally and vertically. Thus, a hierarchy representing a column can be duplicated and shifted over another column, and similarly, a hierarchy representing a table can be duplicated and shifted over another table.

FlashRelate utilizes both positive and negative output examples to generate a program in a domain-specific language called Flare [Ba15]. This approach enables FlashRelate to handle various extraction tasks from diverse spreadsheets, as long as it is possible to identify cells using regular expressions and recognize the spatial arrangement of the cells. In contrast to FlashRelate, our program necessitates the user to manually choose each data cell containing either data or metadata. It does not automatically identify similar cells based on user-provided selections. Instead, our program allows users to select not only individual cells but also sets of cells. Portions of the spreadsheet that represent relational data rather than hierarchical data can be chosen by first selecting the domain of the relation as a set of cells. Typically, the range values of the relation share the same row as the domain values. In a subsequent step, the ranges of the relation can be selected by duplicating the cell set of the domain and moving it horizontally to the desired cells containing the range values.

TableSense is another approach that employs Convolutional Neural Networks to identify tables in spreadsheets [Do19]. In their test with the WebSheet400 dataset, out of 400 random spreadsheets containing 795 tables, TableSense successfully detected 91.3% of the tables (recall), and of the tables detected by TableSense, 86.5% were indeed genuine tables (precision). However, while TableSense excels at detecting table boundaries, it does not identify data hierarchy or extract data from the tables it identifies. Our approach currently does not use artificial intelligence. Our project's primary focus is to empower

users to manually select all the desired data and describe its hierarchy, enabling our program to automatically extract this data into a relational format.

### 3 Methodology

We used the software development kit Flutter to develop a program with a user interface that allows the selection of the cells containing the metadata and data inside the spreadsheet. We refer again to the example from Fig. 1 to describe the necessary steps required for data extraction from spreadsheets. To minimize user interaction, it is advisable to begin by selecting the most abstract meta-information and then progressively narrow down to increasingly specific meta-information until the actual facts are chosen. In Fig. 2, cells are presented as they appear within our program's data selection view after all the selections are made. Additionally, an additional layer with black arrows illustrates the optimal sequence of selections for this example, designed to minimize user interaction. These arrows are numbered from 1 to 7, representing the specific steps of user interaction.

Please note that the program deconstructs merged cells. Cells from which the merged cell was created are displayed as individual cells (e.g. “Quantity” and “LU”). This will be useful for the following selections.

|   | A       | B                                  | C        | D                                | E                                | F               | G               | H                    |
|---|---------|------------------------------------|----------|----------------------------------|----------------------------------|-----------------|-----------------|----------------------|
| 1 | Row no. | Farms with ... to ... Calves and Y | Farms    | Stock of Calves and Young Cattle | Stock of Calves and Young Cattle | Stock of Cattle | Livestock Total | Agric. Utilised Area |
| 2 | Row no. | Farms with ... to ... Calves and Y | Quantity | Quantity                         | LU                               | LU              | LU              | ha                   |
| 3 | Row no. | Farms with ... to ... Calves and Y | Quantity | Quantity                         | LU                               | LU              | LU              | ha                   |
| 4 |         |                                    |          |                                  |                                  |                 |                 |                      |
| 5 | Germany |                                    |          |                                  |                                  |                 |                 |                      |
| 6 |         |                                    |          |                                  |                                  |                 |                 |                      |
| 7 | 1       | 1 - 9                              | 35 237   | 181 349                          | 48 405                           | 608 150         | 759 225         | 1 112 718            |
| 8 | 2       | 10 - 19                            | 19 705   | 276 477                          | 82 943                           | 823 569         | 908 351         | 1 025 698            |
| 9 | 3       | 20 - 49                            | 26 140   | 829 799                          | 248 940                          | 2 297 135       | 2 453 837       | 2 145 194            |

Fig. 2: The data selection view, once all selections are completed, along with an additional layer featuring black arrows indicating the sequence of selections with minimal user interaction

The most abstract meta-information, which is the meta-information shared by most cells, is the country or state in this example (Arrow 1). After that, the header of the domain of the relation is selected (Arrow 2) and then the domain itself will be picked (Arrow 3). While Selections 1 and 2 each selected individual cells, Selection 3 introduces the concept of choosing a set of cells.

Moving on to the first data column, the process involves selecting the first column header (Arrow 4), followed by choosing the second column header (Arrow 5). Now, the first range of the relation is selected (Arrow 6).

If the selection of data were to continue in the same manner, this would involve an additional 15 selections just for the first table, offering no significant improvement over manually creating the relation by simply copying and pasting the cells. However, the

subsequent selections can be automated, given that both the two column headers and the numeric values are located in the same row, each one cell to the right of the previous one. The program's 'Duplicate and Move' function allows these cells to be selected in a single step. To do this, Selection 4 will be chosen, and the duplicate is moved one cell to the right. A slider can be adjusted to determine how many duplicates are to be generated. Each duplicate is moved the same number of cells in the same direction as the previous one. For this example, the slider is set to create 5 duplicates (see Fig. 3). This results in all the selections depicted as arrows labelled 7 in Fig. 2. With this, the first table is captured.




Fig. 3: The user interface to move selections and to duplicate and repeat the step multiple times

The same procedure used to capture the previous 5 columns can be applied to capture the tables arranged below one another. For that, Selection 1 is chosen, then duplicated and moved down by 6 cells. However, the header cells (B1 to H2) are an exception to this, because they do not reappear in the tables below. The program offers a 'freeze' option for this purpose. The 'frozen' cells are duplicated but remain in their original positions during the move. Fig. 4 illustrates how the 'Duplicate and Move' function was employed to capture the lower table by moving all but the 'frozen' selections down by 6 cells (all arrows labelled with the number 8).

|    | A       | B                                  | C        | D                                | E                                | F               | G               | H                    |
|----|---------|------------------------------------|----------|----------------------------------|----------------------------------|-----------------|-----------------|----------------------|
| 1  | Row no. | Farms with ... to ... Calves and Y | Farms    | Stock of Calves and Young Cattle | Stock of Calves and Young Cattle | Stock of Cattle | Livestock Total | Agric. Utilised Area |
| 2  | Row no. | Farms with ... to                  | Quantity | Quantity                         | LU                               | LU              | LU              | ha                   |
| 3  | Row no. | Farms with ... to                  |          |                                  |                                  |                 |                 |                      |
| 4  |         |                                    |          |                                  |                                  |                 |                 |                      |
| 5  | Germany |                                    |          |                                  |                                  |                 |                 |                      |
| 6  |         |                                    |          |                                  |                                  |                 |                 |                      |
| 7  | 1       | 1 - 9                              | 35 237   | 161 349                          | 48 405                           | 608 150         | 759 225         | 112 718              |
| 8  | 2       | 10 - 19                            | 19 705   | 276 477                          | 82 943                           | 823 569         | 908 351         | 025 698              |
| 9  | 3       | 20 - 49                            | 26 140   | 829 799                          | 248 940                          | 297 135         | 453 837         | 145 194              |
| 10 |         |                                    |          |                                  |                                  |                 |                 |                      |
| 11 | Berlin  |                                    |          |                                  |                                  |                 |                 |                      |
| 12 |         |                                    |          |                                  |                                  |                 |                 |                      |
| 13 | 1       | 1 - 9                              | 5        | .                                | .                                | .               | .               | .                    |
| 14 | 2       | 10 - 19                            | 3        | 53                               | 16                               | 231             | 259             | 251                  |
| 15 | 3       | 20 - 49                            | 1        | .                                | .                                | .               | .               | .                    |

Fig. 4: Expansion of the example depicted in Fig. 2, showcasing the final step of selecting the tables arranged one below the other

After the selections are made, the data can be exported as a CSV file as depicted in Fig. 5.

|         |   |         |                                  |          |        |
|---------|---|---------|----------------------------------|----------|--------|
| Germany | Farms with ... to ... Calves and Young Cattle | 1 - 9   | Farms                            | Quantity | 35237  |
| Germany | Farms with ... to ... Calves and Young Cattle | 10 - 19 | Farms                            | Quantity | 19705  |
| Germany | Farms with ... to ... Calves and Young Cattle | 20 - 49 | Farms                            | Quantity | 26140  |
| Germany | Farms with ... to ... Calves and Young Cattle | 1 - 9   | Stock of Calves and Young Cattle | Quantity | 161349 |
| Germany | Farms with ... to ... Calves and Young Cattle | 10 - 19 | Stock of Calves and Young Cattle | Quantity | 276477 |
| Germany | Farms with ... to ... Calves and Young Cattle | 20 - 49 | Stock of Calves and Young Cattle | Quantity | 829799 |

Fig. 5: The first rows of the exported CSV file

## 4 Results

Our student assistants used the program to extract data from more than 500 Excel files. The time taken for each file was determined from a sample of 331 processed Excel files, comprising 3,093 worksheets, with outliers caused by pauses removed. On average, the student assistants needed 15 minutes per file. The range falls between 4 minutes (25% quantile), 7 minutes (median), and 18 minutes (75% quantile) of processing time per file. This results in an average processing time per worksheet of 95 seconds.

## 5 Conclusion and Outlook

We have successfully developed a prototype No-Code ETL tool. Using data from the Agricultural Structure Survey on land use and livestock farming, we showed that our program can be used by users with no programming experience to extract data from Excel files with diverse formats. In the future, we aim to explore how AI can potentially reduce user interaction by providing suggestions for additional selections. Additionally, we plan to integrate data cleansing capabilities into the user interface.

### Bibliography

- [Ba15] Barowy, D. W. et al.: FlashRelate: extracting relational data from semi-structured spreadsheets using examples. ACM SIGPLAN Notices 6/50, pp. 218–228, 2015.
- [Ch13] Chen, Z. et al.: Senbazuru. Proceedings of the VLDB Endowment 12/6, pp. 1202–1205, 2013.
- [Do19] Dong, H. et al.: Tablesense: Spreadsheet table detection with convolutional neural networks: Proceedings of the AAAI conference on artificial intelligence, pp. 69–76, 2019.
- [SB23] Statistisches Bundesamt: Viehhaltung der Betriebe - Fachserie 3 Reihe 2.1.3 - 2020 (Letzte Ausgabe - berichtswise eingestellt). <https://www.destatis.de/DE/Themen/Branchen-Unternehmen/Landwirtschaft-Forstwirtschaft-Fischerei/Tiere-Tierische-Erzeugung/Publikationen/Downloads-Tiere-und-tierische-Erzeugung/viehhaltung-2030213209005.xlsx>, accessed 30 Oct 2023.

## Innovative form generator for recording complex support programmes

Alexander Aue <sup>1</sup>, Andrea Ackermann<sup>1</sup> and Norbert Röder <sup>1</sup>

**Abstract:** In an effort to incentivize environmental protection actions among farmers, different administrations offer various support programmes. These programmes differ between states, change over time and are published in non-machine-readable formats. Since the lack of a nationwide database hampers the comprehensive evaluation of these programmes, we propose a flexible form generator for standardizing the programme descriptions. Our tool meets the needs of researchers as it facilitates the transformation of text-based definitions to a well-structured relational database with its graphical questionnaire user interface. Redundancies in data input are avoided by allowing the collected data of a support program to be inherited by another and to extend it by additional properties or overwriting existing ones. Furthermore, it accommodates complex data collection needs, supporting limitless sub-questions and customized input fields. The resulting hierarchical data is automatically stored in a relational database, ensuring a user-friendly experience both for quantitative researchers and data analysts. This innovative approach enhances the evaluation of e.g. environmental protection programmes.

**Keywords:** form generator, form builder, data collection, unstructured data, data inheritance, hierarchical data, relational data


### 1 Introduction


In order to provide farmers with an incentive to conduct more environmentally friendly farming practices, various administrations offer different support programmes. In the European Union, the programmes funded by the Common Agricultural Policy are of particular relevance [Eu22]. In Germany, the overwhelming majority of the support programmes is designed and administered at regional level [BM23], with the details published in natural language in paper form or as PDF files. In this form, however, the information is not machine-readable. The absence of a nationwide database containing these programmes inhibits the ability to comprehensively characterize, evaluate, and assess them across different funding periods and federal states. Therefore, the need for a nationwide database and a corresponding data collection form becomes evident.

In order to ensure data quality and consistency in a data collection form, it is advisable to avoid free-text inputs. Instead, predefined input methods should be used. This can be

---

<sup>1</sup> Thünen-Institute of Rural Studies, Bundesallee 64, 38116 Braunschweig, alexander.aue@thuenen.de,

 <https://orcid.org/0009-0001-8683-3630>; andrea.ackermann@thuenen.de; norbert.roeder@thuenen.de,

 <https://orcid.org/0000-0002-2491-2624>

achieved through techniques like single-choice and multiple-choice questions, radio buttons, checkboxes, date pickers and numeric inputs. Auto-suggestions can also guide users in providing structured data. By implementing these strategies, data collection becomes more organized, making analysis and management more straightforward while minimizing the risk of inconsistent or inaccurate data.

Existing form software available on the market, like Google Forms or SurveyJS, is typically designed to deliver user-friendly interfaces for standard top-level questions. They can significantly expedite the process of configuring a form compared to developing one from the ground up with the help of software developers. Another option is the Open Data Kit, which allows forms to be created by specifying the form structure within a spreadsheet, allowing greater customisation [Ha10]. However, the intricate nature of support programs cannot be effectively characterized by existing tools: For instance, support measures can extend upon other existing measures by introducing additional properties or modifying existing ones, so called top-ups. In such cases, custom solutions are necessary to accurately capture the details and interdependencies of these measures, which goes beyond the capabilities of readily available form-building tools. Furthermore, existing form builders often fall short in supporting sub-questions and detailed answer customizations. While some form builders do provide the option to present an additional panel or page when a particular answer is selected, these panels or pages are usually limited to organizing questions at the top level.

Consider a scenario where a multiple-choice question includes the same sub-question for every answer option. In a conventional form builder, developers would have to create a separate section for each set of sub-questions and then duplicate these sections for every top-level answer [Sh23; Cr23]. This duplication necessitates the use of unique identifiers to distinguish among them. On the user's end, keeping track of which section corresponds to which answer becomes a cumbersome task, even when dealing with just two levels of questions and answers. For a form that goes beyond two levels and includes three or more levels of nested questions, the process of creating and managing numerous sections representing nested questions becomes increasingly impractical for both developers and users. Matching sections to specific answers grows more challenging as complexity rises.

When handling these multiple nested layers of form fields and predefined values, the question arises about how to store that data. While a hierarchical database format like JavaScript Object Notation (JSON) or a NoSQL database like MongoDB may seem like an option, it results in semi-structured data that is challenging to analyse. A relational database presents a more suitable solution as they are widely adopted in land use research and therefore familiar to users who want to analyse the data.

Since support programmes depend on evolving political goals and vary over time, it becomes necessary to add fields to the form. An effective strategy is to dynamically generate forms based on an easily maintainable configuration, allowing advanced users to define fields and predefined values. As this configuration is then stored in the database, every user can get the updated configurations from the database directly, ensuring that the

form can easily adapt to evolving data collection needs without requiring constant developer intervention and program compilations.

### 1.1 Problem Statement

To address the need for a nationwide database containing support programmes, enabling comprehensive characterization, evaluation, and assessment across different funding periods and federal states, the development of a flexible and easily adaptable form generator is imperative. This form generator should fulfil the data collection requirements for support programmes while maintaining the user-friendliness of a simple relational database for subsequent analysis.

The strategy to achieve this goal is twofold:

1. We present a relational database model capable of storing hierarchical data for multiple-choice form fields and predefined values, with an unlimited number of nested multiple-choice form fields. This model also allows filled-out forms to be inherited by other filled-out forms, enabling the extension of existing forms with additional properties or manipulation of existing ones.
2. We introduce a form application that consumes a simple JSON configuration of the survey structure, specifying the order and types of form fields, along with conditional logic to show or hide certain fields and predefined values. This application stores form data in the relational database and offers features to duplicate existing filled-out forms, inherit them, extend them with additional properties, or overwrite existing properties.

## 2 Methods

### 2.1 Relational database model for support programmes

The relational database model used for storing the collected data is depicted in Fig. 1. This model was designed not only for support programmes but can also be applied for surveys in general. The *survey\_type* table stores the form configuration as JSON in the *structure* column. The configuration for the data collection form for support programmes is represented by a single tuple in the *survey\_type* table. However, the table can be used to store different versions of the form or configurations for forms with entirely different purposes. The *survey* table stores general data about the surveys, including the title, the user who created it, and the creation date, as well as the corresponding form configuration linked via the relationship with the *survey\_type* table.

The *choice\_question\_answers* table contains the collected data for multiple-choice questions. This table links to the *survey* table to track which survey the answer belongs to.

The hierarchical structure enabling sub-questions and sub-sub-questions is established through the fact that tuples in *choice\_question\_answer* can link to other tuples in the same table via the relationship between *parent\_question\_id* and the primary key *id*.

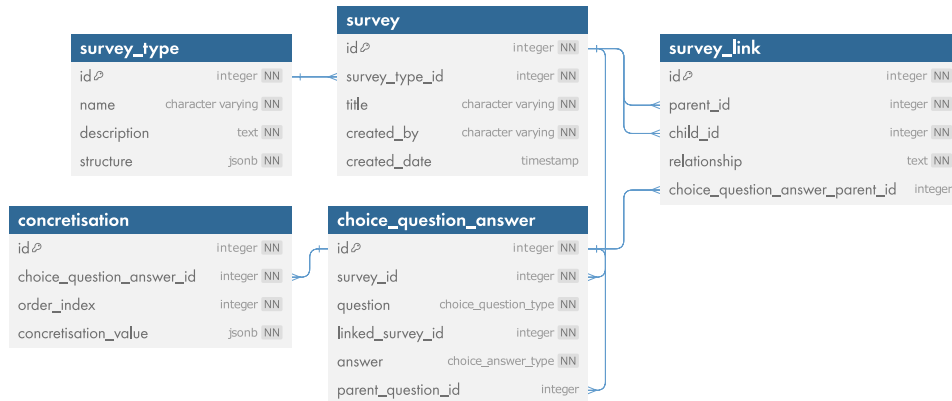


Fig. 1: Relational database model for surveys, including those for support programmes

The *concretization* table allows adding various types of details to each answer, linked through a relationship with the *choice\_question\_answer* table. The form builder supports custom input types tailored for support programmes, including time spans, numeric inputs with a selection of common agricultural units, and free text inputs for other purposes. New types of concretizations can be easily added because the *concretization\_value* is flexible as it is stored as JSON. Finally, the *survey\_link* table allows surveys to inherit from one another and decide which properties to inherit and which to omit.

## 2.2 Form Builder

An excerpt of the form for collecting support programmes is depicted in Fig. 2. For the purpose of this paper, the texts were translated into English. It displays the top-level questions on the left, with the question ‘Fertilization’ currently selected, and it presents the pre-set answers on the right.



Fig. 2: Top-level questions as displayed in the generated form

The answer ‘Restriction to Specific Fertilizers’ allows for more details with the question ‘Fertilizer Type’. Clicking on that question opens the sub-question in the right panel, as shown in Fig. 3 on the left. Similarly, the answer ‘Organic Fertilizer’ can be further specified with the question ‘Organic Fertilizer Type’. Clicking on this question opens the sub-sub-question, depicted in Fig. 3 on the right.

Fig. 3: Second level question (left) and third level question (right)

A simplified excerpt of the configuration for this example, showing only the first two levels and omitting IDs needed for the database, is shown in Listing 1.

```
{ "type": "MultipleChoiceQuestion",
  "title": "Fertilization",
  "choices": [
    { "title": "Reduced Fertilizer Quantity" },
    { "title": "Restriction to Specific Fertilizers",
      "subQuestions": [
        { "type": "MultipleChoiceQuestion",
          "title": "Fertilizer Type",
          "choices": [ { "title": "Organic" } ]
        }
      ]
    }
  ]
}
```

Listing 1: Simplified version of the configuration for the example shown in Fig. 2

### 3 Results

With the presented form generator, a form structure for support programmes was created, consisting of an extensive set of 47 single-choice and multiple-choice questions, along with 366 pre-set values. Using the generated form, over 300 agri-environmental schemes implemented by the German federal states in the CAP support period 2015-2022 were recorded and stored in a standardized database. First relevant queries were tested, such as compiling a complete systematic overview of existing measures.


### 4 Conclusion and Outlook

We have developed and applied a form builder with the capacity to generate data collection forms tailored for support programmes. Throughout the data collection process, new questions and predefined values had to be added frequently. Importantly, their incorporation into the existing form could be achieved without any interruptions in data entry or the intervention of a software developer. The resulting data base is currently being extended by adding remaining schemes from the period 2015-2022 and more importantly by adding the schemes for the time before 2015 and after 2022. This database will be primarily used for the general evaluation of CAP programmes, but also for research on the effectiveness and efficiency of support schemes for the promotion of biotic and abiotic resources.

#### Bibliography

- [BM23] BMEL: CAP-Strategic Plan for the Federal Republic of Germany. [https://www.bmel.de/SharedDocs/Downloads/DE/\\_Landwirtschaft/EU-Agrarpolitik-Foerderung/gap-strategieplan-version-2-0.pdf?\\_\\_blob=publicationFile&v=5](https://www.bmel.de/SharedDocs/Downloads/DE/_Landwirtschaft/EU-Agrarpolitik-Foerderung/gap-strategieplan-version-2-0.pdf?__blob=publicationFile&v=5), accessed 27 Oct 2023.
- [Cr23] Create a Multi-Page Survey | SurveyJS Form Libraries. <https://surveyjs.io/form-library/documentation/design-survey/create-a-multi-page-survey#configure-page-visibility>, accessed 26 Oct 2023.
- [Eu22] European Court of Auditors: Biodiversity on farmland: CAP contribution has not halted the decline. <https://op.europa.eu/webpub/eca/special-reports/biodiversity-13-2020/en/>, accessed 14 Dec 2023.
- [Ha10] Hartung, C. et al.: Open data kit. In (Unwin, T. Ed.): Proceedings of the 4th ACM/IEEE International Conference on Information and Communication Technologies and Development. ACM, New York, NY, pp. 1–12, 2010.
- [Sh23] Show questions based on answers - Google Docs Editors Help. <https://support.google.com/docs/answer/141062>, accessed 26 Oct 2023.

## Akzeptanzprognose zur Einführung eines Energiemanagementsystems in automatisierten Milchviehställen in Bayern – „CowEnergySystem“

Christoph Bader <sup>1</sup>, Jörn Stumpfenhausen<sup>2</sup> und Heinz Bernhardt<sup>1</sup>


**Abstract:** Angesichts des weltweit steigenden Bedarfs entwickelt sich die Ressource Energie zu einem bedeutenden Kostenfaktor in der Agrarwirtschaft. Von dieser Entwicklung sind besonders tierhaltende Betriebe betroffen und vor zusätzliche Herausforderungen gestellt. Durch den gesellschaftlich gewünschten Ausstieg aus der Nutzung fossiler Energieträger treten regenerative Energien verstärkt in den Mittelpunkt. Gerade für landwirtschaftliche Betriebe ergeben sich dadurch bisher ungenutzte Potenziale. Durch Photovoltaikanlagen auf Dächern von Betriebsgebäuden oder die Verwertung von Gülle in Biogasanlagen kann zusätzliche Energie erzeugt werden. Dadurch eröffnet sich die Möglichkeit, preiswerte Energie im Betrieb selbst zu nutzen oder in das öffentliche Stromnetz zu liefern. Im Rahmen des Forschungsprojektes „CowEnergySystem“ soll neben einer betriebsindividuellen Stromerzeugung untersucht werden, welche Möglichkeiten einer effizienten Nutzung dazu beitragen können, die Stromkosten nachhaltig zu senken. Kernelement eines solchen Nutzungskonzeptes stellt ein entsprechendes Energiemanagementsystem (EMS) dar. Erste Erfahrungen aus einem bayerischen Milchvieh-Betrieb lassen auch für andere Betriebszweige und Regionen ähnliche Nutzenpotenziale erwarten. Die erfolgreiche Verbreitung eines derartigen Konzepts wird entscheidend von der Akzeptanz der Nutzer bestimmt. Erste Ergebnisse zur möglichen Akzeptanz dieses EMS sowie wichtige Einflussfaktoren sollen für Bayern vorgestellt werden.

**Keywords:** Regenerative Energien, dezentrale Energieversorgung, Energie-Management-System, Energieeffizienz, Innovation, Markteinführung, Akzeptanz

### 1 Einleitung

Aus der Diskussion über fossile Energieressourcen und der Zielsetzung einer nachhaltigen Energiewende treten in jüngerer Zeit verstärkt intelligente Energiemanagementsysteme (EMS) in den Vordergrund. In Folge inflationsbedingt steigender Produktionsmittelpreise nimmt der Druck zur weiteren Senkung der Kosten zu. In einem solchen Umfeld wachsen die Spannungen zwischen Produzenten, Handel und Verbrauchern [Zi19]. Gleichzeitig ist

---

<sup>1</sup> Technische Universität München, Lehrstuhl Agrarsystemtechnik, Dürmast 10, 85354 Freising, christoph.bader@tum.de,  <https://orcid.org/0009-0007-7419-8741>, heinz.bernhardt@tum.de

<sup>2</sup> Hochschule Weihenstephan-Triesdorf, Fakultät Nachhaltige Agrar- und Energiesysteme, Am Staudengarten 1, 85354 Freising, joern.stumpfenhausen@hswt.de

bislang die Frage ungenügend beantwortet, wie ein entsprechender Stall in Zukunft energetisch aussehen soll und ob es dem Landwirt technisch, aber vor allem auch finanziell möglich sein wird, diesen Anforderungen gerecht zu werden.

In einer derartigen Lage bleibt kein anderer Weg, als die wichtigsten, selbst zu beeinflussenden Triebkräfte in der Bewirtschaftung zu intensivieren, z. B. durch Verbesserung der Produktionseffizienz oder durch Nutzung von Synergieeffekten, zunächst einzelbetrieblich, aber langfristig auch betriebsübergreifend. Die in den letzten Jahren entwickelten Möglichkeiten der Automatisierung speziell in der Nutztierhaltung haben zu einer Steigerung der Leistungsfähigkeit bei parallel verbesserten Haltungsbedingungen geführt [Ga17; Lo18]. Neben der Erzeugung von Milch und Fleisch besitzt ein milchviehhaltender Betrieb das Potenzial zur Energieerzeugung als weiterer Einkommensquelle. Durch die für die Tierhaltung notwendigen baulichen Anlagen besteht die Möglichkeit einer eigenständigen Energieerzeugung vor Ort [SB19].

Auf Basis der bisherigen Forschungsergebnisse „Stall 4.0“ [SB19] und der Entwicklung eines zentralen Monitoring- und Steuermoduls im EMS sind inzwischen zwei Versuchsbetriebe mit derartiger Technik ausgestattet [Ha21]. Dabei werden mit Hilfe von 16 Smartmetern die wichtigsten Energieverbraucher im Stall erfasst, um daraus eine zielgerichtete Laststeuerung umzusetzen. Durch den intelligenten Energieeinsatz ist eine erhebliche Effizienzsteigerung zu erreichen und gleichzeitig die Rolle eines dezentralen Energiedienstleisters möglich, wodurch zusätzlich neue Absatzmärkte erschlossen werden können. Für den Freistaat Bayern wurden im Rahmen einer Studie bis 2020 dazu erste Erhebungen hinsichtlich Akzeptanz und Marktpotenzial bei Milchviehhaltern durchgeführt [SM10].

## 2 Grundlagen

Die Forschungsinitiative „Stall 4.0“ befasst sich seit 2013 mit der praxisorientierten Erarbeitung systemspezifischer Grundlagen und der Konzeption eines On-Farm-Energiemanagement-Systems für Milchviehställe [SB19]. In Kooperation mit Industriepartnern und mit Unterstützung des Bundesministeriums für Ernährung und Landwirtschaft (BMEL) wurde das System zwischenzeitlich zur Marktreife weiterentwickelt und in eine praxistaugliche Hard- und Softwarelösung umgesetzt [SB19]. Auf einem zweiten Versuchsbetrieb wurde inzwischen ein Demonstrator installiert, welcher bei weitgehend autonomer Energieversorgung neue Erkenntnisse für die intelligente Vernetzung relevanter Systemelemente im Rahmen des betriebsindividuellen Lastmanagement liefert [Gr15; Hö15].

Abbildung 1 zeigt die komplexen Strukturen des integrierten EMS mit seinen verschiedenen Einflussbereichen. Im Gegensatz zur Außenwirtschaft (mit ISOBUS-Standard) gibt es für das EMS keine einheitlichen Schnittstellen. Deshalb mussten für jedes Systemelement eigene Aktoren entwickelt werden, um für eine optimierte betriebsinterne Netz- und Kommunikationstechnik zu sorgen. Bei diesen Aktoren handelt es sich um elektronische

Module, die zwischen dem EMS und den einzelnen Energieverbrauchern interagieren und so eine anpassungsfähige Systemintegration gewährleisten.

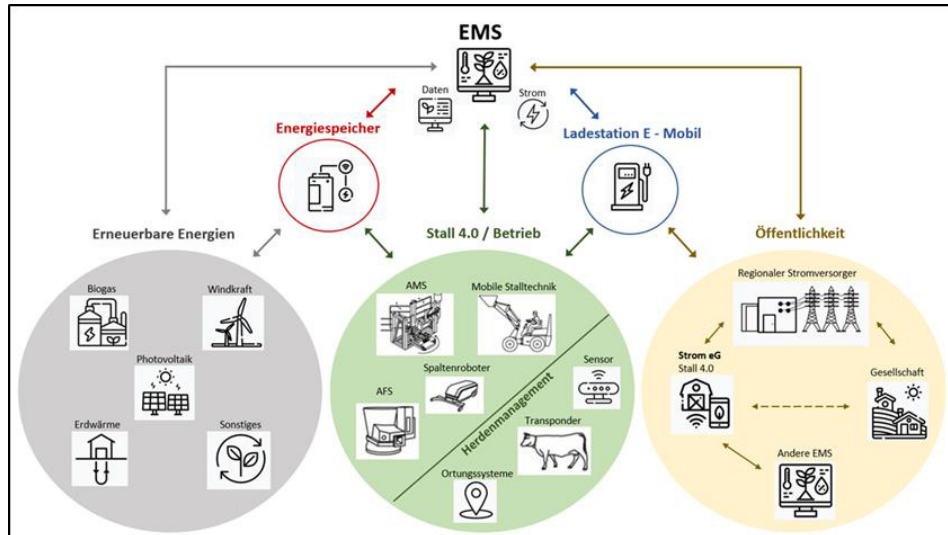


Abb. 1: Integration des On-Farm-Energiemanagementsystems in die Produktionsabläufe eines Milchviehbetriebs

Durch das eigene Sensornetz können alle wichtigen Informationen über ein Cloud-System gespeichert werden. Durch das EMS wird es dann möglich, sowohl Einsatzzeitpunkt als auch -dauer der einzelnen Aggregate mit Abgleich von Energieerzeugung und -verbrauch zu flexibilisieren. Das EMS nutzt weitere prozessrelevante Informationen, wie Leistungsdaten der Milchkuhe, Wetterprognosen und Stallklimadaten, um Echtzeit-Simulationen zu erzeugen [Hö18]. Daraus kann das EMS Rückschlüsse auf den künftigen Energiebedarf ziehen. Das Speicherkonzept muss deshalb eine Diversifikation an Stromverfügbarkeit bereitstellen, damit es die zentrale Steuerung der Energieströme nach Bedarf und Angebot managen kann. Die landwirtschaftliche Energiebereitstellung ist dadurch gekennzeichnet, dass im Durchschnitt mehr Strom erzeugt als durch interne Prozesse verbraucht wird. Der Überschuss kann an das öffentliche Netz abgegeben werden. Der Landwirt dient somit als dezentraler Energiedienstleister im ländlichen Raum, wobei der betrieblich notwendige Energiebedarf immer Vorrang haben muss [Hö18].

### 3 Akzeptanzprognose

Mit der Einführung entsprechender Energie-Konzepte sind umfangreiche Veränderungen für den landwirtschaftlichen Betrieb und sein Management verbunden. Aus der Innovationsforschung geht hervor, dass Erfolg bzw. Misserfolg von Innovationen insbesondere

von deren Akzeptanz am Markt bestimmt werden [MS22]. Vielfach treten in diesem Zusammenhang innerbetriebliche Innovationsbarrieren auf [Mö22], wodurch räumliche und zeitliche Ausbreitung einer Innovation letztlich abhängen (Diffusionsgeschwindigkeit). Bisher durchgeführte Umfragen ergeben zwar eine positive Grundakzeptanz, lassen aber keine genauere Abschätzung der Marktdaption zu.

Mit Hilfe des webbasierten Software-Tools ADOPT (Adoption and Diffusion Outcome Prediction Tool) soll der mögliche Grad der Annahme und Verbreitung für die Zielgruppe der bayerischen Milchviehhalter vorhergesagt werden. Durch das Modellkonzept wird trotz der Multidimensionalität des Fragegegenstands eine leichte Anwendung ermöglicht. Insgesamt 22 Variablen, die für die jeweilige Beurteilung der Innovationsdiffusion analysiert werden, sind in vier Kategorien untergliedert. Diese beinhalten Merkmale zur Innovation selbst und der gewählten Zielpopulation, sowie zum tatsächlichen Nutzen der Innovation und zur Erlernbarkeit des praktischen Innovationseinsatzes [Ku17]. Neben der wahrscheinlichen Adaptionrate und praktischen Verbreitung erfolgt eine Gewichtung dieser Faktoren, welche die Innovationsdiffusion beeinflussen. Dabei wird eine konsistente Umwelt unterstellt; Veränderungen (z. B. bei Preisen oder rechtlichen Aspekten) werden nicht berücksichtigt. Im Praxisvergleich konnten bereits gute Korrelationen zwischen ADOPT-Prognosen und Praxiszahlen für automatische Lenksysteme oder die Direktsaat gefunden werden [Ku17].

Unter einer definiert festgelegten Ausgangssituation und der zugehörigen Variablenbelegung ist bei den bayerischen Milchviehhaltern mit dem Höhepunkt der Markteinführung nach 8 Jahren zu rechnen, die Marktdurchdringung liegt bei einer maximalen Adaptionrate von 98 % (Abb. 2).




Abb. 2: Ergebnis der Prognose des ADOPT-Tools zur Einführung eines EMS in bayerischen Milchviehbetrieben

Zusätzlich analysiert das Programm innerhalb der 22 Belegungsvariablen den jeweiligen Haupteinflussfaktor auf Adaptionrate und -zeit (Abb. 3). Dabei spielt die Unternehmensgröße die wichtigste Rolle. Analog ergibt sich für die Adaptiondauer die Frage nach der „Erprobung“, womit die Erfahrungen der Pioniere beschrieben werden, als entscheidende Einflussgröße (Abb. 3). Zusammenfassend muss jedoch kritisch festgehalten werden, dass im Tool integrierte Verrechnungsalgorithmen nicht ausreichend nachvollziehbar beschrie-

ben sind. Gut verwertbar sind jedoch die Hinweise und Detailergebnisse von Einzelfaktoren, die eine vertiefte Aussage zur Verbreitung möglich machen, wobei alle 22 Eingabvariablen, wenn auch in unterschiedlichem Umfang, Einfluss auf die Zielgrößen haben.

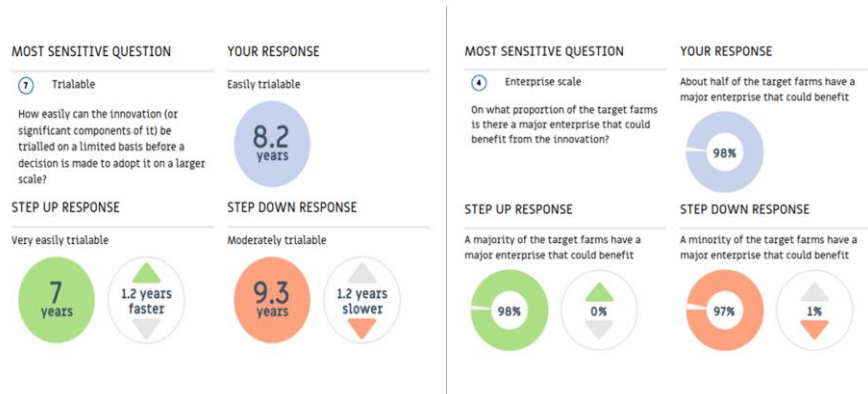


Abb. 3: Haupteinflussvariablen auf die Prognose der maximalen Adaptionshöhe und Dauer eines EMS in bayerischen Milchviehbetrieben (CSIRO ADOPT, 2018)

## 4 Ausblick

In der vorliegenden Untersuchung wurde der Fragestellung nachgegangen, wie sich das von Bernhardt und Stumpenhausen (2013) entwickelte Konzept „Stall 4.0“ mit seinem zentralen Energie-Management-System (EMS) bei bayerischen Milchviehhaltern etablieren lässt. Grundgedanke des Konzeptes ist es, die Energieverbraucher eines Milchviehstalles (Milchgewinnung, -kühlung, Fütterung, Lüftung) mit der Energieerzeugung (Photovoltaik, Biogas, Windenergie) und deren Speicherung so zu kombinieren, dass einzelbetriebliche Energieautarkie, aber auch eine Energievernetzung zur öffentlichen Einspeisung aufgebaut werden können. Dabei interessieren zeitliche Akzeptanz und räumliche Verbreitung bei den Milchviehhaltern. Mit Hilfe des Software-Tools ADOPT wurde dazu eine erste Abschätzung vorgenommen, die von einer hohen Verbreitung (98 %) innerhalb eines Zeitraums von 8 Jahren ausgeht.

Gerade für ein künftiges Vermarktungskonzept sind die Analyse der Einflussfaktoren und der daraus abzuleitenden Maßnahmen wichtig. Im Fokus steht dabei das zielgruppenorientierte, regions- und betriebsangepasste Werben des On-Farm-Energiemanagementsystems. Erste Erfahrungen in Pilotbetrieben lassen darüber hinaus ein weitergehendes Nutzungspotenzial für andere Betriebszweige wie Schweine- und Geflügelhaltung erwarten.

### Literaturverzeichnis

- [Ga17] Gaus, C.-Ch. et al.: Mit autonomen Landmaschinen zu neuen Pflanzenbausystemen. Schlussbericht. Johann Heinrich von Thünen-Institut, Braunschweig, 2017. URL:

- [https://oprints.org/id/eprint/32438/1/32437\\_14NA004\\_011\\_012\\_thuenen\\_institut\\_de\\_Witte\\_Landmaschinen\\_Pflanzenbau.pdf](https://oprints.org/id/eprint/32438/1/32437_14NA004_011_012_thuenen_institut_de_Witte_Landmaschinen_Pflanzenbau.pdf), Stand 20.04.2022.
- [Gr15] Gräff, A. et al.: Effect of a simulated power cut in AMS on milk yield valued by statistics model. , International Journal of Engineering Research and Applications (IJERA), Vol 5, Issue 12, 2015.
- [Ha21] Hartwig-Kuhn, S.: Ein Energiemanagementsystem für den Milchviehhalter. In: Landeskuratorium für tierische Veredlung in Bayern e.V. - LKV [Hrsg.]: LKV-Magazin Ausgabe 3/2021, S. 15-18, München, 2021.
- [Hö18] Höhendinger, M. et al.: Einbindung externer Datenquellen und Komponenten in ein On-Farm Energiemanagementsystem. In: Ruckelshausen, A. et al. [Hrsg.]: Digitale Marktplätze und Plattformen, S. 107-110, Tagungsband 38. GIL-Jahrestagung 26.-27. Februar 2018 Kiel, Gesellschaft für Informatik e.V., Bonn, 2018.
- [Hö15] Höld, M. et al.: Grundlagenerarbeitung zur Implementierung eines On-Farm Energie Management Systems im Milchviehstall In: Ruckelshausen, A., H.-P. Schwarz, und B. Theuvsen, B. [Hrsg.]: Fokus: Komplexität versus Bedienbarkeit / Mensch-Maschine-Schnittstellen, S. 73–76, Tagungsband 35. GIL-Jahrestagung 23.-24. Februar 2015, Geisenheim. Gesellschaft für Informatik e.V., Bonn, 2015.
- [Ku17] Kuehne, G. et al.: Predicting farmer uptake of new agricultural practices: A tool for research, extension and policy, Agricultural Systems 156:115-125, 2017, <https://doi.org/10.1016/j.agsy.2017.06.007>
- [Lo18] Lokhorst, C.: An introduction to smart dairy farming. Hogeschool van Hall Larenstein, NL-Wageningen, 2018.
- [Mö22] Möhrle, M.G.: Innovationsbarrieren. Wirtschaftslexikon Gabler. Springer Fachmedien Wiesbaden GmbH, 2022. URL: <https://wirtschaftslexikon.gabler.de/definition/innovationsbarrieren-38557>, Stand 13.09.2022.
- [MS22] Möhrle, M.G., Specht, D.: Diffusion. Wirtschaftslexikon Gabler. Springer Fachmedien Wiesbaden GmbH, 2022. URL: <https://wirtschaftslexikon.gabler.de/definition/diffusion-29314>, Stand 13.09.2022.
- [SB19] Stumpfenhausen, J., Bernhardt, H.: Integrated Dairy Farming - Ein Forschungsansatz für den Stall 4.0. In: Verein Deutscher Ingenieure - VDI [Hrsg.]: Technik in Bayern. 22. Jgg., H. 02, S. 12-13, 2019, München.
- [SM10] Stumpfenhausen, J., Mutzhas, N.: Marktprognose für „Automatische Melksysteme“ in Bayern bis 2020.- Projektstudie, Dr. Stumpfenhausen Consulting, Pliening, 2010.
- [Zi19] Zinke, O.: Social Lab: Was Verbraucher von Landwirten wollen. agrarheute vom 14.03.2019. Deutscher Landwirtschaftsverlag GmbH, München, 2019. URL: <https://www.agrarheute.com/management/betriebsfuehrung/sociallab-verbraucher-landwirten-wollen-552428>, Stand 30.08.2022.



## Deep Learning-based UAV-assisted grassland monitoring to facilitate Eco-scheme 5 realization

Deepak H. Basavegowda <sup>1,2</sup>, Marina M.-C. Höhne<sup>1,2</sup> and Cornelia Weltzien<sup>1,2</sup>


**Abstract:** Eco-scheme 5 has been introduced to promote biodiversity in permanent grasslands through sustainable land management. While this scheme motivates farmers through result-based remuneration, it also entails a significant monitoring cost in terms of time and money to identify indicators manually. To overcome this burden and facilitate the realization of Eco-scheme 5, we developed an object detection model based on Deep Learning (DL) to automate the indicator species identification. First, we trained and evaluated the model on high-resolution Unmanned Aerial Vehicle (UAV) data. The model achieved an Average Precision (AP) rate of 80.8 AP<sub>50</sub>, but limited training data and the class imbalance problem among indicators affected the model performance. To address these problems, we enriched training data with proximal images of indicators, resulting in a performance gain from 80.8 AP<sub>50</sub> to 95.3 AP<sub>50</sub>. Our results demonstrate the potential of DL and UAV applications in assisting result-based agri-environmental schemes (AES) such as Eco-scheme 5.

**Keywords:** biodiversity monitoring; result-based AES; object detection; cross-domain knowledge transfer

### 1 Introduction

Eco-schemes are a key element of the new European Union (EU) Common Agricultural Policy (CAP 2023-27) and are expected to play an important role in the transformation of European agriculture towards greater sustainability [La20]. Eco-schemes are intended to provide incentives for sustainable farm and land management through direct payments and are open to farmers voluntarily. Under this new direct payment instrument, seven Eco-schemes have been introduced in Germany to reward farmers who voluntarily provide additional ecological services [Bm23]. These schemes have been established based on needs and priorities at the national and regional level and include some well-known provisions such as additional set-aside of arable land or extensification of permanent grassland in favor of biodiversity, crop diversity to improve soil quality and agroforestry systems to sequester carbon and reduce the greenhouse effect.

---

<sup>1</sup> Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB), Agromechatronik; Data Science in der Bioökonomie, Max-Eyth-Allee 100, 14469 Potsdam, Germany {dbasavegowda; MHoehne; CWeltzien}@atb-potsdam.de,  <https://orcid.org/0000-0003-1692-2256>

<sup>2</sup> Technische Universität Berlin, Straße des 17. Juni 135, 10623 Berlin, Germany

Among these seven Eco-schemes, Eco-scheme 5 (“Result-based extensive management of permanent grassland areas with evidence of at least four regional indicator species”) has been introduced to promote biodiversity in permanent grasslands. This scheme is a result-based approach, requiring farmers to demonstrate the presence of at least four regionally typical indicator species on their grasslands to receive financial incentives. Only areas of permanent grasslands are eligible under this scheme, and the indicator species used for the assessment come from a list of species or species groups of species-rich grasslands defined by the respective federal state. It is irrelevant how the eligible grasslands are managed; the only decisive factor is the presence of indicator species [Bm23].

The indicator species are not determined over the entire grassland area but along a diagonal line that runs through the field, identifying the longest possible diagonal line. The defined diagonal is then divided into three sections of equal length, leaving the edge areas. For each marked section, the identified indicator species are recorded. To be considered under Eco-scheme 5, at least four different indicator species must occur in each section. Although this scheme, or any other result-based payment scheme, gives the landowner the freedom to decide what conservation measures to implement, leading to innovation and adaptation, they come with two significant challenges. First, farmers must bear the risk that indicator species may not be observed on their land despite all conservation efforts. Second, the traditional approach to monitoring species-rich grasslands, i.e., identifying indicator species manually by farmers or qualified personnel, comes with high monitoring costs in terms of money and human working hours.

Therefore, there is a need to develop a monitoring system that can autonomously and tirelessly collect and process data to identify indicator species. Furthermore, the sheer size of grassland in Germany (about 5 million hectares) indicates the importance of developing such systems [St17]. To the best of our knowledge, no study has been conducted to identify indicator species using Deep Learning (DL) applied on Unmanned Aerial Vehicle (UAV) imagery, except a few studies focused on identifying indicator or grassland species using close-proximal imagery [Ba22]. In this study, we address this gap by investigating the potential of DL-based UAV-assisted monitoring to identify indicator species. In doing so, we facilitate the realization of Eco-scheme 5.

## 2 Materials and Methods

As depicted in Figure 1, the proposed method involves training an object detection model using UAV and proximal data. Proximal data refers to the use of image sensors in close proximity to the object of interest, i.e., indicator plants in our case. First, we trained the model using only UAV data with limited data samples and an imbalanced class distribution. Second, images from the proximal domain were used as auxiliary data to enrich training data and address the class imbalance problem in the UAV domain. The method is based on the hypothesis that the performance of Deep Learning models can be

improved by enriching training data in a target domain, i.e., the UAV domain in our case, with data from other relevant domains. We collected high-resolution UAV data with a Ground Sampling Distance (GSD) of less than 0.5 mm to detect all selected indicator species regardless of their morphological characteristics (e.g., *Armeria maritima* is a small-sized plant with grass-like leaves). In addition, we preserved the spatial resolution of UAV images by dividing them into smaller tiles to relate the UAV and proximal domains.

## 2.1 Indicator selection

For this study, we selected six distinct indicator plant species: *Armeria maritima* (Grasnelke), *Centaurea jacea* (Wiesen-Flockenblume), *Cirsium oleraceum* (Kohldistel), *Daucus carota* (Wilde Möhre), *Knautia arvensis* (Wiesen-Witwenblume), and *Lychnis flos-cuculi* (Kukucks-Lichtnelke). The selected species are from the list of *High Nature Value* (HNV) indicators considered under Eco-scheme 5 in the northeast region of Germany. *Centaurea jacea*, *Cirsium oleraceum*, *Knautia arvensis*, and *Lychnis flos-cuculi* are commonly used HNV indicators all over Germany. *Armeria maritima* and *Daucus carota* are only used as indicators in the northeast region. The selected species have distinct and diverse morphological features, resulting in different difficulty levels in detection, particularly during the vegetative period.

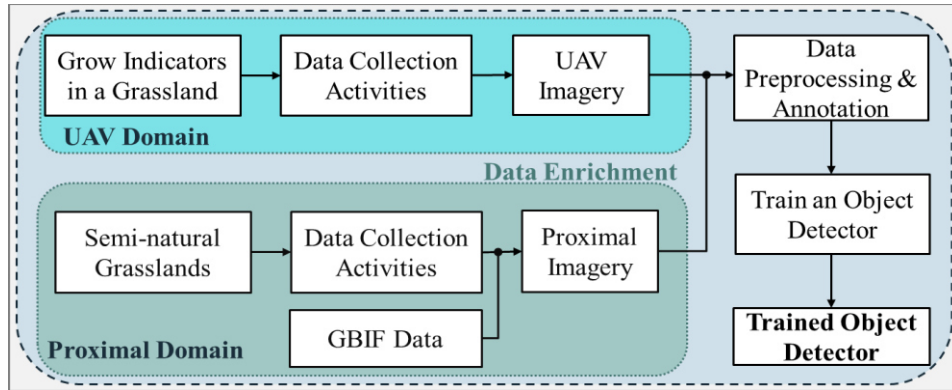


Fig. 1: Overview of the proposed method. The data scarcity and class imbalance problem in the UAV domain was addressed by enriching training data using data from the proximal domain

## 2.2 Data and implementation

One of the main challenges in developing a reliable and robust UAV-based monitoring system for the autonomous identification of grassland species is the availability of extensive training data, as the generalization ability of deep learning models is highly dependent on large and diverse datasets [Ma21]. Species identification is a unique problem

in machine learning because individuals of the same species can look very different, whereas different species can look very similar.

Therefore, data preparation, such as image acquisition, categorization, and annotation, is of great interest while developing such monitoring systems. In the scope of this study, the selected indicators have different ecological requirements and therefore, it is not easy to find them all in one place. For example, *Armeria maritima* is a species of dry grasslands, and *Cirsium oleraceum* is found in moist grasslands. To find all these species in one place and to reduce logistical hurdles, we converted a grassland plot at the research station of the Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB) in Marquardt, Potsdam, Germany, into a species-rich grassland by cultivating all the selected indicator species. The species were planted in 2022 and 2023 on a grassland plot of 20 m x 30 m, with a total count of 100 plants per species. The dataset used in this study consisted of 18880 annotated indicator species (see Tab. 1).

We used a single-stage object detection model based on the EfficientDet architecture [TPL20]. The Average Precision (AP) metric was used to evaluate the model’s performance and was calculated according to the COCO (Common Objects in Context) object-detection evaluation standards [Li14]. In the training process, images were first resized to  $768 \times 768$  pixels. The model was trained for 200 epochs with a total batch size of 12 on four NVIDIA GeForce RTX 2080Ti GPUs, each with 11 GB of memory. TensorFlow 2 and Python 3 were used for the implementation.

| Species Name               | Training Data |                 |                 | Test Data |
|----------------------------|---------------|-----------------|-----------------|-----------|
|                            | UAV           | Proximal (ours) | Proximal (GBIF) | UAV       |
| <i>Armeria maritima</i>    | 771           | 1831            | 455             | 50        |
| <i>Centaurea jacea</i>     | 436           | 1057            | 1488            | 60        |
| <i>Cirsium oleraceum</i>   | 630           | 2500            | 150             | 53        |
| <i>Daucus carota</i>       | 1042          | 1986            | -               | 106       |
| <i>Knautia arvensis</i>    | 518           | 1143            | 1480            | 77        |
| <i>Lychnis flos-cuculi</i> | 488           | 805             | 1700            | 57        |

Tab. 1: Overview of indicator species data used in the study. The numbers represent the image instances of each indicator species under different datasets. Proximal datasets (grey-colored) were only used in training, and the model was evaluated solely on the UAV data (test)

### 3 Results

To validate our method, i.e., enriching training with proximal data to improve the performance of a Deep Learning model on UAV data, we conducted two experiments using UAV and proximal images. First, we trained the object detector using images from the UAV domain, regardless of the number of data samples collected for each indicator species. Second, we enriched training data with images from the proximal domain before training the model as shown in Figure 1. We evaluated both models using UAV test data only, since the intention of using proximal data was to enrich training data.

#### 3.1 Model 1: Trained on UAV data

In this experiment, the model was trained using 3885 image instances of the indicator species. The number of image instances of each indicator species used in training varied between 488 and 1042 (Tab. 1), leading to the class imbalance problem, as some classes had relatively more instances than others. The model evaluated on UAV test data achieved an average precision rate of 42.2 AP and 80.8 AP<sub>50</sub>. As shown in Figure 2, the results are not uniform over all the indicator species. The model performed poorly on *Daucus carota* despite being highly represented within the training data. In the case of *Armeria maritima*, the results are superior to the other species, although this class was the most difficult to identify. This is due to the fact that we did not include images from the vegetative period, as they were impossible to identify without additional distinguishing features, such as flowers.




Fig. 2: Evaluation results. The performance of the different models is demonstrated by the Precision-Recall (PR) curves calculated for each indicator species respectively. We can observe that the model performance significantly improved after training data was enriched with proximal data (right) compared to the model trained with UAV data only (left)

### 3.2 Model 2: Enriching training with proximal data

To investigate the usefulness of proximal data in improving the model's capability to detect indicator species on UAV data, we trained a model using 18480 image instances of indicator species by combining data from proximal and UAV domains. The number of samples of each species ranged from 3030 to 3330. The model evaluated on UAV test data achieved an average precision rate of 58.2 AP and 95.3 AP<sub>50</sub>. Furthermore, the performance of the model against each indicator species improved significantly. For instance, the performance against *Daucus carota* improved from 24.7 AP to 44.3 AP.

## 4 Discussion

This study aimed to investigate the potential of DL-based UAV-assisted monitoring to facilitate Eco-scheme 5 realization in Germany. For this purpose, we developed the object detection model to detect indicator species on UAV imagery. Considering the limited data availability in the UAV domain, we used data from the proximal domain to enrich the training to improve the performance of the model. The significant improvement in the performance of the model after enriching the training with proximal images indicates the usefulness of the proposed method when limited data is available in the target domain. In summary, our results demonstrate the potential of DL-based UAV-assisted monitoring to facilitate the implementation of Eco-scheme 5 and open up a wide range of use cases in grasslands, such as invasive or toxic plant species identification.

### Bibliography

- [Bm23] BMEL: Umsetzung der Gemeinsamen Agrarpolitik der Europäischen Union 2023 in Deutschland, <https://www.bmel.de/SharedDocs/Downloads/DE/Broschueren/gap-2023.html>, 24.10.2023.
- [Ba22] Basavegowda, Deepak Hanike et al.: Indicator plant species detection in grassland using EfficientDet object detector, S. 6, 2022.
- [Li14] Lin, Tsung-Yi et al.: Microsoft COCO: Common Objects in Context. In: Fleet, D. et al. (Hrsg.): Computer Vision – ECCV 2014, Lecture Notes in Computer Science. Cham: Springer International Publishing, 2014 — ISBN 978-3-319-10602-1, S. 740–755.
- [La20] Lampkin, Nic et al.: Using Eco-schemes in the new CAP: a guide for managing authorities, IFOAM EU, FiBL and IEEP, Brussels, 2020.
- [Ma21] Madan, Spandan et al.: When and how CNNs generalize to out-of-distribution category-viewpoint combinations, arXiv (2021). — arXiv: 2007.08032 [cs]
- [St17] Stenzel, Stefanie et al.: Identification of high nature value grassland with remote sensing and minimal field data. In: Ecological Indicators Bd. 74, S. 28–38, 2017.
- [TPL20] Tan, Mingxing; Pang, Ruoming; Le, Quoc V.: EfficientDet: Scalable and Efficient Object Detection. In: arXiv:1911.09070 [cs, eess] (2020). — arXiv: 1911.09070

## Comparison of UAV- and mowing machine-mounted LiDAR for grassland canopy height estimation

Justus Bracke<sup>1</sup> , Marcel Storch<sup>2</sup> , Janis Bald<sup>3</sup>  and Thomas Jarmer<sup>2</sup> 

**Abstract:** Towards autonomous process monitoring, canopy height estimation in grassland based on data from a mowing machine-mounted LiDAR and a UAV-LiDAR system is compared to manually measured ground truth heights. In a field trial, a LiDAR mounted on the cabin roof of the mowing machine recorded data during the mowing process, while two recording flights before and after the mowing were conducted with a UAV-LiDAR. The data from both systems were processed similarly and parameters such as height estimation method, spatial resolution and percentile filters were systematically varied to investigate their influence on height estimation accuracy. Statistical evaluation showed that canopy height estimates based on the UAV-LiDAR ( $R^2 = 0.89$ , RMSE = 0.05 m) were more accurate and precise than those based on the mowing machine-mounted LiDAR ( $R^2 = 0.51$ , RMSE = 0.08 m). The influence of the different investigated parameters varied.


**Keywords:** LiDAR, UAV, machine-mounted sensors, grassland, canopy height estimation



### 1 Introduction


Knowledge about the small-structured canopy height distribution of grassland is essential for a differentiated biomass estimation [SKF87]. In addition, canopy height differences may reveal anomalies within a field which could be the basis for a more site-specific crop management or the adjustment of process settings.

Many approaches estimate the canopy height of grassland based on data from UAV-attached cameras and structure-from-motion techniques [Zh18]. Some studies have compared these approaches with estimates from ground-based LiDAR systems [Ob20; GAW21]. Canopy height estimation based on UAV-LiDAR systems has so far only been investigated in other field crops such as wheat [HBK20]. For these crops, there are also studies where LiDAR systems were mounted on real agricultural machines to estimate the crop height [Wa19; LM13]. This study compares the estimation of canopy height in grassland based on data from a mowing machine-mounted LiDAR and a UAV-LiDAR system.

---

<sup>1</sup> German Research Center for Artificial Intelligence, Research Department Plan-based Robot Control, Hamburger Straße 24, 49084 Osnabrück, justus.bracke@dfki.de,  <https://orcid.org/0009-0003-6901-8268>

<sup>2</sup> Osnabrück University, Inst. of Computer Sc., Wachsbleiche 27, 49090 Osnabrück, macel.storch@uos.de,  <https://orcid.org/0000-0001-5726-6297>, thomas.jarmer@uos.dea  <https://orcid.org/0000-0002-4652-1640>

<sup>3</sup> University of Applied Science Osnabrück, Fac. of Agric. Sc. and Landscape Architecture, Am Krümpel 31, 49090 Osnabrück, a,  <https://orcid.org/0000-0002-0512-7735>

## 2 Data Acquisition

A structured experiment was conducted on a 1.6 ha large grassland field in Recke, north-western Germany. On 10 May 2023, the field was mowed for the first time that year using a high-capacity self-propelled mower conditioner, the Big M 450 from KRONE. The machine's working width divided the field into nine lanes, each approximately 10 meters wide and oriented in a north-south direction.

The height of the grassland was measured manually at 86 systematically arranged plots along the lanes in the morning before the mowing. Two methods were used for ground truth data collection. The first method consists of a ruler which was placed in the canopy. The height was then assessed by comparing the average height of the highest blades of grass in the immediate vicinity with the ruler. The assessment was consistently conducted by a single grassland survey expert, to prevent a variable bias in the measurements. The second method was similar to the Rising Plate Meter used by O'Sullivan et. al [SKF87]. A styrofoam plate measuring 0.5 m × 0.5 m with a center hole for a ruler was placed on top of the canopy and the height was then read off from the ruler. Both methods were applied once after each other on the same position in a plot and the exact location was measured using a RTK-GNSS receiver.

UAV-LiDAR data acquisition took place on two flight dates: one flight on 8 May 2023 before the mowing and one flight on 15 May 2023 after the mowing and collection of the cut grass. The system used was a RIEGL miniVUX-1UAV laser scanner mounted on a DJI Matrice 600 multicopter drone in a nadir down-facing angle. The scanner had a rotation frequency of 29 Hz, a range accuracy of ±1.5 cm and a precision of ±1 cm. A flight altitude of 20 m above ground in combination with a flight speed of 5 km/h and a lateral overlap of 40% between two adjacent flight strips resulted in an average laser shot density of approx. 670 pulses/m<sup>2</sup>. Each shot had a footprint of 3.2 × 1 cm ellipsoid. The flight and scan parameters were kept identical for both flights.

Additionally, data was recorded during the mowing process using a sensor carrier with an Ouster OS1-64 LiDAR attached to the cabin roof of the mowing machine. The LiDAR was mounted 4 m above the ground at a 45° angle relative to the ground level. A measurement area measuring 2 m in length and 6 m in width was defined in front of the machine. The center point of this area was 3.42 m before the sensor mounting position in the driving direction on the central longitudinal axis of the machine. Inside the measurement area, the average point density of the Ouster LiDAR was 325 points/m<sup>2</sup> with an average footprint of the laser beam being a circle with a diameter of 2.72 cm. The LiDAR sensor had a rotation frequency of 10 Hz, a range accuracy of ±3 cm and a precision of ±1 cm.

The mowing machine operated at a driving speed of 10 km/h and the cutting height was set to approx. 17 cm. All recorded sensor data was georeferenced by RTK-GNSS coordinates.



### 3 Data Processing

The UAV data was processed according to [Br17]. First, the raw flight trajectory of the drone was corrected by using GNSS reference data recorded from a RTK-referenced base station in the field. The GNSS post-processing resulted in the Smoothed Best Estimate of Trajectory (SBET). Second, this trajectory was subsequently combined with the raw range measurements acquired by the laser scanner and globally registered into one consistent point cloud in the global WGS-84 coordinate reference system. The processing steps were performed using proprietary software associated with the Inertial Measurement Unit (Applanix POSPac UAV) and the scanner (RIEGL's RiPROCESS) of the UAV.

The data from the LiDAR mounted on the mowing machine (MoM) was processed using a Python-based script that utilized the open-source library Open3D. Each individual point cloud was processed for every ground truth measurement position, rather than being globally registered into one large point cloud. First, from the data stream of the sensor carrier, the GNSS message with the spatially closest position information to the respective ground truth point was identified. Next, based on the timestamp of the messages, the temporal closest point cloud message to that GNSS message was determined. This step was necessary because the GNSS sensor on the carrier only operated with 8 Hz. Because of the time difference of the two messages, the position information from the GNSS message was corrected based on the current speed and heading of the machine and transformed to the center point of the measurement area in front of the machine. The raw point cloud itself was cropped to the size of the measurement area after rotating the local sensor coordinate system by  $45^\circ$  to align the z-axis perpendicular to the ground.

The determination of the canopy height using LiDAR in general is done by subtracting the measured distance to the canopy top from the distance to the ground. Therefore, the identification of LiDAR data points that represent the ground is crucial [HBK20]. The generation of a digital terrain model (DTM) from these points is challenging in grassland vegetation due to the high-density coverage, which results in insufficient ground information [Zh18]. As a result, reference measurements were taken at ground level after mowing the field. The LiDAR mounted on the mowing machine maintained a constant distance from the ground, requiring only one reference measurement on a grass-free area of the field. To create the DTM from the UAV data, a second flight was conducted five days after mowing.

The individual point clouds of the MoM-LiDAR and the global point cloud of the UAV were both rasterized into a regular grid. Three different spatial resolutions of 0.2, 0.4 and 0.6 m for the raster fields were tried in order to analyze the effect of raster field size on the estimation accuracy. Based on the reference measurements, the canopy height for each raster field was determined with two different methods. Subtracting the lowest ground point from the highest canopy point was called the minmax-method (mm). The second method was called average-method (avg) where the average height of the ground points got subtracted from the average height of the canopy points. To investigate the influence

of outliers a percentile filter was applied. For every spatial resolution and system, the top percentile value was decreased from 100% in 0.5% steps to 50% to identify the best fitting percentile value.

The canopy height estimates from both LiDAR systems, each processed by both methods for every raster resolution with and without percentile filter were statistically compared to both measured ground truth heights. The mean error (BIAS) and the root mean square error (RMSE) between the estimates and the ground truth measurements were calculated to quantify the accuracy while the coefficient of determination ( $R^2$ ) of a linear regression was calculated to quantify the precision.

## 4 Results and Discussion

The comparison between the two ground truth measurement methods showed that the plate-based method (GT\_plate) delivered slightly lower height values with less variance compared to the ruler-based method (GT\_ruler) (Tab. 1). This was reasonable because the weight of the styrofoam plate pushed slightly down the tips of the grass blades.

| method   | median | mean | standard deviation |
|----------|--------|------|--------------------|
| GT_ruler | 0.72   | 0.70 | 0.12               |
| GT_plate | 0.71   | 0.68 | 0.11               |

Tab. 1: Ground truth grassland canopy height measurements (all values in meter)

The results of the statistical comparison between the canopy height estimates based on the UAV- and the MoM-LiDAR to the ground truth measurements showed a general trend. Across all settings, the UAV-based estimates were more accurate and more precise (Tab. 2). The detailed analysis showed that the influence of the varied parameters on the estimation quality was different.

The results of the average-method delivered in general more precise (higher  $R^2$ ), but less accurate (lower RMSE) estimates of the canopy height compared to the minmax-method, but the precision of the minmax-method increased to the same level when the percentile filter was applied. The filter also reduced the BIAS of the minmax-method to nearly zero. Compared to the ground truth measurements, both LiDAR systems showed a higher precision to the plate method than to the ruler method. For both ground truth methods, the accuracy was on the same level for the minmax-method, but for the average-method the accuracy of the ruler method was worse. The influence of the percentile filter was comparable in this case. The spatial resolution of the raster influenced only the precision in case of the average-method. For larger spatial resolutions, the precision improved for the MoM system while it decreased for the UAV system. The accuracy remained at the same level for both systems. In case of the minmax-method, the precision and accuracy decreased for both systems for larger spatial resolutions. The improvement of the estimates by the percentile filter was higher for the larger spatial resolutions. The overall comparison resulted

in different best fitting top percentile values depending on the spatial resolution and the LiDAR system (Tab. 2). The percentile values were significantly lower for the MoM-LiDAR than for the UAV-LiDAR. This matched the general observation that the estimates based on the MoM-LiDAR system tended to be higher and scattered more.

Compared to the plate ground truth the best processing method for the UAV-LiDAR system was the 0.2 m minmax-method which results in a  $R^2$  of 0.89 and a RMSE of 0.05 m. The best method for the MoM-LiDAR system was the 0.6 m minmax-method together with a 65.5% top percentile filter which results in a  $R^2$  of only 0.51 and a RMSE of 0.08 m. Both systems were underestimating the ground truth height in these cases.

There are several possible reasons for differences between the systems. Firstly, the angle and the footprint of the two LiDAR systems were different. The much larger footprint of the UAV-LiDAR might have led to an averaging out effect of small grass tips and therefore, to reduced height estimates with less larger outliers. The driving speed of the mowing machine was twice as high as the flight speed of the UAV while the rotation frequency of the MoM-LiDAR was a third compared to the UAV-LiDAR. There were also shock and vibration influences from the machine during the mowing process on the LiDAR, which might have had a negative influence on the measurements. Especially pitch movements of the machine might have changed the distance to the ground compared to the used reference distance. Detailed test trials like those from [Bl20] are needed to further investigate and quantify these influences.

| method              | raw data     |       |      |       |      |       | percentile filtered data |       |                |       |                |       |
|---------------------|--------------|-------|------|-------|------|-------|--------------------------|-------|----------------|-------|----------------|-------|
|                     | 0.2          |       | 0.4  |       | 0.6  |       | 0.2                      |       | 0.4            |       | 0.6            |       |
|                     | mm           | avg   | mm   | avg   | mm   | avg   | mm                       | avg   | mm             | avg   | mm             | avg   |
| <b>GT_ruler_UAV</b> |              |       |      |       |      |       | top perc. 100            |       | top perc. 94.0 |       | top perc. 89.0 |       |
| $R^2$               | <b>0.85</b>  | 0.83  | 0.73 | 0.76  | 0.55 | 0.70  | 0.85                     | 0.83  | 0.75           | 0.77  | 0.67           | 0.71  |
| RMSE                | <b>0.06</b>  | 0.15  | 0.06 | 0.14  | 0.09 | 0.13  | 0.06                     | 0.15  | 0.06           | 0.16  | 0.07           | 0.15  |
| BIAS                | <b>-0.04</b> | -0.14 | 0.01 | -0.13 | 0.05 | -0.12 | -0.04                    | -0.14 | -0.03          | -0.15 | -0.02          | -0.14 |
| <b>GT_plate_UAV</b> |              |       |      |       |      |       | top perc. 100            |       | top perc. 94.0 |       | top perc. 89.0 |       |
| $R^2$               | <b>0.89</b>  | 0.87  | 0.81 | 0.84  | 0.66 | 0.80  | 0.89                     | 0.87  | 0.83           | 0.84  | 0.78           | 0.80  |
| RMSE                | <b>0.05</b>  | 0.13  | 0.06 | 0.12  | 0.09 | 0.11  | 0.05                     | 0.13  | 0.05           | 0.14  | 0.05           | 0.14  |
| BIAS                | <b>-0.03</b> | -0.12 | 0.03 | -0.11 | 0.07 | -0.10 | -0.03                    | -0.12 | -0.01          | -0.13 | -0.01          | -0.13 |
| <b>GT_ruler_MoM</b> |              |       |      |       |      |       | top perc. 89.5           |       | top perc. 89.5 |       | top perc. 65.5 |       |
| $R^2$               | 0.37         | 0.40  | 0.31 | 0.41  | 0.29 | 0.44  | 0.40                     | 0.40  | 0.37           | 0.42  | <b>0.44</b>    | 0.45  |
| RMSE                | 0.11         | 0.16  | 0.12 | 0.15  | 0.13 | 0.14  | 0.11                     | 0.16  | 0.10           | 0.15  | <b>0.09</b>    | 0.17  |
| BIAS                | 0.01         | -0.11 | 0.05 | -0.11 | 0.08 | -0.11 | -0.01                    | -0.12 | 0.02           | -0.12 | <b>-0.01</b>   | -0.14 |
| <b>GT_plate_MoM</b> |              |       |      |       |      |       | top perc. 89.5           |       | top perc. 89.5 |       | top perc. 65.5 |       |
| $R^2$               | 0.44         | 0.47  | 0.39 | 0.48  | 0.36 | 0.50  | 0.47                     | 0.47  | 0.44           | 0.49  | <b>0.51</b>    | 0.52  |
| RMSE                | 0.10         | 0.14  | 0.11 | 0.13  | 0.14 | 0.13  | 0.10                     | 0.14  | 0.10           | 0.14  | <b>0.08</b>    | 0.15  |
| BIAS                | 0.02         | -0.10 | 0.07 | -0.10 | 0.10 | -0.10 | 0.01                     | -0.10 | 0.03           | -0.10 | <b>0.01</b>    | -0.13 |

Tab. 2: Descriptive statistics of the experiment (all values in meter except  $R^2$ , top percentile in %)

## 5 Conclusion

The comparison of the two LiDAR systems revealed that canopy height estimates based on the UAV-mounted LiDAR were more accurate and precise than those based on the mowing machine-mounted LiDAR. The used minmax-method in combination with a top percentile filter delivered the best estimates for both systems. The effect of the top percentile filter and the spatial resolution of the sampling area was different for the systems.

**Acknowledgements:** We would like to thank Maschinenfabrik Bernard Krone GmbH & Co. KG company for their support during the field experiments and for providing the machines, special thanks to Viktor Martel and Roman Weisgerber. This work was supported by the German Federal Ministry for Economic Affairs and Climate Action within the Agri-Gaia project (grant numbers: 01MK21004A & 01MK21004K). The German Research Center for Artificial Intelligence in Lower Saxony is sponsored by the Ministry of Science and Culture of Lower Saxony and the Volkswagen Foundation.

### Bibliography

- [Bl20] Blanquart, J.-E. et al.: Online crop height and density estimation in grain fields using LiDAR. *Biosystems Engineering* 198, pp. 1-14, 2020.
- [Br17] Brede, B. et al.: Comparing RIEGL RiCOPTER UAV LiDAR derived canopy height and DBH with terrestrial LiDAR. *Sensors* 17/17, pp. 2371:1-2371:16, 2017.
- [GAW21] Grüner, E.; Astor, T.; Wachendorf, M.: Prediction of Biomass and N Fixation of Legume-Grass Mixtures Using Sensor Fusion. *Frontiers in Plant Science* 11, no. 603921, 2021.
- [HBK20] ten Harkel, J.; Bartholomeus, H.; Kooistra, L.: Biomass and crop height estimation of different crops using UAV-based LiDAR. *Remote Sensing* 12/20, pp. 17:1-17:18, 2020.
- [LM13] Long, D. S.; McCallum, J. D.: Mapping straw yield using on-combine light detection and ranging (lidar). *International Journal of Remote Sensing*, vol. 34, no. 17, pp. 6121-6134, 2013.
- [Ob20] Obanawa, H. et al.: Portable LiDAR-Based Method for Improvement of Grass Height Measurement Accuracy: Comparison with SfM Methods. *Sensors* 17/20, no. 4809, 2020.
- [SKF87] O’Sullivan, M.; O’Keeffe, W. F.; Flynn, M. J.: The Value of Pasture Height in the Measurement of Dry Matter Yield. *Irish Journal of Agricultural Research*, vol. 26, no. 1, pp. 63–68, 1987.
- [Wa19] Walter, J. D. C. et al.: Estimating Biomass and Canopy Height With LiDAR for Field Crop Breeding. *Frontiers in Plant Science* 10, no. 1145, 2019.
- [Zh18] Zhang, H. et al.: Estimation of grassland canopy height and aboveground biomass at the quadrat scale using unmanned aerial vehicle. *Remote Sensing* 10/18, pp. 851:1-851:19, 2018.

## The FAIR-Device – an AI image recognition-based non-lethal and generalist monitoring system for insect biodiversity in agriculture

Juan A. Chiavassa<sup>1</sup>, Martin Kraft<sup>2</sup>, Patrick Noack<sup>1</sup>, Simon Walther<sup>3</sup>, Ameli Kirse<sup>4</sup> und Christoph Scherber<sup>4,5</sup>

**Abstract:** Agriculture is influenced by pest insects, but also has a considerable impact on general insect biodiversity. Insect field monitoring is essential for understanding their abundance, diversity, and dynamics in ecosystems, including pest distribution, control measures, and prediction of pest outbreaks. However, traditional monitoring systems can present difficulties leading to a limited temporal and spatial resolution of the information obtained. To resolve these limitations, automatic insect monitoring traps have been developed. However, most of them address only agricultural pests and are not suitable for monitoring a generalist population of insects. This limits their use for assessing the respective impact of different crop management practices. The Field Automatic Insect Recognition (FAIR)-Device is a novel generalist field device that provides high-resolution data for evaluating insect diversity. Proof of concept tests demonstrated the potential of the FAIR-Device as a low-cost, non-lethal tool for insect monitoring.

**Keywords:** e-traps, smart traps, automatic trap, integrated pest management, biodiversity monitoring, sensor-based monitoring, iNaturalist

### 1 Introduction

Preserving and enhancing biodiversity is crucial from both an economic and ecological perspective. Insects play a vital role in providing ecosystem services such as pollination and being an important link in food chains. Agriculture has a significant impact on insect species richness and diversity by influencing their habitat in various ways. Various measures to support insect biodiversity in agriculture have been or are being developed, such as flowering strips, beetle banks, controlled row farming, and strip cropping. These measures aim to maximize crop diversity per area while also supporting insect biodiversity.

---

<sup>1</sup> Weihenstephan-Triesdorf University of Applied Sciences; Neuseser Str. 1, 91732 Merkendorf, juan.chiavassa@hswt.de / juan.chiavassa@gmail.com; patrick.noack@hswt.de

<sup>2</sup> Thünen Institute of Agricultural Technology; Bundesallee 47, 38116 Braunschweig, martin.kraft@thuenen.de

<sup>3</sup> Weihenstephan-Triesdorf University of Applied Sciences, Am Staudengarten 1, 85354 Freising; simon.walther@hswt.de

<sup>4</sup> Leibniz Institute for the Analysis of Biodiversity Change (LIB), Museum Koenig, Centre for Biodiversity Monitoring and Conservation Science, Bonn, A.Kirse@leibniz-lib.de; C.Scherber@leibniz-lib.de

<sup>5</sup> Institute of Evolutionary Biology and Ecology, University of Bonn, Bonn

While these approaches promise to increase insect biodiversity, the availability of data to judge their effectiveness is limited. The main reason is that implementing traditional monitoring systems, such as Malaise traps, tends to be labor-intensive and requires considerable entomological expert knowledge, thus making it impractical to realize a high spatial and temporal resolution of gathered data. However, new developments in automatic insect monitoring systems seek to resolve these difficulties and limitations. Electronic traps (e-traps) are now available to replace traditional insect monitoring by providing real-time, continuously analyzed data at unprecedented temporal and spatial scales. Recently developed e-traps involve sensor technologies for image acquisition [PVA21]. Still, most of them focus on the study of agricultural pests and are not suitable for monitoring a generalist population of insects, which limits their use to evaluate the respective impact of different crop management practices. For automated image analysis, e-traps increasingly rely on software developments in artificial intelligence technologies. These technologies are also now freely available to users of online portals such as [www.inaturalist.org](http://www.inaturalist.org) and [observation.org](http://observation.org). These biodiversity observation platforms allow users to upload images of insects and use AI algorithms to identify the species with high accuracy.

In this context, the Field Automatic Insect Recognition-Device (FAIR-Device) was developed. Our goal was to develop an automatic, low-cost, generalist monitoring system capable of providing high-resolution data for measuring a wide range of insect taxa diversity. The overarching goal is to eventually enable data-based evaluation of measures to increase insect biodiversity in agriculture, as well as effective and efficient pest monitoring (dual use).

## **2 The FAIR-Device**

### **2.1 Device design, components, operation, and performance**

The FAIR-Device was designed to replace the collection bottle attached to the outlet of a Malaise trap, which in this case was a Bartak-type (Bioform, Nürnberg, Germany) (Fig. 1). Unlike the collection bottle, which lethally collects insects for study, the FAIR-Device only video records them before they freely exit the device through an exit opening at the top. After being intercepted and guided to the top of the Malaise trap, the insects enter the FAIR-Device through a 30 mm wide entrance tube at the bottom. Once inside, the insect finds itself in a tube with a larger diameter (50 mm) illuminated from above by four LEDs that provide light to allow image capture and at the same time attract insects and induce them to fly upwards, towards the device's exit hole. Once outside, sunlight reduces the attraction effect of the LEDs. The recording camera module, also on the top of the device, consists of a computer surveillance system (MotionEye Linux software package) that monitors changes in a standard 1.0-megapixel USB camera's field of view (45° FOV).

The camera lens focuses at 74 mm from the rim of the inlet tube, and movements inside activate MotionEye to record videos automatically. The single board computer (SBC) used was a BeagleBone Black (BeagleBoard.org Foundation, Michigan, USA). All housing components were designed to be fully 3D printed and to allow easy assembly. The electricity supply was delivered through the conventional electrical grid (230 V), with a low-voltage direct current converter (5 V) to power up the SBC and the other components. The connection of the SBC to the computer was via WLAN. The cost of the device, excluding the Malaise trap, is estimated at approximately 210 Euros.




Fig. 1: Design of the FAIR device. (a) Schematic view of the Malaise trap with FAIR device attached on top; (b) FAIR device in the field; (c) close-up of the FAIR device with camera module, exit hole, exit, and entrance tubes; (d) close-up of the device in the field

## 2.2 Data processing

The videos recorded by the FAIR-Device were analyzed manually. Up to five of the best frames were uploaded to the iNaturalist platform for subsequent taxonomic classification using its artificial intelligence identification system. The AI system identified individuals at different taxonomic levels displaying one main (most probable) taxonomic suggestion and eight alternative suggestions. We simulated a completely automatic identification system by taking the main suggestion marked by the AI, even if it did not coincide with our entomological assessment. Part of the classifications (39%) were then made available

to the iNaturalist community for ratification, rectification, and/or for being changed to a classification at a more precise or a less precise taxonomic level.

### 2.3 Device design performance

The test images were clear enough to distinguish the shape, texture, and color of the insects (Fig. 2). The MotionEye application successfully detected the entering insects and recorded the event. However, about 15% of the total recorded videos were false positives, that is, false motion detections. Since the test was carried out without constant supervision, we did not evaluate the incidence of false negatives, that is, the entry of an insect into the device without it being detected.



Fig. 2: Raw FAIR-Device images. (a) A scorpionfly (*Panorpa communis* L., Mecoptera: Panorpidae); (b) an unidentified parasitoid wasp (Hymenoptera: Ichneumonoidea)

Although the behavior of the insects varied, they all eventually left the device. 93.6% of the stays lasted 15 min or less, and 76.2% lasted one minute or less. When leaving the device, 82.8% of insects exited as intended, while 6.9% returned to the entrance, and in 10.3% of cases, the final actions were left unrecorded.

While the high percentage of individuals who left the device in a relatively short time and the acceptable quality of the resulting videos demonstrate that the design was adequate for our intended purposes, we believe that the aforementioned cases of false positives and negatives, returns to entry, and unregistered final actions should be evaluated in more detail in the future to better understand the global accuracy of the monitoring system. This will help us identify areas of improvement and optimize the system's performance.

### 2.4 Insect taxonomy

On the iNaturalist platform, 163 out of the total classifications were made public (observations), with the goal of representing all species at least once (Fig. 3). Only 89 observations (54.6%) were reviewed by the community. Of the reviewed observations, 42 reached research-grade observations, that is, almost 26% of the total published observations. The Diptera Order corresponded to 63.1% of the total observations, followed



by the Orders of Lepidoptera (13.6%) and Hymenoptera (10%) respectively (Tab. 1). Within the Diptera order, about 60% were fly species.

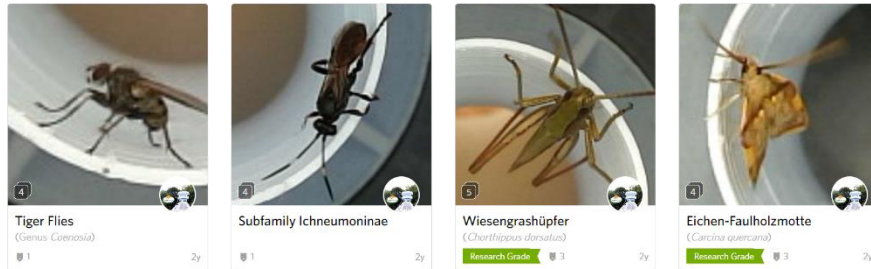


Fig. 3: iNaturalist image database. Video frames uploaded to inaturalist.org ([https://www.inaturalist.org/observations?place\\_id=any&user\\_id=jchiavassa&verifiable=any](https://www.inaturalist.org/observations?place_id=any&user_id=jchiavassa&verifiable=any)). Note the “research grade” badges, indicating high certainty in taxonomic identifications

| Order          | Sub-order    | Super-family | Family       | Sub-family   | Genus        | Species      |
|----------------|--------------|--------------|--------------|--------------|--------------|--------------|
| Diptera        | 98,9%        | 56,1%        | 53,1%        | 41,0%        | 28,4%        | 4,1%         |
| Hymenoptera    | 97,7%        | 95,3%        | 86,0%        | 62,8%        | 53,5%        | 14,0%        |
| Orthoptera     | 100,0%       | 100,0%       | 100,0%       | 96,7%        | 93,3%        | 26,7%        |
| Coleoptera     | 100,0%       | 100,0%       | 100,0%       | 100,0%       | 93,3%        | 73,3%        |
| Lepidoptera    | 89,7%        | 86,2%        | 55,2%        | 37,9%        | 34,5%        | 10,3%        |
| Mecoptera      | 100,0%       | 100,0%       | 100,0%       | 100,0%       | 100,0%       | 0,0%         |
| <b>Average</b> | <b>97,7%</b> | <b>69,3%</b> | <b>62,3%</b> | <b>49,8%</b> | <b>39,8%</b> | <b>10,5%</b> |

Tab. 1: Identification percentage according to the different taxonomic levels and for the different orders within the study period, determined by iNaturalist's AI identification system and subsequent community review. The higher the level of taxonomic precision, the percentage of identification tends to be lower (transition from green, higher, to red, lower)

## 2.5 Combining with other real-time data

Insect detection time series can be related to other time-dependent data, such as weather data. This way, we can study the influence of temperature, wind speed, and precipitation on the incidence of insects. For instance, Fig. 4 shows an insect detection time series whose pattern suggests a possible interrelation between wind speed and the number of insects detected. Given a certain wind intensity, the number of insects may decrease. However, this interrelation of factors is not yet fully understood, and it may be indirect (e.g., strong winds could affect the access of insects from the malaise trap to the interior of the device

regardless of the number of insects present in the ambient). Therefore, further research is necessary to clarify the nature of this relationship.

Studying real-time data correlations can help us understand insect population dynamics more accurately, leading to new and original insights. By analyzing the correlation between insect populations and climatic variables, we can identify the factors that contribute to pest outbreaks and develop targeted strategies to control them. This approach could help farmers reduce their reliance on chemical pesticides and adopt more sustainable agricultural practices.




Fig. 4: Complex dynamics of insect abundance (yellow), temperature ( $^{\circ}\text{C}$ , red), wind speed (m/s, blue-green), and precipitation (mm, blue), including non-operational periods of the trap (grey). Note the relative scale to express all values on a common scale. Relative values are scaled to the maximum of each period, as indicated by the exact values given in the upper and lower panels

### 3 Conclusions

Our proposed device enables the acquisition of quality time-stamped videos from various insect species without causing their death. The combination with the iNaturalist platform allows for the conversion of this data into detailed information about the insect biodiversity of a given site, showing promising results for low-cost, non-lethal, and high temporal and spatial resolution insect biodiversity monitoring. Future plans include incorporating an autonomous electrical power system through solar panels and developing an AI insect-tracking system for counting individuals within the device, to make the system completely automatic. Such fully automated e-traps, arranged as individual nodes to form networks of devices, would open new doors for the accurate long- and short-term study of insect population dynamics in ecological research and agricultural production.

#### Bibliography

- [PVA21] Preti, M.; Verheggen, F.; Angeli, S.: Insect pest monitoring with camera-equipped traps: strengths and limitations. *J Pest Sci*, 94, 203–17, 2021.

## Digitale Experimentierfelder zur Vernetzung in Technik und Wissen für eine digitale Landwirtschaft auf Zukunftsbetrieben in Baden-Württemberg

Hauke Delfs<sup>1</sup>, Annabell Cankaya<sup>2</sup>, Anne Feiler<sup>2</sup>, Markus Frank<sup>2</sup>, Verena Klinger<sup>3</sup>, Gabriel Baum<sup>3</sup> und Christian Bauer<sup>1</sup>

**Abstract:** Im Rahmen des Projektes TechKnowNet soll die Etablierung digitaler Systeme auf landwirtschaftlichen Betrieben vorangebracht und entsprechende Lehrformate für den Unterricht an den Fachschulen für Landwirtschaft erstellt werden. Auf zehn landwirtschaftlichen Betrieben in Baden-Württemberg wird der Status quo der aktuell eingesetzten digitalen Technologien erhoben sowie deren zukünftiger Einsatz praxisnah begleitet. Die daraus hervorgehenden Erkenntnisse werden in Empfehlungen für die landwirtschaftliche Praxis sowie in Lehrformate an Fachschulen und in die Beratung übertragen. Digitale Technologien sind in einigen Bereichen bereits gut etabliert, jedoch ist der Bedarf an Unterstützung in Beschaffung und Beratung hoch.

**Keywords:** Knowhow, Digitalisierung, Bildung und Beratung, landwirtschaftliche Praxis, Wissenstransfer, Baden-Württemberg

### 1 Einleitung

Die Landwirtschaft in Baden-Württemberg zeichnet sich historisch bedingt durch eine kleinteilige Struktur aus. Die durchschnittliche Betriebsgröße lag im Jahr 2020 bei 36,0 ha und auf 54,2 % der knapp 39.000 landwirtschaftlichen Betriebe wurden weniger als 20 ha bewirtschaftet. 35,6 % der Betriebe der Rechtsform Einzelunternehmen wurden im Haupterwerb und 64,6 % im Nebenerwerb geführt [St23] Diese betrieblichen Strukturen stellen einen wichtigen Faktor bei der Entscheidung für oder gegen die Etablierung von digitalen Strukturen in Baden-Württemberg dar. So ist die Adaption von digitalen Technologien wie z. B. Lenksystemen oder die teilflächenspezifische Bewirtschaftung in Regionen mit großstrukturierter Landwirtschaft deutlich weiterverbreitet [PGG21].

---

<sup>1</sup> Landwirtschaftliches Technologiezentrum Augustenberg (LTZ), Referat 11 – Pflanzenbau, Neßlerstraße 23, 76227 Karlsruhe, hauke.delfs@ltz.bwl.de, christian.bauer@ltz.bwl.de

<sup>2</sup> Hochschule für Wirtschaft und Umwelt Nürtingen-Geislingen (HfWU), Institut für Agrarforschung (IAAF), Neckarsteige 6-10, 72622 Nürtingen, annabell.cankaya@hfwu.de, anne.feiler@hfwu.de, Markus.Frank@hfwu.de

<sup>3</sup> Landesanstalt für Landwirtschaft, Ernährung und Ländlichen Raum Schwäbisch Gmünd (LEL), Oberbettringer Str. 162, 73525 Schwäbisch Gmünd, Verena.Klinger@lel.bwl.de, Gabriel.Baum@lel.bwl.de

Um dieser Herausforderung nachzukommen, werden im Rahmen des BMEL-geförderten Projektes „TechKnowNet“ der Status quo der Digitalisierung erhoben und Umsetzungshemmnisse der digitalen Transformation auf landwirtschaftlichen Betrieben in Baden-Württemberg identifiziert. Darüber hinaus werden mögliche Handlungs- sowie Unterstützungshilfen in der praktischen Anwendung auf den Betrieben durchgeführt und Lehrformate zum Thema Digitalisierung für landwirtschaftliche Fachschulen entwickelt. Diese Umsetzung wird im Folgenden auf Grundlage erster Ergebnisse näher erläutert.

## 2 Stand des Wissens

Die digitale Transformation der Landwirtschaft in Baden-Württemberg steht noch am Anfang, wobei zu beobachten ist, dass beispielsweise in Bayern automatische Lenksysteme oder FMIS (Farmmanagement-Informationssysteme) auf ca. einem Fünftel der Betriebe zunehmend eingesetzt werden [Lf20]. Darüber hinaus besteht eine Diskrepanz in der Nutzung von Precision Farming im Ackerbau zwischen kleinen Betrieben (< 100 ha), von denen zurzeit lediglich 10 % Techniken der Präzisionslandwirtschaft anwenden, und großen Betrieben (> 500 ha), von denen 70 % derartige Technologien anwenden. [PT16]

Außerdem ist evident, dass den Landwirten ohne ausreichende Informationen Entscheidungsgrundlagen zu digitalen Technologien fehlen, welche notwendig sind, um Alternativen, Konsequenzen und Risiken einschätzen zu können [PTK22].

Zwar sind an den Fachschulen für Landwirtschaft in Baden-Württemberg 69 % der Lehrkräfte und 62 % der Studierenden der Meinung, der Einsatz digitaler Technologien werde an der Schule unterrichtet. Dennoch stimmten 28 % der Lehrkräfte und 40 % der Studierenden nicht oder eher nicht zu, dass der Unterricht an der Fachschule auf die Führung eines digitalen landwirtschaftlichen Betriebes vorbereitet. So geben über die Hälfte der Studierenden an, im Fachschulunterricht keine Kenntnisse z. B. zur Unkrautbestimmung über Apps oder zur Erstellung von Applikationskarten erlernt zu haben. Als Hindernisse des Unterrichts der Digitalisierung werden von den Lehrkräften u. a. fehlende Thematisierung im Lehrplan, Mangel an Unterrichtsmaterial, kaum Weiterbildungen und die hohe Frequenz an Neuerungen genannt. [Pa23]

## 3 Material und Methoden

Für die Erhebung des Status quo der Digitalisierung im Ackerbau auf den landwirtschaftlichen Betrieben in Baden-Württemberg sowie der Evaluierung von verschiedenen digitalen Technologien wurden zehn Projektbetriebe ausgewählt. Diese unterscheiden sich in Bewirtschaftungsform, Größe, technischer Ausstattung, Fortschritt in der Digitalisierung und räumlicher Verteilung innerhalb Baden-Württembergs, um die aktuellen Gegebenheiten der landwirtschaftlichen Praxis optimal abbilden zu können. Zwei der zehn Projektbetriebe werden ökologisch bewirtschaftet.

Als Grundlage für die Evaluierung des gegenwärtigen Standes der Digitalisierung wurde ein Fragenkatalog mit 92 Fragen entwickelt. Diese deckten u. a. die Themenbereiche der allgemeinen Betriebsabläufe, des Betriebsmanagements, der Nutzung digitaler Tools/Technologien, die Motivation zur Nutzung der digitalen Tools/Technologien, die Einschätzungen/Wahrnehmungen zu Datensicherheit und Datenschutz sowie der Informationsbeschaffung ab. Ergänzend zu dem Fragenkatalog wurden Gesprächsprotokolle der Befragungen angefertigt. Somit konnten angesprochene Themen der Landwirte über den Fragenkatalog hinaus aufgenommen werden und in die spätere Auswertung mit einfließen.

Basierend auf den Erkenntnissen der Interviews, der Hinzunahme aktueller wissenschaftlicher Literatur sowie unter Berücksichtigung der guten landwirtschaftlichen Praxis wurde ein allgemein anwendbarer Leitfaden zur Digitalisierung entwickelt. Dieser durchläuft aktuell ein Review-Verfahren auf den Projektbetrieben, in welchem die Betriebsleitung entsprechende Differenzen zu dem eigenen Digitalisierungsprozess anmerken kann. Dies soll die Praxistauglichkeit der Empfehlungen und der darauf aufbauenden Lehrinhalte für die Fachschulen sicherstellen.

Kleine Lerneinheiten, welche modular zusammensetzbar sind, sogenannte „Learning Nuggets“ werden auf Grundlage dieser Erkenntnisse entwickelt und in Form eines Curriculums bereitgestellt. Neben der Nutzung der Lernplattform kommen dabei mediendidaktische Tools zum Einsatz, welche im Vorfeld auf Messebesuchen und Vorortterminen auf die Anwendbarkeit für die Vermittlung der Lehrinhalte erprobt wurden.

## 4 Ergebnisse

### 4.1 Stand der Digitalisierung der Projektbetriebe




Abb. 1: Übersicht der Antworten zur Anwendung gängiger digitaler Tools auf den Praxisbetrieben in TechKnowNet (n = 10)

Aus den Befragungen der Projektbetriebe geht hervor, dass auf vielen Betrieben bereits digitale Tools genutzt werden oder die Beschaffung in absehbarer Zukunft geplant ist.

Aktuell wird bereits auf allen Projektbetrieben eine digitale Ackerschlagkartei (ASK) angewendet. Ein FMIS ist auf fünf Betrieben in der Anwendung und soll auf zwei Betrieben im kommenden Jahr und auf einem Betrieb in den kommenden fünf Jahren beschafft werden. Neun von zehn Betrieben nutzen eine Maschinenkommunikation über ISOBUS oder automatische Lenksysteme und bei einem Betrieb ist die Beschaffung bereits in Planung. Die Nutzung von teilflächenspezifischem Pflanzenschutz oder der Ertragskartierung ist hingegen nur marginal etabliert. Jedoch ist auf einigen Betrieben eine Beschaffung in den nächsten Jahren angedacht oder wird von den Betriebsleitern als nicht notwendig erachtet.

## 4.2 Digitalisierungsplan

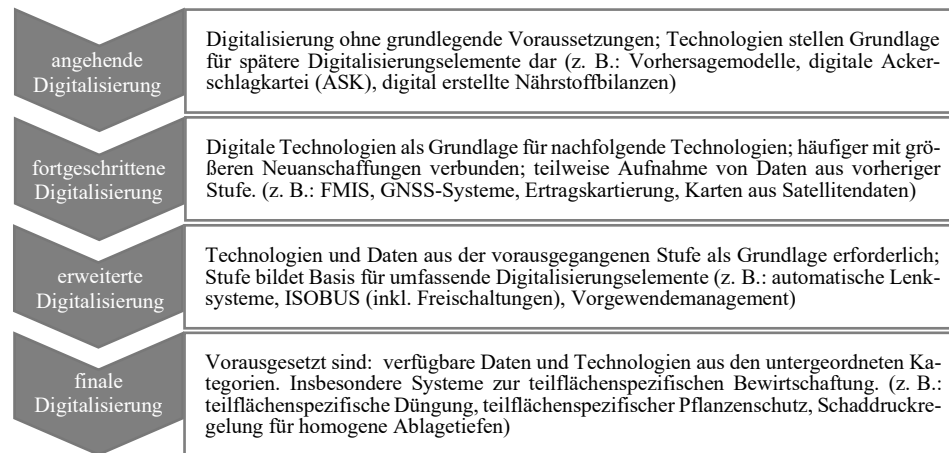


Abb. 2: Vier Schritte der landwirtschaftlichen Digitalisierung

Aus den gewonnenen Erkenntnissen der Betriebsbefragungen werden die in Abbildung 2 dargestellten vier Schritte der landwirtschaftlichen Digitalisierung abgeleitet. Innerhalb dieser Schritte können digitale Elemente zugeordnet werden, welche auf landwirtschaftlichen Betrieben Anwendung finden. Aus den jeweiligen Schritten kann dementsprechend das Stadium der digitalen Transformation des vorliegenden Betriebes abgeleitet werden. Ebenso kann darauf basierend von den Landwirten erkannt werden, welche Schritte als nächstes für einen erfolgreichen Transformationsprozess notwendig sind und welche Technologien aufeinander aufbauen.

## 4.3 Lehre

Aufbauend auf einem Workshop mit Lehrkräften der Fachschulen für Landwirtschaft in Baden-Württemberg und anschließenden Vorortterminen wurde die Notwendigkeit der mediendidaktischen Gestaltung niederschwelliger Angebote („Learning Nuggets“) im Bereich der digitalen Landwirtschaft identifiziert. Diese können mittels der Lernplattform

Moodle flexibel in den Unterricht implementiert werden. Da aktuell noch kein themenspezifisches Curriculum an den Fachschulen besteht, befindet sich dieses unter Einbezug der Inhalte des Digitalisierungsplans in Erarbeitung, mit dem Ziel der Erprobung an der Akademie für Landbau in Nürtingen. Eine Zusammenarbeit mit den zuständigen Stellen in Rheinland-Pfalz (Dienstleistungszentrum Ländlicher Raum Rheinhessen-Nahe-Hunsrück) soll Synergien gewinnbringend nutzen und das Ergebnis komplementieren.

## 5 Diskussion

Wie aus den Befragungen und Gesprächen mit den Projektlandwirten hervorgeht, besteht eine Nutzung der digitalen ASK und FMIS auf allen Betrieben, wodurch sich ein deutlich fortschrittlicheres Bild als bei vorangegangenen Evaluationen/Erhebungen abzeichnet [Lf20]. Darüber hinaus wurden in den Befragungen zentrale Strukturen identifiziert, worauf aufbauend nun detailliertere Daten zum Thema ASK und FMIS in weiteren Befragungen erhoben werden. Den Erhebungen ist ebenfalls zu entnehmen, dass grundständige digitale Elemente wie automatische Lenksysteme oder die Maschinenkommunikation über ISOBUS bereits in der Praxis etabliert sind. Darüber hinaus besteht eine teilweise Anwendung GPS-gesteuerter Teilbreitenschaltungen sowie teilflächenspezifischer Maßnahmen in Düngung und Pflanzenschutz. Dies zeigt, dass sich bereits viele Betriebe mit der Thematik „Precision Farming“ und Digitalisierung auseinandersetzen. Die weitere Etablierung muss in der kleinstrukturierten Landwirtschaft durch Beratung und Unterstützung der Beschaffung gefördert werden, um den Anschluss beim technischen Fortschritt zu halten.

Es ist bei den Erhebungen dieses Projektes jedoch anzumerken, dass weitere Datenerhebungen über die Projektbetriebe hinaus notwendig sind, um ein klares Bild des Status quo der Digitalisierung auf den landwirtschaftlichen Betrieben in Baden-Württemberg zu erhalten.

Eine weitere Erkenntnis aus den Gesprächen mit den Projektlandwirten besteht hinsichtlich der schwer zu erfassenden Übersicht über die verfügbaren Systeme und deren Zusammenspiel bzw. Konnektivität zueinander. Daher soll die Erstellung eines Digitalisierungsplans diese Lücke füllen und eine grundlegende Umsetzungsempfehlung bilden. Denn um die Möglichkeiten und Folgen weiterer Digitalisierungsschritte einschätzen zu können, ist eine ausreichende Entscheidungsgrundlage notwendig [PGG21]. Was jedoch ebenfalls aus den Erhebungen hervor geht, ist die betriebsindividuelle Gestaltung der Digitalisierungsschritte. Diese ist u. a. abhängig von der Betriebsgröße, dem Know-how im Bereich Digitalisierung, der Bewirtschaftungsart, den Flächenstrukturen und der Betriebsausrichtung sowie den ökonomischen Gegebenheiten.

In der Lehre zeigt sich die Notwendigkeit der Zusammenarbeit mit anderen Bundesländern, da aus den Gesprächen hervorgeht, dass hier ebenfalls ähnliche Lücken im Lehrplan der Fachschulen bestehen und ein Austausch über die Erstellung von Lehrformaten als

sehr sinnvoll angesehen wird. Die Anpassung der Lehrpläne und die Erstellung von Lehrformaten werden ebenfalls durch die Lehrkräfte der Fachschulen hervorgehoben [Pa23]. Darüber hinaus wird von den Fachschullehrkräften angemerkt, dass die eigenständige Erstellung von zusätzlichem Lehrmaterial bezüglich Lehrformaten zur digitalen Landwirtschaft über das eigentliche Lehrdeputat hinausgeht und somit nicht umsetzbar wäre. Dies unterstützt die Annahme des Projekts „TechKnowNet“, dass die Erstellung von Lehrmaterial für den Fachunterricht eine hohe Bedeutung hat und dass die Lehrkräfte dabei mehr unterstützt werden müssen. Ebenfalls lässt sich über die Ergebnisse aus den Befragungen und Beratungen der Projektlandwirte eine Brücke zwischen praktisch relevanter Anwendung und Fachschulcurriculum schlagen. Ziel ist es weiterhin, die Projektbetriebe als zukünftige Arbeitsorte der Studierenden oder deren Eigenschaft in der Betriebsnachfolge weiter in die Anforderungen an entsprechende Lehrformate mit einzubinden.

**Förderhinweis:** Die Förderung des Vorhabens erfolgt aus Mitteln des Bundesministeriums für Ernährung und Landwirtschaft (BMEL) aufgrund eines Beschlusses des deutschen Bundestages. Die Projektträgerschaft erfolgt über die Bundesanstalt für Landwirtschaft und Ernährung (BLE) im Rahmen der Bekanntmachung über die Förderung der Einrichtung von Experimentierfeldern als Zukunftsbetriebe und Zukunftsregionen der Digitalisierung in der Landwirtschaft sowie in vor- und nachgelagerten Wertschöpfungsketten mit dem Förderkennzeichen 28DE206A21.

#### Literaturverzeichnis

- [Lf20] LfL Bayern, [https://www.lfl.bayern.de/mam/cms07/ilt/dateien/ilt6\\_presentation\\_by\\_2390\\_27082020.pdf](https://www.lfl.bayern.de/mam/cms07/ilt/dateien/ilt6_presentation_by_2390_27082020.pdf), Stand: 25.10.2023.
- [Pa23] Paulus, M.: Digitalisierung in der landwirtschaftlichen Berufsbildung: Untersuchung zur Wissensvermittlung an landwirtschaftlichen Schulen in der Aus- und Weiterbildung; Stand: 01/2023 (unveröffentlicht).
- [PT16] Paustian, M; Theuvsen, L.: Adoption of precision agriculture technologies by German crop farmers. *Precision Agric* 18/2017, 701–716, 2016.
- [PTK22] Pfaff, S.A.; Thomas A.; Knierim A.: Analyse der sozialen Folgen von digitalen Technologien für Betriebe in der kleinstrukturierten Landwirtschaft. *Zeitschrift für Technikfolgenabschätzung in Theorie und Praxis* 31/3/2022: 65–71, 2022.
- [PGG21] Pfeiffer, J.; Gabriel, A.; Gandorfer, M.: Klein gegen Groß - Vergleich von klein- und großstrukturierten Agrarregionen beim Einsatz digitaler Technologien. In: Referate der 41. GIL-Jahrestagung, S. 247–252., (2021) Online verfügbar unter [https://gil-net.de/Publikationen/GIL2021\\_Gesamt\\_finalb.pdf](https://gil-net.de/Publikationen/GIL2021_Gesamt_finalb.pdf), zuletzt geprüft am 18.10.2023.
- [St23] Statistisches Landesamt Baden-Württemberg, <https://www.statistik-bw.de/Landwirtschaft/Agrarstruktur/>, Stand: 16.10.2023.



## Hybrid-Cloud-Infrastrukturen – Edge Computing und KI-basierte Anwendungen in der Landwirtschaft für resiliente und effektive Produktions- und Biodiversitätsmaßnahmen

Daniel Eberz-Eder <sup>1</sup>, Franz Kuntke <sup>2</sup>, Christian Reuter <sup>2</sup>, Ansgar Bernardi<sup>3</sup>, Ahmad Kadi<sup>3</sup>, Gerwin Brill<sup>4</sup>, Daniel Martini<sup>5</sup> und Benno Kleinhenz<sup>6</sup>


**Abstract:** Mobile Erhebung semantisch modellierter Daten und deren Auswertung im Feld durch Hybrid Cloud Computing sind Grundlage des Resilienten Smart Farmings im Projekt GeoBox. Eine skalierbare Architektur und semantische Datenmodellierung ermöglichen das Management betrieblicher Software-Container, die flexible Anpassung an neue Aufgaben und die Realisierung einfach nutzbarer externer Services, vorgestellt am Beispiel eines Resistenz-Beratungs-Chatbots und von Blühstreifen als Biodiversitätsmaßnahme.



**Keywords:** Resilienz, Edge Computing, Künstliche Intelligenz, Semantik, HofBox

### 1 Einleitung

Die fortschreitende Digitalisierung der Landwirtschaft eröffnet neue Möglichkeiten der Unterstützung effizienter und ressourcenschonender Produktion, stellt aber gleichzeitig hohe Anforderungen an Datenerhebung, Dokumentation, Datenschutz, Datensicherheit, Schnittstellen und Vernetzung [DN22; Bi22]. Zudem geraten alle Arbeitsschritte in immer stärkere Abhängigkeit von der Verfügbarkeit aktueller Daten und Web-Dienste, so dass die datentechnische Infrastruktur zunehmend zu einem kritischen Single Point of Failure zu werden droht. Im Innovationsprojekt GeoBox wurde ein System realisiert, das diese Schwierigkeiten durch einen Hybrid-Cloud-Ansatz entschärft: Mobile Datenverarbeitung

---

<sup>1</sup> Dienstleistungszentrum Ländlicher Raum (DLR) Rheinessen-Nahe-Hunsrück, Rüdeshheimer Str. 60-68, 55545 Bad Kreuznach, daniel.eberz@dlr.rlp.de,  <https://orcid.org/0000-0002-6539-5221>

<sup>2</sup> Technische Universität Darmstadt, PEASEC, Pankratiusstraße 2, 64298 Darmstadt, kuntke@peasec.tu-darmstadt.de  <https://orcid.org/0000-0002-7656-5919> und reuter@peasec.tu-darmstadt.de,  <https://orcid.org/0000-0003-1920-038X>

<sup>3</sup> Deutsches Forschungszentrum für Künstliche Intelligenz GmbH (DFKI), Trippstadter Str. 122, 67663 Kaiserslautern, ansgar.bernardi@dfki.de, ahmad.kadi@dfki.de

<sup>4</sup> expeer GmbH, Wachsbleiche 10-12, 53111 Bonn, brill@expeer.de und nuderscher@expeer.de

<sup>5</sup> Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (KTBL), Bartningstraße 49, 64289 Darmstadt, d.martini@ktbl.de

<sup>6</sup> Zentralstelle der Länder für EDV-gestützte Entscheidungshilfen und Programme im Pflanzenschutz (ZEPP), Rüdeshheimer Str. 60-68, 55545 Bad Kreuznach, kleinhenz@zepp.info

im Feld ermöglicht unmittelbare Datenerhebung vor Ort; die Replikation benötigter Basisdaten im betrieblichen Hof-Server (HofBox) und die lokale Auswertung durch Resilient Edge Computing (REC) sichern die betriebliche Datenhoheit und Resilienz gegen Störungen [EKB23; EKR22]. Die Datenmodellierung stützt sich auf etablierte Ontologien (z. B. AGROVOC [AG23]), diese explizite Semantik ermöglicht höchste Flexibilität bei Änderungen sowie Übertragbarkeit und Verarbeitung durch externe Dienste.

Wir präsentieren im Folgenden die Prinzipien der Resilient Edge Computing Architektur und der semantischen Datenmodellierung und die Evaluierung durch zwei Beispiele: Ein Beratungsassistent zum Pflanzenschutz unter Berücksichtigung von Resistenzfragen illustriert, wie auf dieser Basis moderne, dialogfähige KI-Systeme unmittelbaren Einsatz in der betrieblichen Praxis finden können; die im Experiment mit minimalem Aufwand realisierte Systemerweiterung zur Erfassung und Bewertung der Biodiversitätsmaßnahme „Blühstreifen“ zeigt die außerordentliche Adaptierbarkeit an neue Herausforderungen.

## 2 Ergebnisse

### 2.1 Hybrid-Cloud-Infrastruktur – Resilient Edge Computing als Möglichkeit zur Steigerung der Resilienz

Als skalierbare Architektur (Abb. 1) für ein Resilient Edge Computing [EKB23] verwenden wir das open source Framework Open Horizon<sup>7</sup>. Dies erlaubt, tausende HofBoxen mit containerisierter Software zu administrieren. Die aktuelle Entwicklung der HofBox zeichnet sich durch eine weitgehende Vorkonfiguration aus, sodass eine Inbetriebnahme ohne weitere Konfiguration möglich ist. Anwendungen können mittels eines Internetbrowsers, d.h. ohne zusätzliche Software, genutzt werden. Zur Unterstützung der täglichen Arbeit wird standardmäßig eine erweiterbare Basissoftware (GeoBox-App) mitgeliefert. Zusätzliche Anwendungen können über die Integration eines App-Stores installiert werden, wenn dies vom Nutzer gewünscht wird. Das HofBox-Grundsystem basiert auf einer Linuxdistribution (Ubuntu) in Kombination mit einem vorkonfigurierten Open-Horizon-Client. Diese Kombination ist auf einer Vielzahl von Computerhardware lauffähig, wodurch sich auch später unterschiedliche Anforderungen durch potentere oder sparsame Hardware abbilden lassen. Im Kern ist die Idee, dass ein dedizierter Compute-Server, der an den Betrieb geliefert und aus der Ferne verwaltet wird, dem Landwirt lokal Datenverarbeitungsdienste zur Verfügung stellt. Um robustes Smart Farming in die Praxis umzusetzen, werden die Daten der Landwirte primär auf der HofBox gespeichert. Nur mit Zustimmung werden Daten an andere Orte gesendet und gespeichert.

---

<sup>7</sup> Linux Foundation Projekt unter LF Edge Open Horizon

Die entwickelte Architektur der GeoBox-App als containerisierte Software hält die notwendigen Daten zunächst lokal auf dem jeweiligen Endgerät (z. B. Smartphone) und synchronisiert diese dann mit der HofBox. Durch das Betreiben eines eigenen open-source-basierenden LoRaWAN-Server (Chirpstack) können autarke und internetunabhängige regionale LoRaWAN-Sensornetzwerke aufgebaut werden. Diese können u.a. zur Notkommunikation genutzt werden [Ku23b].

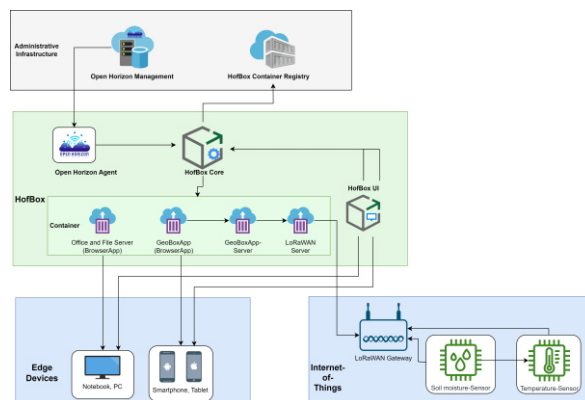


Abb. 1: Systemarchitektur des Resilient Edge Computing (EKB 23)

## 2.2 Semantische Datenmodellierung im GeoBox-Buchungsjournal

Die Dokumentation landwirtschaftlicher Maßnahmen und Beobachtungen auf einem Feld erfolgt fortlaufend über die Vegetationsperiode. Traditionelle Karteikarten, aber auch digitale Schlagkarteien mit proprietären geschlossenen Datenmodellierungen bieten aber nicht die notwendige Flexibilität, Offenheit und Interoperabilität. GeoBox erreicht dies durch Datenmodellierung mit semantischen Technologien. Jede Beobachtung oder Maßnahme wird als Instanz einer (allgemeinen oder spezifischen) „Aktivität“ dargestellt. Die konkreten Attribute und Werte dieser Instanz nutzen eindeutige Vokabulare. Hierzu wurde eine Ontologie entwickelt, die mögliche Feldmaßnahmen und Beobachtungen in eine Klassenhierarchie einordnet und dadurch bestimmt, welche Attribute, Wertebereiche und Datentypen die landwirtschaftlichen Maßnahmen beschreiben [Ka23]. Ein wichtiges Vokabular zur Beschreibung landwirtschaftlicher Objekte und Vorgänge ist der Thesaurus AGROVOC. Klassen und Prädikate der GeoBox-Ontologie sind mit den entsprechenden Konzepten aus AGROVOC über Mapping-Relationen verbunden. Das kontinuierliche Hinzufügen von Einträgen (Instanzen) lässt das GeoBox-Buchungsjournal entstehen, das die Arbeit im Betrieb oder auf dem Feld dokumentiert. Das Buchungsjournal ist ein betrieblicher Wissensgraph und kann durch beliebige SPARQL-Anfragen [SP23] ausgewertet werden. Informationsbedürfnisse externer Systeme werden so nach Inhalt und Form befriedigt. Soweit Fremdsysteme solche Anfragen stellen, wird die Ausgabe durch Menschen geprüft und freigegeben und so die Datenhoheit gewahrt.

### 2.3 Experiment: Erfassung und Bewertung von Biodiversitätsmaßnahmen

GeoBox-Architektur und -Datenmodellierung bieten außerordentliche Flexibilität, um das System an neue Aufgaben anzupassen. Im Experiment betrachten wir das Beispiel eines landwirtschaftlichen Betriebs, der Teile seiner Felder als Blühstreifen ausweisen möchte, um die Biodiversität zu erhöhen. Um diese Maßnahme neu zu dokumentieren, zu bewerten und darüber zu berichten, genügen wenige Eingriffe: Zur Ontologie wird eine passende Klassendefinition hinzugefügt. Die nötigen Bildschirm-Eingabemasken entstehen daraus automatisch. Zur Auswertung der neu erfassten Daten wird eine SPARQL-Query neu formuliert, die den gewünschten Bericht erzeugt. Abbildung 2 zeigt die wesentlichen Elemente: das neue Konzept „Blühstreifen“, die daraus generierte Eingabemaske, die SPARQL-Abfrage für Abfrage und Berechnung des Anteils der ökologischen Maßnahme sowie den erzeugten Bericht. Die Definition dieser Elemente und der Import in das System sind eine Sache weniger Minuten!

```
fsg:WildFlowerStripProvisioningShape
a          sh:NodeShape ;
rdfs:label "Blühstreifen"@de;
sh:targetClass fsg:WildFlowerStripProvisioning;
sh:property fsg:generatedAtTimeShape;
sh:property fsg:timeZoneForResourceShape;
sh:property [sh:path rdfs:label;
             sh:datatype xsd:string;
             sh:property [sh:path fr:numberOfField;sh:
             datatype xsd:integer];
sh:property
[ sh:path geo:hasGeometry;
  sh:class sf:Polygon;
  dash:editor dash:DetailsEditor;
  sh:node     fsg:PolygonCoordinatesShape;
  sh:maxCount 1;
  sh:name     "Koordinaten"@de;
  sh:order   4 ; ];
sh:property [sh:path fr:isPermanentField;
             sh:datatype xsd:boolean];
sh:property [sh:path fr:area;
             sh:class qudt:Quantity];
sh:property [sh:path fr:soilTexture;
             dash:rootClass soil:SoilTexture];
sh:property [sh:path fr:fieldGradient;
             sh:class qudt:Quantity];
sh:closed true;
sh:ignoredProperties (rdf:type);
```

Daten zu Blühstreifen bereitstellen

**Datum**  
2023-08-14 15:52

**Zeitzone**  
Europa/Berlin

**Name der Blühstreifen**

**Blühstreifennummer**

**Koordinaten**  
Polygon

Zurückrechnen

**Dauerhaft**

**Fläche**  
Wert  Einheit

**Bodenart**

**Hangneigung**  
Wert  Einheit

Speichern

```
PREFIX
fr: <https://srv.ktbl.de/ontologies/
FarmResource#>
PREFIX
qudt: <http://qudt.org/schema/qudt/>
PREFIX
geo: <http://www.opengis.net/ont/geo-
sparql#>
PREFIX
geoext: <http://rdf.useekm.com/ext#>
select (sum(?areal) /
(sum(?areal) + sum(?area2)) AS ?total)
where {
  {?s a fr:WildFlowerStrip ;
   fr:area/qudt:value ?areal.}
 UNION {
  ?p a fr:Field ;
   fr:area/qudt:value ?area2 .}}
```

**Ökologische Feldmaßnahmen**

**Blühstreifenanteil: 7.17 %**

**Blühstreifenfläche: 1.03 HA**

**Gesamtfläche: 14.36 HA**

Abb. 2: Shape-Definition, Eingabemaske, SPARQL-Query, Bericht

### 2.4 Chatbot zum Resistenzmanagement mittels semantischer Technologien

Neben betrieblichen Datenbeständen benötigen Entscheidungsunterstützungssysteme weitere relevante Datenquellen; z. B. spielen Eigenschaften von Kulturpflanzen, Schaderregern und Pflanzenschutzmitteln oder die Wetterlage eine Rolle bei der Planung von Pflanzenschutzmaßnahmen. Außerdem enthalten Entscheidungsunterstützungssysteme in Form von Modellen oder Entscheidungsbäumen kodifiziertes Expertenwissen. Für betriebsspezifische Empfehlungen müssen diese Elemente zusammengeführt werden. Im Projekt wurde ein Chatbot für interaktive Beratungsdialoge entwickelt, der Empfehlungen für die Anwendung von Pflanzenschutzmitteln gibt und dabei Resistenzaspekte und die individuelle betriebliche Historie berücksichtigt [Ka23]. Per API werden Entscheidungsbäume des öffentlichen Experten-Beratungsdienstes (ISIP)

genutzt, die wirksame und Resistenzen vermeidende Pflanzenschutzempfehlungen ermitteln. Zusammen mit Wetter- und Lokationsinformationen fließen diese in das auf dem IBM Watson Assistant [WA23] aufbauende Chatbot-System. Die Interaktion mit den Nutzenden geschieht durch sicheren Austausch über die Kommunikations-App „Messenger“ der Geobox-Infrastruktur.

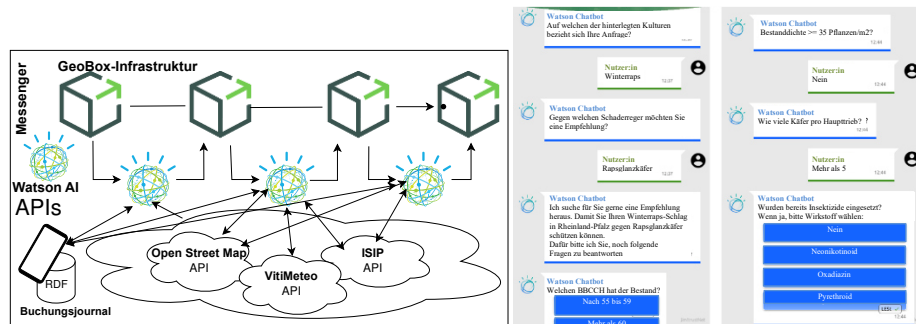


Abb. 3: Chatbot-Architektur: mit IBM Watson, daneben ein Chat-Beispiel im Messenger

Im Dialog müssen dann u. a. Fragen zur aktuellen Aussaat und den früher eingesetzten Pflanzenschutzmitteln beantwortet werden. Diese Arbeiten sind im Buchungsjournal unter Nutzung der Vokabulare dokumentiert, so dass der Chatbot unmittelbar SPARQL-Anfragen an das Buchungsjournal stellen kann. Die erhaltene Antwort wird im Chat hervorgehoben und manuell abgeschickt. Abbildung 3 zeigt die Architektur und den Chat-Verlauf einer Resistenzberatung bei der Schädlingsbekämpfung, wobei z. B. die Historie früherer Anwendungen direkt aus dem Buchungsjournal entnommen wird. Zu sehen sind die hervorgehobenen Antworten zwischen den möglichen Optionen.

### 3 Diskussion und Ausblick

Die von uns konzipierte und entwickelte Lösung zur Stärkung der digitalen Resilienz in der Landwirtschaft, Resilient Smart Farming, ist technologisch machbar. In zukünftigen Tests wird sich zeigen, ob die Lösung auch unter den Bedingungen der landwirtschaftlichen Praxis erfolgreich ist. Die technologische Machbarkeit konnten wir, wie oben beschrieben, mit Resilient Edge Computing praktisch demonstrieren. Wir erwarten, dass containerisierte Software in den nächsten Jahren verstärkt auch in der Landwirtschaft eingesetzt wird. Mit Einsatz von Open Horizon zeigen wir, wie diese auch auf Edge-Geräten verwaltet und administriert werden können. Der Einsatz von KI auf unterschiedlichen Edge Devices wird in naher Zukunft neue Möglichkeiten für Echtzeitanalyse und Entscheidungsfindung in einer Vielzahl von Branchen realisieren. Im Beispiel „Anpassung an Biodiversitätsfrage“ konnten wir zeigen, dass die Anpassung des Systems an neue Fragestellungen dank der semantischen Modellierung rasch und mit minimalen Eingriffen möglich ist. Die prototypische Entwicklung des Resilient Smart

Farming durch resilientes Edge Computing wird u. a. im Experimentierfeld Südwest erprobt und ist Vorbild für andere kritische Infrastrukturen. Hybrid-Cloud-Computing (Zusammenspiel von Cloud – und Edge-Computing) gewinnt mit landwirtschaftlicher IoT-Verbreitung in öffentlichen Institutionen und Privatwirtschaft an Bedeutung.

#### Literaturverzeichnis

- [AG23] AGROVOC multilingual thesaurus, [www.fao.org/agrovoc](http://www.fao.org/agrovoc), Stand: 24.04.2023.
- [Bi22] Bitkom-Research, Studie: Die Digitalisierung der Landwirtschaft, Bitkom e.V., Berlin, 12. Mai 2022.
- [DN22] Dörr, J.; Nachtmann, M.: Summary. In: Dörr, J., Nachtmann, M. (eds) Handbook Digital Farming. Springer, Berlin, Heidelberg, 2022.
- [EKB23] Eberz-Eder D.; Kuntke F.; Brill G.: Resilient Smart Farming a conceptual and technological opportunity to strengthen resilience, ECPA2023 – UNLEASHING THE POTENTIAL OF PRECISION AGRICULTURE - Book of Abstracts (Posters), Bologna.
- [Eb23] Eberz-Eder D. et al.: Prototypische Entwicklungen zur Umsetzung des Resilient Smart Farming (RSF) mittels Edge Computing. 43. GIL-Jahrestagung, Resiliente Agri-Food-Systeme. Bonn: Gesellschaft für Informatik e.V.. PISSN: 1617-5468. ISBN: 978-3-88579-724-1. pp. 309-314. Osnabrück. 13.-14. Februar 2023.
- [EKR22] Eberz-Eder D.; Kuntke F.; Reuter C.: Sensibilität für Resilient Smart Farming (RSF) und seine Bedeutung in Krisenzeiten, RSF für eine nachhaltige, umweltgerechte und resiliente digitale Landwirtschaft. 42. GIL-Jahrestagung: Informatik in der Land-, Forst- und Ernährungswirtschaft, 2022, ISBN: 978-3-88579-711-1, ISSN: 1617-5468.
- [Ka23] Kadi, A. et al.: Mobile semantische Dokumentation als Basis für KI-gestützte Beratungsdienste: Das GeoBox Buchungsjournal In (INFORMATIK 2023): Designing Futures: Zukünfte gestalten. Köllen, Berlin, S. 1639-1644, 2023.
- [Ku23a] Kuntke, F. et al: “GeoBox: design and evaluation of a tool for resilient and decentralised data management in agriculture.” Behaviour & Information Technology (2023).
- [Ku23b] Kuntke F. et al.: LoRaWAN security issues and mitigation options by the example of agricultural IoT scenarios. Trans Emerging Tel Tech. 2022;33(5):e4452.doi: 10.1002/ett.4452.
- [Ku20] Kuntke, F. et al.: Die GeoBox-Vision: Resiliente Interaktion und Kooperation in der Landwirtschaft durch dezentrale Systeme. In: *Mensch und Computer 2020 - Workshop-band*, S. 1-6, 2020.
- [SP23] SPARQL 1.1 Query Language, [www.w3.org/TR/2013/REC-sparql11-query-20130321/](http://www.w3.org/TR/2013/REC-sparql11-query-20130321/), Stand 24.04.2023.
- [WA23] IBM Watson Assistant: KI-Chatbot mit hohem Bedienungskomfort, [www.ibm.com/de-de/products/watson-assistant/artificial-intelligence](http://www.ibm.com/de-de/products/watson-assistant/artificial-intelligence), Stand 27.05.2023.

## A comparative study of RGB and multispectral imaging for weed detection in precision agriculture

Benedikt Fischer<sup>1</sup>, Pascal Gauweiler<sup>1</sup>, Benedikt Hofmann<sup>1</sup>, Robin Gruna<sup>1</sup>, Thomas Längle<sup>1</sup> and Jürgen Beyerer<sup>1,2</sup>

**Abstract:** Precision agriculture and specifically mechanical weed control systems have the potential to positively impact our environment by reducing the use of herbicides. In recent years, multispectral cameras have become more and more accessible, which raises the question whether the additional costs of such cameras are worth the potential benefits. In this study, we recorded and annotated a multispectral instance segmentation dataset for sugar beet crop and weed detection. We trained Mask-RCNN models on the RGB and multispectral data in a transfer learning approach and extensively evaluated and compared the results for different scenarios. We found that the multispectral data can improve the weed detection performance significantly in many cases.

**Keywords:** multispectral imaging, precision agriculture, machine learning, object detection

### 1 Introduction

Conventional agriculture relies heavily on herbicides for weed control. However, the widespread use of herbicides in agriculture has a negative impact on our ecosystems, they reduce biodiversity and compromise human health. Precision farming robots can reduce the need for herbicides by removing weeds mechanically. Such robots must be able to detect weeds in real time and need to be robust to changes in environmental conditions, which brings high demands on the used camera technology and algorithms. In recent years, many new multispectral cameras within the VIS-NIR wavelength range, targeted specifically for use in agriculture, have been brought to the market. This raises the question whether the possible benefits of multispectral cameras, in the context of weed detection, are worth the additional costs compared to standard RGB cameras.

There are several existing public datasets dedicated to weed control that used multispectral imaging [Ch17; Sa18]. But many datasets were annotated for Semantic Segmentation use cases and thus cannot be readily used with object detection models. There is no multispectral crop and weed instance segmentation dataset that was recorded from a

---

<sup>1</sup> Fraunhofer IOSB, Visual Inspection Systems (SPR), Fraunhoferstr. 1, 76131 Karlsruhe, Germany,

benedikt.fischer@iosb.fraunhofer.de,  <https://orcid.org/0009-0006-3334-5613>;

pascal.gauweiler@iosb.fraunhofer.de; benedikt.hofmann@iosb.fraunhofer.de;

robin.gruna@iosb.fraunhofer.de; thomas.laengle@iosb.fraunhofer.de; juergen.beyerer@iosb.fraunhofer.de

<sup>2</sup> Karlsruher Institut für Technologie (KIT), Lehrstuhl für Interaktive Echtzeitsysteme, Adenauerring 4, 76131 Karlsruhe, Germany

ground-based vehicle under real-world conditions and includes labels for different environmental conditions. In our work we aim to compare weed and crop detection performance between multispectral and RGB imaging data. Therefore, we recorded and annotated a new multispectral dataset of sugar beet crops and weeds with 508 annotated images, covering different relevant growth stages and weather conditions. We then trained Mask-RCNN models on the data and extensively evaluated the results for different scenarios. Thus, we hope to give some indication on when multispectral imaging could be worth to consider and when RGB imaging might be sufficient.

## 2 Dataset

### 2.1 Data acquisition

For the series of measurements, a 5-channel Multispectral prism camera was used (JAI FS-3200T-10GE-NNC). The camera covers the VIS-NIR wavelength range with 2 NIR channels in addition to the RGB channels. The camera was mounted on a tractor at a height of approx. 1.8m facing the ground. Two broadband LED lights (EFFI-Flex-HSI) were mounted next to it to improve the illumination of the scene. The camera recorded 5 frames per second while the tractor was driving at walking speed. The recordings were made on three days within a 3-week period in June and July 2022 in southern Germany. The sugar beet field was prepared in such a way that plants with different growth stages were present at the same time. Thus, a high variability could be achieved with the three measurement series. In detail, the crop growth stages BBCH 12 to 16 were covered during both sunny and cloudy weather conditions. Each measurement series differs in the degree of weed presence. In total, several thousand images were recorded and a subset of 508 non-overlapping images was selected to be annotated and used for the modelling.

### 2.2 Annotation

To reduce the labelling effort, a semi-automatic annotation approach was used. In the first step, a binary image was created by calculating the NDVI vegetation index, based on the first NIR channel and the red channel of the images, and using a threshold to separate the plants from the background. In the second step, a connected component analysis (CCA) was performed to obtain instance aware binary masks. Afterwards, these automatically created masks were reviewed and corrected manually. Overlapping objects had to be corrected manually as the CCA cannot separate them. The classes weed or crop were manually assigned to each mask instance. Each image was also assigned a label for the corresponding crop growth stage and environmental light condition. The bounding boxes were automatically created from the mask instance outline. The 508 annotated files contain a total of 3189 weed instances and 3199 crop instances. In Tab. 1, the number of images for the different environmental light and crop growth stage settings is shown. In Fig. 1,



two example images are shown with an overlay of the pixel masks and boxes. In the right image, a shadow can be seen that was cast by the tractor.

|        | BBCH 12 | BBCH 14 | BBCH 16 |
|--------|---------|---------|---------|
| Cloudy | 49      | 106     | 99      |
| Sunny  | 138     | 69      | 47      |

Tab. 1: Number of annotated images for each crop growth stage and environmental light condition




Fig. 1: Example images of the dataset. Annotated crop in green, weed in orange. Left: BBCH 12 stage and cloudy conditions. Right: BBCH 16 stage and sunny conditions

### 3 Experiment

For our experiment we trained three different models. One model was trained solely on the RGB channels. One model was trained on the RGB channels and one artificial NIR channel that was calculated from the mean of both NIR channels of the camera. This model is referred to as RGBN. One model was trained on all five channels and is referred to as RGBNN. The models were trained on the full train set. The evaluation of the models was done on the full test set and additionally on subsets that include only some growth stages or light conditions.

#### 3.1 Architecture

For all experiments, the Mask-RCNN architecture [He17] with a ResNet-50 backbone pretrained on the COCO dataset was utilized. The model implementation from torchvision was used and adapted to be suitable for the number of channels in the images and the number of classes in our dataset.

The ResNet-50 backbone was pretrained on an RGB dataset and has 3 input channels. In our experiments we have 3, 4 or 5 input channels. To adapt the architecture to different

input channels we added channel dimensions to the first convolutional layer. The weights of the added dimension have been copied over from the mean of the first 3 dimensions. The intention of this weight copying is to preserve the features the model learned to extract in its pretraining.

The head of the Mask-RCNN consists of a bounding box predictor and a mask predictor. The number of output features of these predictors depend on the number of classes in the dataset. The COCO dataset contains 91 classes while our dataset contains 2 classes. To adapt the model to our task we replaced the final predictor layers to match the number of classes in our dataset. The weights of the new layers have been copied over from the weights of the replaced layers that correspond to the first class.

### 3.2 Training

The models described before were trained on the full train dataset, including all growth stages and environmental light conditions. The dataset was split into 70% training, 15% validation and 15% test. The models were trained with stochastic gradient descent optimization until the validation loss did not improve for 20 epochs. Then the weights of the epoch with the minimal validation loss were used for the evaluation on the test dataset. In our experiments the optimum was reached between 28 and 50 epochs. During training time, the training images have been augmented by horizontal flipping and a random image rotation between  $-15^\circ$  and  $+15^\circ$ .

### 3.3 Evaluation

The trained models were evaluated on the hold-out test set. It was found that the model detections included very small plant leaves that were around the size of a crop at BBCH 10 to 11. That is the stage when the crop emerged from the ground and its first two leaves are not yet fully unfolded [Me18]. At this stage, the plants are pea-sized, and it is very difficult even for humans to distinguish crop from weed at that stage by looking only at the image. Therefore, a correct ground truth annotation for plants of that size could not be guaranteed in our dataset. To evaluate the models by fair means we filtered out the small objects that are pea-sized or smaller by applying a size filter with a minimum area of 0.1% of the full image area. The size filter was applied to both predictions and ground truth data prior to the evaluation. This reduced the number of ground truth crop instances in the test set from 472 to 439 and the number of weed instances from 444 to 252. Predictions were also filtered with a confidence score of 75% and a non-maximum suppression IoU of 0.5 for the evaluation. The training took around 5 to 7 hours on a NVIDIA RTX A6000 GPU in our case. This would make a cross validation time consuming. Therefore, we trained the model only once on the train set and used bootstrap resampling on the test set to get an estimate of the uncertainty in the model performance metrics. The bootstrap sample size was equal to the size of the test set and the resampling was repeated 20 times. We then calculated the mean and the 95% confidence interval for the metrics.

## 4 Results and Discussion

In Tab. 2, the performance metrics of the three models, evaluated on the full test set are shown. mAP describes the mean average precision over all classes. @50 stands for an IoU of 0.5 and means that predictions will be considered as true positives only if the bounding boxes have an IoU of at least 0.5 with an existing ground truth bounding box. The  $\pm$  range describes the 95% confidence interval from the bootstrap resampling. The best results are highlighted in bold if there is a clear best result, considering the confidence interval. The models trained with additional NIR channels are better than the RGB model in almost all metrics shown. The best performance was achieved by the model trained on 5 channels.

|            | RGB            | RGBN           | RGBNN                            |
|------------|----------------|----------------|----------------------------------|
| mAP@50-95  | 55.9 $\pm$ 0.6 | 60.0 $\pm$ 0.8 | <b>62.1 <math>\pm</math> 1.0</b> |
| mAP@50     | 76.8 $\pm$ 0.7 | 78.5 $\pm$ 0.9 | <b>81.3 <math>\pm</math> 1.1</b> |
| AP@50 crop | 95.5 $\pm$ 0.6 | 95.3 $\pm$ 0.5 | 94.1 $\pm$ 0.5                   |
| AP@50 weed | 58.2 $\pm$ 1.2 | 61.8 $\pm$ 1.8 | <b>68.5 <math>\pm</math> 1.9</b> |

Tab. 2: BBox AP metrics of the three models evaluated on the full test set

Fig. 2 depicts the AP@50 results of the models, evaluated on the different subsets of the test set. The metrics are given for the mean of both classes and for the individual classes. In the top of the diagram the results for different environmental light conditions are compared. In the bottom the different growth stages are shown. The addition of NIR channels led to a significant improvement of the weed detection performance in all cases. The changes in the crop detection performance are negligible in comparison, but they are quite high overall with AP values between 90% and 95%. The improvement is most evident in the case of weed detection in scenes with small crop growth stages (BBCH 12) and in scenes with sunny conditions. Both scenarios make the weed detection task more difficult according to the lower AP values, thus offering more room for improvement.

## 5 Conclusion

We recorded and annotated a multispectral weed detection dataset and evaluated it using a Mask-RCNN instance segmentation model that we trained in a transfer learning approach by adapting the first and last layers to be compatible with our data, while keeping as many of the previously learned weights as possible. We found that the multispectral images can significantly improve the weed detection performance in many cases. More precisely the weed detection performance at earlier stages of crop growth was significantly improved from an AP@50 of 50% to 72% by using multispectral data. In later stages of growth, the AP@50 improved from 54% to 63%. In sunny weather conditions, the AP@50 improved significantly from 42% to 58% using multispectral data. In cloudy situations where the lighting conditions are more homogeneous, the AP@50 got improved from 58% to 67%. The performance of the models can potentially be further improved through hyperparameter optimization or anchor sizes adaption, though that was not the goal of this

comparative study. For real world practical weeding applications, a distinction between different weed varieties would be useful, which can be examined in future research.





Fig. 2: BBox AP@50 of the three models evaluated on different subsets of the test set. “All” describes the mAP@50 over both classes. The error bars describe the 95% confidence interval

### Bibliography

- [Ch17] Chebrolu, N. et al.: Agricultural Robot Dataset for Plant Classification, Localization and Mapping on Sugar Beet Fields. *The International Journal of Robotics Research* 36 (10), 1045–52, 2017.
- [He17] He, K. et al.: Mask R-CNN. In: 2017 IEEE International Conference on Computer Vision (ICCV), 2980–88, 2017.
- [Me18] Meier, U.: Growth Stages of Mono- and Dicotyledonous Plants: BBCH Monograph. Open Agrar Repositorium, Quedlinburg, 2018.
- [Sa18] Sa, I. et al.: WeedMap: A Large-Scale Semantic Weed Mapping Framework Using Aerial Multispectral Imaging and Deep Neural Network for Precision Farming. *Remote Sensing* 10 (9), 1423, 2018.

## Praxistest zum Einsatz von UHF-RFID- Transponderohrmarken in der Ferkelaufzucht

Adriana Förschner <sup>1</sup>, Anita Kapun<sup>2</sup> und Eva Gallmann<sup>2</sup>


**Abstract:** Der Einsatz der elektronischen Tiererkennung in der landwirtschaftlichen Nutztierhaltung bietet viele Möglichkeiten im Bereich des Tiermonitorings. In diesem Beitrag werden in einem Projekt entwickelte elektronische Ohrmarken vorgestellt und getestet, die eine Pulkerfassung in Gruppen ermöglichen und dabei klein genug sind, um sie Aufzuchtferkeln einzuziehen. Hierfür wurden die Beschäftigungstürme in vier Buchten mit Antennen ausgestattet und insgesamt 96 Aufzuchtferkeln elektronische UHF-RFID-Transponderohrmarken eingezogen. Erste Auswertungen zeigen sehr gute Ergebnisse bezüglich der Erkennungsrate und der Lesereichweite der Ohrmarken. Weitere Auswertungen sind nötig, um die Wiederholbarkeit und Zuverlässigkeit der Funktionalität der Ohrmarken zu überprüfen.

**Keywords:** Elektronische Tiererkennung, UHF-RFID, Aufzuchtferkel

### 1 Einleitung

Die elektronische Tiererkennung ist schon seit einiger Zeit Standard sowohl in der Haustier- als auch in der Nutztierhaltung. Üblicherweise kommen hier LF-Transponder (low frequency) zum Einsatz. Die Vorteile von ultrahochfrequenten Radio-Frequenz-Identifikationssystemen (UHF-RFID) liegen unter anderem in einer höheren Lesereichweite und insbesondere in der Pulkerfassung (d. h. mehrere Tiere können quasi gleichzeitig erkannt werden). So konnten in verschiedenen Untersuchungen mit UHF-RFID bei Schweinen bisher schon Aufenthaltsdauern an Beschäftigungsautomaten oder Trögen erfasst [Ka20 ; KAG20] sowie die Möglichkeit einer Ortung im Stall evaluiert werden [Ad16]. Dafür wurden allerdings entweder recht große, selbstentwickelte Ohrmarken oder pro Schwein je zwei der auf dem Markt verfügbaren Ohrmarken verwendet, um ausreichende Erkennungsraten zu generieren. Im Projekt „UTE 2“ (Ultra-hochfrequente Tiererkennung – Teil 2) sollten unter anderem UHF-RFID-Transponder für Ferkelohrmarken entwickelt und getestet werden, die über die Wertschöpfungskette hinweg am Tier verbleiben können und durchgängig gleichmäßig gut lesbar bleiben

---

<sup>1</sup> Landwirtschaftliches Zentrum für Rinderhaltung, Grünlandwirtschaft, Milchwirtschaft, Wild und Fischerei  
Baden-Württemberg, Atzenberger Weg 99, 88326 Aulendorf, [adriana.foerschner@lazbw.bwl.de](mailto:adriana.foerschner@lazbw.bwl.de),   
<https://orcid.org/0000-0002-7643-074X>

<sup>2</sup> Universität Hohenheim, Zentrum für Tierhaltungstechnik, Garbenstr. 9, 70599 Stuttgart, [anita.kapun@uni-hohenheim.de](mailto:anita.kapun@uni-hohenheim.de), [eva.gallmann@uni-hohenheim.de](mailto:eva.gallmann@uni-hohenheim.de)

sollen. Im vorliegenden Versuch wurden einige dieser Transponderohrmarken bei Schweinen in der Ferkelaufzucht auf ihre Funktionalität getestet.

## 2 Material und Methoden

In diesem Abschnitt wird der Gesamtversuchsaufbau beschrieben. Im vorliegenden Beitrag werden jedoch zunächst nur beispielhaft Ergebnisse aus einer Bucht präsentiert.

Der Versuch wurde Anfang 2020 (2.1.2020 bis 19.2.2020) am Bildungs- und Wissenszentrum Boxberg (Landesanstalt für Schweinezucht – LSZ) in einem Abteil mit vier Buchten im Ferkelaufzuchtstall durchgeführt. Je Bucht wurden 24 Aufzuchtferkel im Alter von 28 Tagen und mit einem Durchschnittsgewicht von 7,8 kg ( $\pm 1,5$  kg) gemischtgeschlechtlich eingestallt (insgesamt 96 Tiere). Die Aufzuchtbuchten waren jeweils 15 m<sup>2</sup> groß und verfügten neben dem Trog (Breiautomat), vier Tränken (zwei Nippeltränken und zwei Beckentränken) und einem Beschäftigungsturm auch über zusätzliches Beschäftigungsmaterial (zwei Sisalseile, ein Holzstück und eine Scheuerleiste). Am Beschäftigungsturm in jeder Bucht wurde entweder eine UHF-RFID-Antenne (MIRA-100-circular, Kathrein Solutions GmbH, Stephanskirchen, Deutschland), die mit einem externen Lesegerät verbunden war, oder ein UHF-RFID-Lesegerät mit integrierter Antenne (TSU 200, deister electronic GmbH, Barsinghausen, Deutschland) eingebaut. Abbildung 1 zeigt den Aufbau einer Bucht sowie die Lesetechnik im Inneren des Beschäftigungsturms (in diesem Fall TSU 200). Die Ausgangsleistung des TSU 200 lag bei etwa 27 dBm EIRP (effective isotropic radiated power).




Abb. 1: Aufbau einer Aufzuchtbucht mit Beschäftigungsmöglichkeiten (links) und Lesegerät (TSU 200) im Inneren des Beschäftigungsturms (Mitte) sowie Ferkel mit Transponderohrmarke (rechts)

Jedes Ferkel bekam zu Beginn der Ferkelaufzucht eine UHF-RFID-Transponderohrmarke (flexible Torbogenform, Multiflex®, Caisley International GmbH, Bocholt, Deutschland) eingezogen (Abb. 1 rechts). Pro Bucht wurden hierbei drei unterschiedliche, im Projekt entwickelte Transpondertypen in den Ohrmarken zufällig auf je acht Ferkel verteilt (interne Bezeichnungen D220, D230 und D290, deister electronic GmbH, Barsinghausen, Deutschland). Diese Transpondertypen unterschieden sich hauptsächlich im Antennendesign innerhalb der Ohrmarke. Bei den Ferkeln einer Bucht waren zusätzlich managementbedingt bereits kommerziell verfügbare UHF-RFID-Knopfmarken in einem Ohr vorhanden. Diese beeinträchtigen die Lesefunktion der anderen Ohrmarken nicht und können getrennt erkannt und ausgewertet werden.

Für die Evaluierung der verschiedenen Transponderohrmarken und Lesetechniken wurden an jeweils zwei Tagen zu Beginn und Mitte der Ferkelaufzucht von 04:00 Uhr bis 20:00 Uhr (14 h) Videoaufnahmen an den vier Beschäftigungstürmen gemacht, um die RFID-Lesungen mit den tatsächlichen Aufenthalten der Ferkel zu vergleichen. Hierfür wurden die Ferkel am jeweils ersten Aufnahmetag entsprechend markiert. Außerdem wurde viermal täglich automatisiert eine kleine Menge Häckselstroh am Beschäftigungsturm ausgegeben. Die Übereinstimmung von Videoaufnahmen und RFID-Lesungen wurde analog zu anderen Versuchen mit RFID-Systemen bei Schweinen [Ma16] mithilfe der binären Klassifikatoren Sensitivität, Spezifität, Positiver Vorhersagewert und Korrektklassifikationsrate ermittelt. Die Ferkel sollten vom RFID-System erkannt werden, wenn sie sich mit dem Kopf innerhalb des Betonrings um den Beschäftigungsturm befanden (definierter Lesebereich).

### **3 Ergebnisse**

Im Folgenden werden als erste Auswertungen beispielhaft die Ergebnisse einer Bucht dargestellt. In dieser Bucht war das UHF-RFID-Lesegerät TSU 200 verbaut. Abbildung 2 zeigt die Ergebnisse zur Sensitivität und zum Positiven Vorhersagewert für die Videoauswertung der vier Versuchstage für Bucht 1 (drei Transpondertypen in den Ohrmarken, acht Ferkel je Transpondertyp, vier Versuchstage).

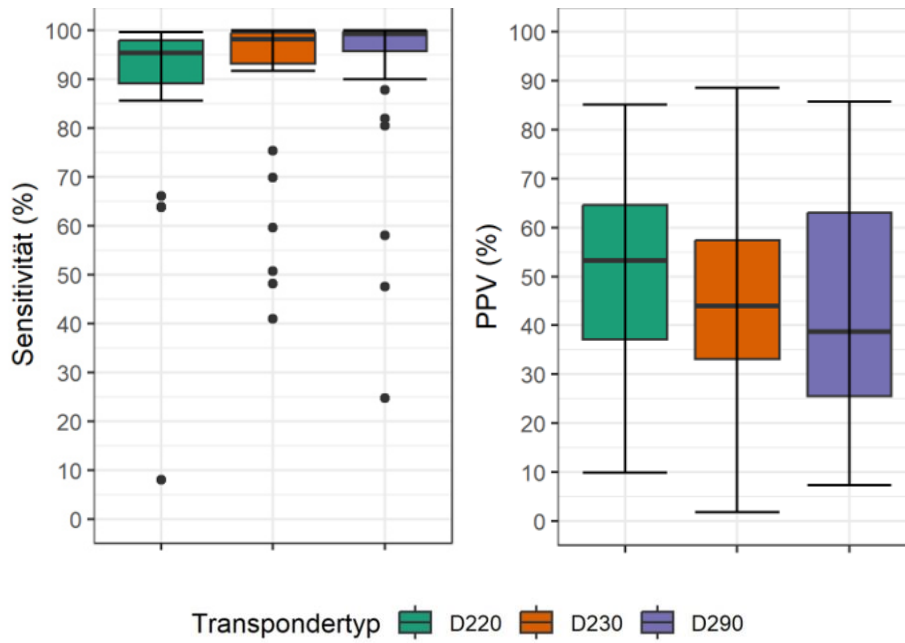


Abb. 2: Ergebnisse zur Sensitivität (links) und zum Positiven Vorhersagewert (rechts) für den Vergleich zwischen Videoaufnahmen und UHF-RFID-Lesungen von drei unterschiedlichen Transpondertypen in den Ohrmarken in einer Bucht an vier Versuchstagen (n=32 je Boxplot, Boxplots mit Whiskern der Länge 1,5 x Interquartilsabstand)

Die Sensitivität gibt an, mit welcher Wahrscheinlichkeit ein Tier erkannt wurde, wenn es sich im Bereich des Beschäftigungsturms aufhielt, und liegt bei allen drei Transponderohrmarken im Durchschnitt bei über 90 %. Allerdings gibt es auch bei allen drei Typen Ausreißer nach unten (Werte liegen mehr als 1,5 x Interquartilsabstand unter dem unteren Quartil), einmal sogar bis unter 10 %. Der Positive Vorhersagewert spiegelt wider, ob die Tiere, die durch das RFID-System erkannt wurden, sich auch tatsächlich im definierten Lesebereich des Beschäftigungsturms aufgehalten haben. Dieser Wert ist bei allen drei Transponderohrmarken in Bucht 1 im Mittel zwischen 40 und 50 % und streut zudem sehr stark. Dies bedeutet, dass die Tiere vermutlich zu oft vom RFID-System erkannt wurden, obwohl sie sich nicht im definierten Lesebereich direkt am Ring um den Beschäftigungsturm befanden. Die Spezifität und die Korrektklassifikationsrate lagen jeweils bei über 95 % im Durchschnitt (Spezifität zwischen 96,7 und 97,5 %; Korrektklassifikationsrate zwischen 95,4 und 97,1 %).



## 4 Diskussion

Die Ergebnisse zeigen, dass alle drei im Versuch getesteten UHF-RFID-Transponderohrmarken zumindest in der ausgewerteten Bucht vielversprechende Ergebnisse erzielen. Laut einer Studie [Br19] sollten die binären Klassifikatoren mindestens folgende Werte erreichen: Sensitivität mind. 80 %, Positiver Vorhersagewert mind. 70 %, Spezifität und Korrektklassifikationsrate mind. 95 %. Somit sind die Ergebnisse für die Sensitivität, die Spezifität und die Korrektklassifikationsrate als sehr gut zu bewerten, wohingegen der Positive Vorhersagewert nicht ausreichend hoch ist, da das UHF-RFID-System die Ferkel vermutlich (unerwarteterweise entgegen vorangegangenen Tests) in einem größeren Umkreis als erwünscht noch erkannt hat. Dem kann allerdings mit einer Anpassung der Ausgangsleistung an der UHF-RFID-Antenne bis zu einem gewissen Grad entgegengewirkt werden. Aufgrund der sehr guten Sensitivität besteht hier durchaus Spielraum, das System hinsichtlich aller Werte noch zu optimieren. Ein System, das „zu viel“ erkennt, kann in seiner Leistung verringert werden, wohingegen es nicht möglich ist, schlecht lesbare Transponder beliebig weit zu erkennen. Im vorliegenden Versuch ging es allerdings nicht um die Optimierung des gesamten UHF-RFID-Systems, sondern vielmehr um die Prüfung und den Vergleich verschiedener im Projekt „UTE 2“ entwickelter UHF-RFID-Transponderohrmarken.

In anderen Versuchen mit kommerziellen UHF-Knopfmarken im gleichen Ferkelaufzuchtstall konnte eine Sensitivität von ca. 71 % erzielt werden [Ka21]. Diese sind allerdings nur bedingt mit dem hier durchgeführten Versuch vergleichbar. Zum einen war die Ausgangsleistung der Antenne (MIRA-100-circular) geringer als die Leistung des Lesegerätes (TSU 200) in der hier ausgewerteten Bucht, was bedingt, dass die Leserate und -reichweiten tendenziell eher schlechter sind. Zum anderen wurde dieser Wert für die Sensitivität durch Einsatz von zwei gleichen UHF-RFID-Ohrmarken je Ferkel erzielt [Ka20].

Die im vorliegenden Versuch getesteten Transponderohrmarken scheinen insgesamt noch eine relativ hohe Streuung in ihrer sonst guten Leistung zu haben. Es handelt sich hierbei noch um Prototypen, die eine gewisse Fertigungstoleranz haben. Außerdem hängt die Lesereichweite auch zum Teil davon ab, ob die Transponderohrmarken eng am Ferkelohr anliegen oder Abstand zum Ohr haben. Weitere Auswertungen zu den Ergebnissen der anderen Buchten, zur Wiederholbarkeit und Funktionalität, zum Einfluss des Ferkelwachstums sowie den genaueren Ursachen für bessere oder schlechtere Lesungen folgen.

## 5 Fazit

Es konnte gezeigt werden, dass die entwickelten UHF-RFID-Transponderohrmarken ein sehr großes Potenzial haben. Mit ihrer Größe sind sie klein und leicht genug, um schon bei Ferkeln in jungem Alter eingezogen zu werden, und zeigen dabei in ersten

Auswertungen eine sehr gute Leserate. Dies bildet eine vielversprechende Ausgangslage für zukünftige Versuche und Einsatzmöglichkeiten.

**Förderhinweis:** Die Autoren danken der Bundesanstalt für Landwirtschaft und Ernährung und der Landwirtschaftlichen Rentenbank für die Förderung im Rahmen der Deutschen Innovationspartnerschaft (DIP) Agrar. Die Förderung erfolgte aus Mitteln des Zweckvermögens des Bundes bei der Landwirtschaftlichen Rentenbank.

**Danksagung:** Die Autoren danken den Projektpartnern agrident GmbH, Caisley International GmbH, deister electronic GmbH, Phenobyte GmbH & Co. KG, der Hochschule Hannover und ihren Mitarbeitern.

#### Literaturverzeichnis

- [Ad16] Adrion, F. et al.: Sektorlokalisierung von Mastschweinen mit UHF-RFID. In (Ruckelshausen, A. et al. Hrsg.): Informatik in der Land-, Forst- und Ernährungswirtschaft. Fokus: Intelligente Systeme - Stand der Technik und neue Möglichkeiten; Referate der 36. GIL-Jahrestagung, 22.-23. Februar 2016 in Osnabrück, Germany. Gesellschaft für Informatik, Bonn, S. 17–20, 2016.
- [Br19] Brown-Brandl, T. M. et al.: A review of passive radio frequency identification systems for animal monitoring in livestock facilities. *Applied Engineering in Agriculture* 4/35, S. 579–591, 2019.
- [Ka20] Kauselmann, K. et al.: Turning the gaze to maize: The effects of maize kernels in straw as enrichment on exploration in pigs. *Berliner und Münchener Tierärztliche Wochenschrift* 12/133, 2020.
- [Ka21] Kauselmann, K. et al.: Tasty straw pellets - Exploration of flavoured rooting material by pigs. *Animal an international journal of animal bioscience* 6/15, S. 100239, 2021.
- [KAG20] Kapun, A.; Adrion, F.; Gallmann, E.: Case study on recording pigs' daily activity patterns with a UHF-RFID system. *Agriculture* 11/10, S. 542, 2020.
- [Ma16] Maselyne, J. et al.: Methods to construct feeding visits from RFID registrations of growing-finishing pigs at the feed trough. *Computers and Electronics in Agriculture* 128, S. 9–19, 2016.

## Brunstüberwachung nur digital? Vergleichende Bewertung von Brunsterkennungssystemen in der Milchviehhaltung

Adriana Förschner<sup>1</sup>, Lisa Aumann<sup>2</sup> und Hansjörg Nußbaum<sup>2</sup>

**Abstract:** Durch das Precision Livestock Farming (PLF) haben sich verschiedene Sensorsysteme zur automatischen Brunsterkennung etabliert. Allerdings gibt es nur selten die Möglichkeit, verschiedene Sensorsysteme zur Brunsterkennung auf dem Betrieb zu vergleichen und solche PLF-Systeme zu demonstrieren. Ziel dieser ersten Untersuchung war es, drei Brunsterkennungssysteme mit dem Goldstandard „Milchprogesteronmessung“ an einem AMS rein digital und ohne visuelle Kontrolle am „LAZBW Aulendorf“ zu vergleichen. Betrachtet wurden ein Brunsterkennungssystem auf Basis eines Halsbandsensors, einer Sensorohrmarke und eines Pansenbolus. Um die Güte der einzelnen Brunsterkennungssysteme zu beurteilen, wurden die Alarmer der untersuchten Sensorsysteme mit dem Brunstalarm der Milchprogesteronmessung verglichen. Der Pansenbolus löste am häufigsten als erstes System nach dem Brunstalarm der Milchprogesteronmessung einen Brunstalarm aus und zeigte die höchste Sensitivität mit 62,82 %. Nähere Untersuchungen der Systeme zeigten, dass die Hälfte der Brunstereignisse tagsüber von 6.00 bis 21.00 Uhr stattfanden.

**Keywords:** Precision Livestock Farming, Sensorsysteme, Brunsterkennung, Milchkühe

### 1 Einleitung

In der heutigen Zeit ist die Möglichkeit der visuellen Brunstbeobachtung durch die Landwirte eingeschränkt. Durch eine wachsende Herdengröße und folglich steigende Arbeitsbelastung der Landwirte bleibt immer weniger Zeit für die visuelle Brunstbeobachtung [Di12]. Auch für Nebenerwerbsbetriebe, bei denen Landwirte außerhalb der Landwirtschaft einer anderen Tätigkeit nachgehen, ist die Brunstbeobachtung in dieser Zeit erschwert. Des Weiteren nehmen die Brunstdauer und die Brunstintensität immer weiter ab. Vor allem hochleistende Tiere zeigen eine geringere Brunstintensität über einen kürzeren Zeitraum [Do08; Lo05]. Außerdem kann vermehrt beobachtet werden, dass Brunstereignisse häufig in den Abendstunden und nachts

---

<sup>1</sup> Landwirtschaftliches Zentrum für Rinderhaltung, Grünlandwirtschaft, Milchwirtschaft, Wild und Fischerei Baden-Württemberg (LAZBW), Atzenberger Weg 99, 88326 Aulendorf, adriana.foerschner@lazbw.bwl.de, hansjoerg.nussbaum@lazbw.bwl.de

<sup>2</sup> Universität Hohenheim, Zentrum für Tierhaltungstechnik, Garbenstr. 9, 70599 Stuttgart, lisa.aumann@gmx.de

geschehen [Di12]. Um einer geringen Brunsterkennungsrate entgegenzuwirken, können verschiedene automatisierte Brunsterkennungssysteme (BES) angewendet werden. Eine Übersicht über verschiedene am Markt erhältliche BES ist in [SU20] zu finden.

Ziel der vorliegenden Untersuchung ist es, drei Brunsterkennungssysteme mit dem Goldstandard „Milchprogesteronmessung“, verbaut in ein Automatisches Melksystem, rein digital und ohne visuelle Brunstbeobachtung zu vergleichen. Betrachtet werden ein BES auf Basis eines Halsbandsensors (Sensor A), einer Sensorrohrmarke (Sensor B) sowie eines Pansenbolus (Sensor C). Für den Vergleich der drei Systeme wurden die Parameter Sensitivität, Positiver Vorhersagewert, Fehlerrate sowie der F1-Score berechnet.

## 2 Material und Methoden

Die Untersuchung wurde im Zeitraum vom 20.02.2023 bis zum 25.06.2023 am LAZBW in Aulendorf (Landwirtschaftliches Zentrum Baden-Württemberg) durchgeführt. Für den Versuch wurden 67 tatsächliche Brunstereignisse von durchschnittlich 48 Milchkühen (Rasse: Fleckvieh) der ersten bis neunten Laktation durch die Milchprogesteronmessung erfasst. Die Versuchstiere wurden in einem einheitlichen Boxenlaufstall mit insgesamt 50 Liegeplätzen gehalten. Es wurden drei verschiedene kommerzielle BES miteinander verglichen: Sensor A wurde am Halsband der Tiere angebracht, Sensor B als Sensorrohrmarke am Ohr befestigt und Sensor C als Bolus im Netzmagen der Kühe platziert. Die untersuchten Kühe waren mit allen drei Systemen ausgestattet. Als Goldstandard diente die Messung des Milchprogesteronspiegels, die in das Automatische Melksystem integriert war. Der Schwellenwert zur Auslösung eines Brunstalarms beträgt  $< 5$  ng/ml. Die Brunstalarne der untersuchten Systeme wurden mit Hilfe des Brunstalarms der Milchprogesteronmessung beurteilt und auf Grundlage der binären Klassifikatoren miteinander verglichen. Fallen der Aktivitätsalarm von Sensor A und die Brunstalarne von Sensor B und Sensor C in den Zeitraum -24 bis +90 Stunden vor/nach dem Brunstalarm der Milchprogesteronmessung, wird das Ergebnis als richtig positiv gewertet. Mit Hilfe von Microsoft Excel 2019 wurden somit die Kennzahlen Sensitivität, Positiver Vorhersagewert, Fehlerrate sowie der F1-Score für das jeweilige System berechnet. Der F1-Score vereint die beiden Parameter Positiver Vorhersagewert und Sensitivität. Der höchste Wert des F1-Scores von 100 wird nur erreicht, wenn sowohl der Positive Vorhersagewert als auch die Sensitivität einen Wert von 100 aufweisen [Ha19].

## 3 Resultate

Insgesamt wurden durch die Milchprogesteronmessung im Beobachtungszeitraum 67 Brunstereignisse, in denen eine tatsächliche Brunst vorlag, erfasst. Der Halsbandsensor erkannte davon 32 richtig positive Ergebnisse. Die Sensorrohrmarke generierte 28 richtig

positive Ergebnisse und der Pansenbolus erfasste mit 44 richtig positiven Ergebnissen die meisten Brunstereignisse (siehe Tab. 1).

|    | Sensor A | Sensor B | Sensor C |
|----|----------|----------|----------|
| rp | 32       | 28       | 44       |
| fp | 15       | 14       | 15       |
| fn | 35       | 39       | 23       |
| rn | 6067     | 6068     | 6067     |

Tab. 1: Absolute Anzahl an richtig positiven (rp), falsch positiven (fp), falsch negativen (fn) und richtig negativen (rn) Ergebnissen der untersuchten Brunsterkennungssysteme bei Betrachtung aller Versuchstiere

In Abbildung 1 sind der Mittelwert (in Prozent) der Sensitivität, des Positiven Vorhersagewerts sowie der Fehlerrate der untersuchten Brunsterkennungssysteme dargestellt.




Abb. 1: Mittelwert (in Prozent) der Kennwerte aus der Wahrheitsmatrix der untersuchten Brunsterkennungssysteme

Es ist zu sehen, dass die Sensitivität mit 62,82 % beim Pansenbolus am höchsten ist. Darauf folgt der Halsbandsensor mit 44,77 % und die Sensorrohrmarke mit 37,82 %. Somit

konnten der Halsbandsensor und die Sensorrohrmarke weniger als die Hälfte aller tatsächlich auftretenden Brunstereignisse richtig erfassen. Der Pansenbolus meldete von 10 tatsächlich brünstigen Kühen 6,3 als richtig brünstig.

Der Positive Vorhersagewert liegt mit 76,74 % beim Pansenbolus am höchsten, gefolgt von der Sensorrohrmarke mit 67,22 % und dem Halsbandsensor mit 65,24 %.

Der Pansenbolus weist die geringste Fehlerrate mit 23,26 % auf. Darauf folgt die Sensorrohrmarke mit 32,78 % und anschließend der Halsbandsensor mit 34,76 %.

In der vorliegenden Untersuchung erreicht der Pansenbolus den höchsten F1-Score mit 69,09, gefolgt vom Halsbandsensor mit 53,10 und der Sensorrohrmarke mit 48,41.

Es wurde betrachtet, welches System die Aktivitätserhöhung bzw. den Brunstalarm in Bezug auf die Milchprogesteronmessung am frühesten auslöst. Der Sensor C (Pansenbolus) löste 30-mal und somit am häufigsten als erstes System einen Brunstalarm aus. Darauf folgt Sensor A (Halsbandsensor) mit 15-mal und Sensor B (Sensorrohrmarke) mit viermal. Das System Sensor B hat mit 14 dritten Plätzen am häufigsten als letztes System einen Brunstalarm ausgelöst.

In der vorliegenden Untersuchung fanden 60,42 % der Brunstereignisse untertags zwischen 6.00 Uhr morgens und 21.00 Uhr abends statt.

## 4 Diskussion

Werden die untersuchten Brunsterkennungssysteme miteinander verglichen, fällt auf, dass sich Sensor C (Pansenbolus) in allen oben genannten Parametern als das zuverlässigste System erwiesen hat. Sensor C erreicht sowohl bei der Sensitivität, dem Positiven Vorhersagewert, der Fehlerrate und dem F1-Score die besten Ergebnisse. Es fällt auf, dass alle drei Brunsterkennungssysteme eine hohe absolute Anzahl an falsch negativen Ergebnissen aufweisen. Würde sich ein Betriebsleiter rein auf die Aktivitätserhöhung bzw. die Brunstalarme verlassen, wäre somit bei jedem System eine hohe Anzahl an Tieren nicht besamt worden. Die hohe Anzahl an falsch negativen Ergebnissen deutet an, dass gegebenenfalls die Schwellenwerte für die Aktivitätserhöhung bzw. die Brunstalarme vor allem bei Sensor A sowie Sensor B zu hoch eingestellt sind.

In der Literatur sind meist Brunsterkennungsraten (Sensitivität) zwischen 59,0 % und 95,0 % und ein Positiver Vorhersagewert von 67,0 % bis 100,0 % zu finden [CH14; Fa17; Ho10; J611; LWL18; Ma19; SC12]. Werden diese Zahlen mit den eigenen Ergebnissen verglichen, kann festgestellt werden, dass die untersuchten Systeme Sensor A und Sensor B mit einer Sensitivität von 44,8 % und 37,8 % unter der oben aufgeführten Spanne liegen. Sensor C würde mit einer Sensitivität von 62,8 % in den Bereich der Literatur fallen. Bei der Betrachtung des Positiven Vorhersagewerts liegen Sensor B und Sensor C mit 67,2 % und 76,7 % im angegebenen Bereich der Literatur.

Einen weiteren wichtigen Parameter zur Beurteilung der Brunsterkennungssysteme stellt die Fehlerrate dar. Andere Untersuchungen nennen hier Werte von 17,0 % bis 55,0 % [Fi02]. In diesen Bereich lassen sich die Ergebnisse der vorliegenden Arbeit einordnen.

Aufgrund der geringen Sensitivität und hohen Fehlerrate schlagen andere Autoren vor, die Systeme mit einer visuellen Brunstbeobachtung zu kombinieren, um bessere Ergebnisse zu erzielen. In einer Untersuchung von [Ho11] konnte bei einer Kombination der Methoden Aktivitätsmessung mittels Halsband (Heatime neck collar, SCR Engineers) und zusätzlich visueller Brunstbeobachtung (sechsmal täglich je 10 min) eine Steigerung der Sensitivität auf 75,0 % erreicht werden. Wurde ausschließlich das Heatime Halsband zur Brunsterkennung verwendet, konnten [Ho11] eine Sensitivität von 58,9 % beobachten.

Insgesamt konnte festgestellt werden, dass die Systeme in der vorliegenden Untersuchung schlechter ausfallen als in anderen Studien. Messfehler können in dieser Betrachtung vor allem auch dadurch entstehen, dass das LAZBW ein Lehr- und Versuchsbetrieb ist. Die Tiere können durch äußere Faktoren, wie z. B. durch fremde Personen im Stall und eine intensivere Betreuung des Bestandes beeinflusst werden.

In einer weiteren Untersuchung ist es sinnvoll, die Systeme über einen längeren Zeitraum mit einer höheren Anzahl an Versuchstieren zu betrachten. Auch eine Auswertung der einzelnen Progesteronverläufe kann geeignet sein, um festzustellen, ob von den untersuchten BES auch stillbrünstige Tiere erkannt werden. Das Ziel dieser Untersuchung war ein erster Vergleich, wie gut eine Brunstbeobachtung rein digital ohne eine zusätzliche visuelle Brunstbeobachtung funktioniert.

## 5 Fazit

Aus der vorliegenden Untersuchung geht hervor, dass die angewandte Methodik funktioniert und sich die Milchprogesteronmessung als Goldstandard als sinnvoll herausgestellt hat. Es wurde festgestellt, dass das System Sensor C (Pansenbolus) die besten Ergebnisse erzielt. Dieser erreicht mit 62,82 % die höchste Sensitivität, gefolgt von Sensor A (Halsbandsensor) und Sensor B (Sensorrohrmarke). In der vorliegenden Untersuchung fanden 60,42 % der Brünste zwischen 6.00 Uhr morgens und 21.00 Uhr abends statt.

**Förderhinweis:** Diese Studie wurde über das Projekt DigiMo LAZBW (Digitaler Modellbetrieb LAZBW) mit Mitteln des Ministeriums für Ernährung, Ländlichen Raum und Verbraucherschutz Baden-Württemberg (MLR) durchgeführt.

### Literaturverzeichnis

- [CH14] Chanvallon, A. et al.: Comparison of three devices for the automated detection of estrus in dairy cows. *Theriogenology* 5/82, S. 734–741, 2014.

- 
- [Di12] Dietrich, O.: Etablierung einer neuen Methode zur automatisierten Brunsterkennung beim Rind, 2012.
- [Do08] Dobson, H. et al.: Why is it getting more difficult to successfully artificially inseminate dairy cows? *Animal an international journal of animal bioscience* 8/2, S. 1104–1111, 2008.
- [Fa17] Fasching, C.: Brunsterkennung-Moderne Systeme im Vergleich. Raumberg-Gumpenstein, S. 63, 2017.
- [Fi02] Firk, R. et al.: Automation of oestrus detection in dairy cows: a review. *Livestock Production Science* 3/75, S. 219–232, 2002.
- [Ha19] Harikrishnan N. B.: Confusion Matrix, Accuracy, Precision, Recall, F1 Score. published in *Analytics Vidhya*. <https://medium.com/analytics-vidhya/confusion-matrix-accuracy-precision-recall-f1-score-ade299cf63cd>.
- [Ho10] Hockey, C. et al.: Evaluation of a neck mounted 2-hourly activity meter system for detecting cows about to ovulate in two paddock-based Australian dairy herds. *Reproduction in domestic animals = Zuchthygiene* 5/45, e107-17, 2010.
- [Ho11] Holman, A. et al.: Comparison of oestrus detection methods in dairy cattle. *The Veterinary record* 2/169, S. 47, 2011.
- [Jó11] Jónsson, R. et al.: Oestrus detection in dairy cows from activity and lying data using on-line individual models. *Computers and Electronics in Agriculture* 1/76, S. 6–15, 2011.
- [Lo05] Lopez, H. et al.: Relationship between level of milk production and multiple ovulations in lactating dairy cows. *Journal of dairy science* 8/88, S. 2783–2793, 2005.
- [LWL18] LeRoy, C. N. S.; Walton, J. S.; LeBlanc, S. J.: Estrous detection intensity and accuracy and optimal timing of insemination with automated activity monitors for dairy cows. *Journal of dairy science* 2/101, S. 1638–1647, 2018.
- [Ma19] Mayo, L. M. et al.: Automated estrous detection using multiple commercial precision dairy monitoring technologies in synchronized dairy cows. *Journal of dairy science* 3/102, S. 2645–2656, 2019.
- [SC12] Saint-Dizier, M.; Chastant-Maillard, S.: Towards an automated detection of oestrus in dairy cattle. *Reproduction in domestic animals = Zuchthygiene* 6/47, S. 1056–1061, 2012.
- [SU20] Stachowicz, J.; Umstätter, C.: Übersicht über kommerziell verfügbare digitale Systeme in der Nutztierhaltung. *Agroscope*, 2020.



## Visual servoing in 3D to enhance full farming in occluded vegetable sceneries

Josef Franko<sup>1</sup>, Sivaparvathi Mannem<sup>2</sup>, Simon Maike<sup>1</sup>, Ting Sheng Lee<sup>1</sup>, Rolf Becker<sup>2</sup>  
and Bettina Weber<sup>1</sup>

**Abstract:** In recent years, there has been extensive research and development in the field of agricultural robots. The AgriPV-Bot is a multipurpose field robot to perform selective cultivation in market gardening. However, the cultivation of mixed vegetables in occluded sceneries where not all features are perceptible from top-down perspective poses a challenge especially in spot-farming applications. Therefore, this paper proposes a sweeping motion approach based on 3D visual servoing to utilize multiple view angles to effectively address this challenge. The approach is evaluated both in a simulation and real-world environment.

**Keywords:** 3D visual servoing, occlude vegetable scenes, harvesting robots, full farming, market gardening, automation

### 1 Introduction

Autonomous robotics are revolutionizing agriculture by exploring a range of tasks like weeding, harvesting, irrigation, fertilization, and crop monitoring with higher precision. These advances lead to less resource input as well as higher yields and diminish the necessity for manual labor. Unlike their industrial counterparts, agricultural robots operate in unstructured outdoor environments, which presents significant challenges. However, innovations such as the AgriPV-Bot, which utilizes a rigid linear guide rail, mitigate environmental uncertainties like e.g., uneven or soft terrain. The system must contend with varying weather conditions that can impair the sensors. Consequently, the software and algorithms of agricultural robots must be flexible and adaptable. Recent advances in machine learning and the adoption of the Robot Operating System (ROS) are bringing this level of sophistication within reach of outdoor applications, see [Bi20].

While the technologies for motion and navigation in agricultural robotics have reached a mature level, the capabilities of perception and manipulation still present significant challenges. Plant recognition and precise localization are particularly unreliable in instances of occlusion. Occlusion, a prevalent problem in image processing and computer vision, limits the visual data that is accessible to sensors by blocking the view. Merging this technology with natural environments presents a major challenge. Vegetables, fruits,

---

<sup>1</sup>AI.Land GmbH, Siebenhäuser 7, 47906 Kempen, info@a-i.land

<sup>2</sup>Hochschule Rhein-Waal, Friedrich-Heinrich-Allee 25, 47475 Kamp-Lintfort, rolf.becker@hochschule-rhein-waal.de

weeds, and others are often blocked by surrounding plants from an above perspective. This obstruction poses a risk to robot-assisted farming, potentially leading to less-than-optimal harvests and unintentional crop damage, see [Li22]. Therefore, the development of effective solutions to address the occlusion in the sensor pipeline is imperative to overcome monotonous and physically demanding manual field work.




Fig. 1: Occluded view of kohlrabi plants (left); occluded view of zucchini (right)

Most plants inherit a habit of shielding their core fruits with leaves or excessive foliage, which complicates the task of robotic systems in accurately detecting and localizing produce from an overhead perspective for picking or treatment, as depicted in Figures 1 and 2. Prior research has extensively investigated vegetable recognition, pose estimation, segmentation, and other related computational techniques under conditions of minimal or non-existent occlusion. Nevertheless, advancing into real-world scenarios is another challenge. The methodologies for addressing scenarios with complete occlusion are scarcely documented in literature.



Fig. 2: Occluded zucchini scene, raw image (top view, left); zucchini, raw image (side view, middle); zucchini, ML-segmentation (side view, right)

This gap signifies a substantial challenge in the field of precision agriculture robotics, as complete occlusion substantially diminishes the efficacy of conventional visual-based recognition systems. In this work, a universal approach to harvesting occluded vegetables is proposed, which supports the adoption of automation, robotics, and AI to a variety of vegetable crops in order to increase the farming efficiency and overall competitiveness of farmers.

## 2 State of the Art

Visual servoing is a technique where visual information from calibrated vision sensors is extracted with respect to its locations, and algorithms guide the motion of the robotic manipulator towards that location. The primary goal of visual servoing systems is to reduce the error  $e(t)$  between current visual features  $s(t)$  and target  $s^*$  in an iterative process, cf. [Mo21].

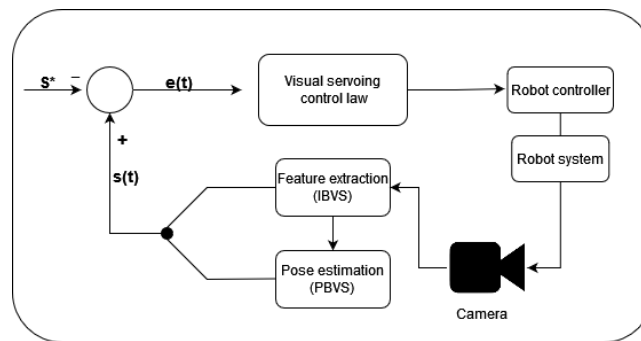


Fig. 3: Visual servoing pipeline

One or more cameras are used to extract the information within the range and to control the robotic arm. The main advantage of this process is that the robot can operate all types of changing and unstructured outdoor environments. There are two ways to configure the camera in visual servoing. (1) eye in hand (2) eye to hand. Within the first method, the camera moves along with the robotic arm. The sight of the camera is limited but it is more accurate. Within the second method, the camera is mounted within the workspace for visual information.

In recent years, many of the agricultural robotic applications attracted the interest of academic researchers. In literature there are numerous robots that are designed to harvest a variety of fruits and vegetables such as iceberg lettuce, broccoli, tomato, sweet pepper, apples, oranges, and many other crops, cf. [Ju21]. Nevertheless, with over 50 fruits and vegetables holding significant market shares that are yet to be harvested autonomously, the sector is poised for innovations that tackle more complex challenges, such as occlusions, that impede robotic harvesting.

## 3 Methodology

The paper refers to visual servoing as the conceptual foundation for robot-based manipulation tasks in unstructured environments. In addition to a sense-and-act approach, the robot arm is programmed to sweep through the area of interest while scanning the scene. Consequently, the vision pipelines receive multiple views from various angles,

enhancing plant recognition and localization in occluded scenes. The approach is simulated in the Gazebo physics engine, and the results are evaluated in a real-world environment using the AgriPV-Bot.




Fig. 4: Overview of the AgriPV-Bot – a semi-mobile agricultural robot for mixed cultivation

Various specialized farming robots are available in the market, but most are not inclusive for the entire farming process. The AgriPV-Bot is a multipurpose autonomous full farming field robot to perform selective and precise cultivation, realized through the mobile robotic arm manipulator, which is mounted on a sledge gliding on rigid guiderails, while the whole system rotates over the crops. Multiple vegetable cultivation is proposed in confined arable land which can be termed as multi-vegetable micro spot-farming. The cultivation of a mixture of vegetables side by side is entitled to improve the biodiversity and reduce large insect populations and other crop diseases.

A Gazebo simulation is created to improve a vegetable harvesting algorithm with a software-in-the-loop approach. This allows testing the software without intense hardware cost prior to the implementation of an actual system. However, to simulate a harvesting robot in Gazebo several components are required: CAD files configuration, vegetable scene along with the robotic arm, and a setup of multiple sensors. Most importantly, the visual servoing and control mechanism for the end effector. For operating the robot and functioning, ROS noetic and python programming is used.

The flow chart in Figure 5 explains the harvest process of occluded and non-occluded ground vegetables using a robotic arm. However, if the scenery is not occluded and vegetables are detected from the top view with a robotic arm the harvesting processing is fast and efficient. The problem arises when a robot is ready to harvest the vegetable from the top and the latter is occluded to an extent that it is completely hidden under the leaves. To overcome this challenge, the novel approach is to place the robot camera (eye in hand) in a lateral angle to the crops and to create a detailed view of the scene using 2D detection methods. For accurate identification of position and orientation in the real world, a 3D pose is determined. Finally, a position-based visual servoing framework is used as visual input from a camera to guide the motion of the end-effector, which is a gripper in our case.

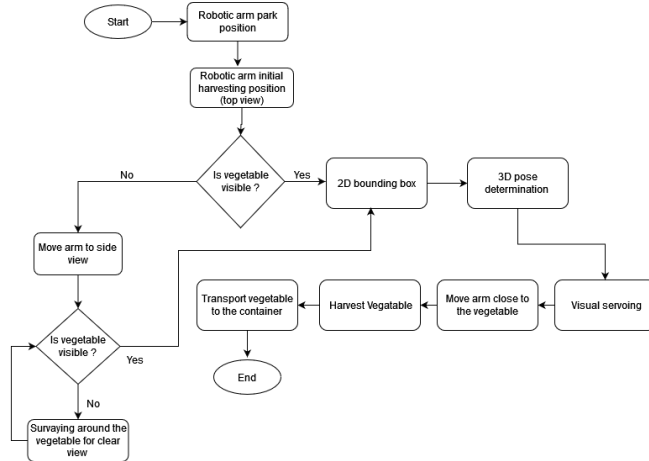


Fig. 5: Harvesting process in occluded and non-occluded conditions (flow chart)

#### 4 Results and Discussion

Although there is significant research and development of harvesting robots in agriculture going on, vegetable harvesting in occluded sceneries it is still widely unrecognized. This approach can be established with existing low-cost vision sensors and enhances the efficiency for harvesting based on plant recognition and localization. The simulation in Gazebo can be subdivided into several steps.




Fig. 6: Manipulator initialization around the area of interest; surveying, scanning, or sweeping; goal estimation (side-view); pick-up process

In Figure 6, the camera is attached to the gripper (eye in hand) to find the vegetable in the scene, but the plant’s edible part is covered by leaves. The probability of the robot to grab the plant without damaging it is relatively low. Thus, the robot sweeps around the area of interest to estimate the goal from a better angle and calculates the picking position with a higher probability of a successful harvest. Based on the simulation in Gazebo, the sweeping algorithm has been tested with plastic balls, before tests have been carried out on kohlrabi. The routine for the sweep motion is implemented into the Yaskawa robot controller and can be triggered through an TCP/IP interface from the ROS server. After

the DCNN confirms a match with the object, ROS takes over to perform 3D visual servoing for a high-precision picking action.



Fig. 7: Validating the simulated algorithm with plastic balls



Fig. 8: Final evaluation on kohlrabi

The Yaskawa HC10 has an IP rating of 67 and may work without additional weather-proof sleeves. During the upcoming season, the proposed harvesting strategy is compared head-to-head to the common top view approach to quantify the improvement. The end-effector is equipped with a tool-changing system to perform multiple tasks based on the visual guiding algorithm presented in this paper. Subsequent applications are weed detection and weed control, root level irrigation and predictive fertilization.

**Acknowledgements:** The published approach to vegetable harvesting is a partial result from the GEM project funded by the European Union within the REACT-EU fund.

#### Bibliography

- [Bi20] Birrell, S. et al.: A field-tested robotic harvesting system for iceberg lettuce. *Journal of Field Robotics*, Volume 37(2), 225–245, 2020.
- [Li22] Li, T. et al.: Occluded Apple Fruit Detection and Localization with a Frustum-Based Point-Cloud-Processing Approach for Robotic Harvesting. *Remote Sensing*, Volume 14(3), 482, 2022.
- [Mo21] Mohamed, I. S: MPPI-VS: Sampling-Based Model Predictive Control Strategy for Constrained Image-Based and Position-Based Visual Servoing. 2021.
- [Ju21] Jun, J. et al.: Towards an efficient tomato harvesting robot: 3D perception, manipulation, and end-effector. *IEEE Access*, Volume 9, 17631–17640, 2021.

## A multi-talented datacube: integrating, processing and presenting big geodata for the agricultural end user

Christoph Friedrich<sup>1</sup>, Johannes Löw<sup>2</sup>, Insa Otte<sup>1</sup>, Steven Hill<sup>1</sup>, Sebastian Förtsch<sup>1</sup>, Jakob Schwalb-Willmann<sup>1</sup>, Ursula Gessner<sup>3</sup>, Christoph Schierghofer<sup>3</sup>, Sina Truckenbrodt<sup>4,5</sup>, Eric Schonert<sup>4</sup>, Thomas Piernicke<sup>6</sup>, Denise Assmann<sup>7</sup>, Christopher Conrad<sup>2</sup> and Michael Thiel<sup>1</sup>

**Abstract:** While scientific methods leveraging Earth Observation for agriculture are abundant, their actual application in Germany remains scarce. A key challenge in this context is to connect the end users to the data without the many technical obstacles. Therefore, we present a versatile platform that not only integrates and processes big geodata of highly diverse origin and type, but also provides access to these resources in ways that reflect the individual user's requirements and expertise. Based on free and open-source software building blocks, our datacube facilitates scientific computation through R and Python environments or direct API access, including emergent technologies such as openEO, STAC, and COG. At the same time, the results are delivered to easy-to-use applications that adequately present them to non-technical experts. We detail the architecture of the system and demonstrate a use case serving computed plant vitality information directly to farmers in the field.

**Keywords:** analysis-ready data, cloud processing, interoperability, data access, user interfaces

### 1 Introduction

Agricultural land management is a major application for Earth Observation (EO) research. It is capable of delivering a variety of information on crop land at high spatial and temporal resolution, ranging from plant vitality and phenology to yield and biomass estimations. This has been utilised for several use cases such as monitoring of subsidies and application maps based on vegetation indices [Eu22]. However, in Germany the agriculturalists

---

<sup>1</sup> University of Würzburg, Institute for Geography and Geology, Department of Remote Sensing, Earth Observation Research Cluster, John-Skilton-Straße 4, 97074 Würzburg, Germany; christoph.friedrich@uni-wuerzburg.de

<sup>2</sup> University of Halle-Wittenberg, Institute for Geosciences and Geography, Department of Geocology, Von-Seckendorff-Platz 4, 06120 Halle (Saale), Germany

<sup>3</sup> German Aerospace Center (DLR), German Remote Sensing Data Center (DFD), Münchener Straße 20, 82234 Weßling-Oberpfaffenhofen, Germany

<sup>4</sup> German Aerospace Center (DLR), Institute of Data Science, Department of Data Acquisition and Mobilisation, Mälzerstraße 3-5, 07745 Jena, Germany

<sup>5</sup> University of Jena, Institute of Geography, Department of Earth Observation, Leutrargraben 1, 07743 Jena, Germany

<sup>6</sup> GFZ German Research Centre for Geosciences Potsdam, Department 1: Geodesy, Section 1.4: Remote Sensing and Geoinformatics, Telegrafenberg, 14473 Potsdam, Germany

<sup>7</sup> Deutscher Wetterdienst, Department of Agrometeorology, Körnerstraße 68, 04288 Leipzig, Germany

working the fields – who are at the core of the system and should thus be the main beneficiaries of such research – are not yet applying EO-based information widely and to its full extent.

This is often attributed to the collected data being abundant in principle, but difficult to use in practice – especially when data from various sources or of different types needs to be combined. In addition to this *variety*, which gets increasingly common as increasingly complicated challenges are tackled, the sheer *volume* of today’s geodata and the *velocity* of its creation add to the urgent need for Big Data management strategies. Therefore, our research project “AgriSens DEMMIN 4.0” not only addresses the creation of novel remote-sensing-based application techniques, but also puts an equally distinct emphasis on the development of an accompanying data integration and visualisation system. In the following, we describe how this essential tool closes the gap between data providers (e.g., satellite operators) and information consumers (e.g., farmers) by facilitating necessary analysis steps and combining these with adequate presentation for data-driven decision making in the agricultural reality.

## 2 Methods

In our IT architecture, we utilise one central *datacube* to conquer this problem, which acts as a cloud-based data holding and computation platform. It gathers a multitude of data (ranging from optical and radar raster imagery through climate data to in-situ field measurements) and pre-processes it into an interoperable, analysis-ready state. These resources can then be accessed through APIs for external usage; or computations can be carried out directly on the datacube and their results immediately visualised with tools hosted on the same server. Through this, we are aiming to make data usage more user-friendly. Figure 1 illustrates the architecture of our datacube, while the following text explains its capabilities in more detail.

The physical system is entirely located at the Leibniz Supercomputing Centre of the Bavarian Academy of Sciences and Humanities (LRZ). Apart from utilising the computing resources available there, this also opens up synergies with already-existing projects: we can directly access the enormous amount of EO data that is already available within the LRZ’s “Data Science Storage” and the DLR’s “terabyte” platform. These storages are directly mounted into our server so that the datacube can access petabytes of imagery without having to duplicate it again, saving costs and emissions. This provides data from major EO satellite missions such as Landsat, MODIS, Sentinel-1, and Sentinel-2, which are essential to many EO workflows and thus a necessity for many EO users. As the supplied archives are not (yet) complete, we partly augment it by ingesting the needed missing parts from the “Open Data on AWS” programme and hosting them locally. All data is pre-processed (e.g. atmospheric correction) and provided in the Cloud-Optimised GeoTIFF (COG) format, resulting in a large collection of analysis-ready data (ARD).






Fig. 1: The architecture of our datacube within its ecosystem. Data that has been acquired (bottom left) is processed by the datacube (big box) so that it can be utilised easily by end users (right-hand side). The latter, depicted by the pictograms, may be farmers, consultants, scientists, policy makers, or basically any agricultural stakeholder wishing to utilise EO data

Extending this rather common data offering, we also compute more special data that is currently intensively researched: Synthetic Aperture Radar (SAR) data has demonstrated its value for agricultural applications such as crop inventories and monitoring applications [Lo23; LUC21]. Its processing, however, is complex and computationally intensive. We set up a pipeline based on “ESA SNAP” (version 9) and “pyroSAR” [Tr19] that consumes Sentinel-1 data and generates products such as InSAR coherence as well as Alpha and Entropy, which are not easily and openly available elsewhere in an analysis-ready format.

Apart from this extensive satellite data repository, our catalogue also contains derived products such as Digital Elevation Models (DEMs), as well as project data like drone imagery or in-situ measurements from field campaigns. Another asset is (agro-) meteorological data provided by the German Weather Service (DWD). It is released every month through their FTP server, from where it is automatically downloaded into the datacube infrastructure, converted from the typical meteorological netCDF format into the more cloud-friendly GeoTIFF format, and then ingested into the datacube’s database. It originates from a network of climate stations of the DEMMIN long-term test site and is delivered as hourly values interpolated over an area of 37 by 43 kilometres [HL22].

The core of our infrastructure is an instance of the “Open Data Cube” software package, which is open source. It provides the functionalities to handle user-specific data requests for computation and visualisation purposes and therefore acts as the link between

metadata, data, and our output channels. The metadata is ingested into its PostgreSQL database and can be retrieved via its built-in “Explorer”, a web-based data discovery application. It is also exposed via an API endpoint of the emergent STAC standard, which in turn can be accessed via the “STAC Browser” or any other compatible software. As we use the COG format for raster data, access is efficient even from remote machines.

Our main interface for scientific computation is Jupyter Hub, enabling collaborative work across institutions. For each user a dedicated Jupyter Lab instance is spawned in its own Docker container that can access all the data of the previously mentioned storages and has a certain amount of computing resources allocated to it. Using containerisation allows to manage resources and minimises the interference for other users while maintaining collaborative pathways via shared folders. Users can write their code in Python or R, which offer the straightforward packages “datacube” or “odcR”, respectively. Another way to work with the data is via openEO, a standardised way to interact with big EO data cloud processing backends via so-called process graphs. This integration is achieved via the “openEO Spring Driver”.

However, to reach our target audience of people who are not EO data experts, these very technical interfaces are not suitable, but easy and straightforward access to data and functionality is required. Therefore, our priority is on developing easy-to-use graphical interfaces that visualise the data and scientific products in a manner that effectively helps the end users. One way to achieve this, which we are applying extensively, is to host not only the data, but also purpose-built web applications that present it via powerful JavaScript mapping libraries like OpenLayers. However, in the next section we explain in detail a case study that utilises a more special output channel.

### 3 Case Study: from Satellite to Field

One use case being realised in this context is a near-real-time plant vitality information system. Vegetation indices (VIs) are computed on incoming Sentinel-2 scenes as soon as they become available and compared to the average VI value that has been measured over the four years 2019 to 2022 for the same crop type and time of year. An interactive mobile application, called *FieldMApp*, then consumes this data, enabling farmers to directly assess the current status of their field on-site in comparison to the long-term average.

The baseline time series of multi-annual average VI values per crop type are calculated based on Sentinel-2 optical satellite data. In order to know which pixels to consider for which crop type’s average, crop type maps that have been created within the AgriSens DEMMIN 4.0 project are utilised. They were produced using a method similar to the one described by Asam et al. [As22] and are available for the years 2019 to 2022, covering the area of the German state of Mecklenburg-Vorpommern. Accordingly, all available Sentinel-2 imagery for this spatio-temporal extent is utilised, atmospherically corrected and cloud masked using the PACO and Fmask algorithms, respectively. Data gaps are

filled by linear interpolation before the data is resampled into continuous 4-year time series of 5-day frequency (analogous to the 5-day revisit frequency of Sentinel-2A/B). Based on this reflectance data, the four VIs NDVI, SAVI, NDYI, and EVI are calculated, resulting in time series of VIs. These are subsequently stratified by the 16 crop types (e.g. winter wheat, maize, potatoes, rapeseed) using the aforementioned crop type maps. Then, for each 5-day time step within one year, the multi-annual (2019-2022) mean and standard deviation are calculated for each pair of VI and crop type. These values are finally exported in the CSV format for further usage.

The datacube is set up to automatically process new Sentinel-2 scenes as soon as they become available. Upon their ingestion, an automatic pipeline is triggered that computes the four aforementioned VIs on the new imagery and produces anomaly products for each of the 16 crop types. To do so, the applicable long-term average closest to the capture date is looked up and subtracted from the VI raster as a constant value. The resulting rasters are then exposed directly as COGs as well as through a Web Map Service (WMS) for increased compatibility with existing software. For the conversion, the “datacube-ows” package is employed.

One output channel is the *FieldMApp*. It is an application (app) for mobile devices that provides support to farmers in sustainable land management and crop production. The app aims at an optimized application of production resources by combining satellite-based crop monitoring data (e.g. from the datacube), freely available geodata, and digitised local knowledge of farmers. The latter can be acquired with the *FieldMApp*, based on (1) a tool for recording and annotating areal data during field management, (2) forms generated with the “Open Data Kit”, and (3) a geographic information system (GIS). With the GIS, vector and raster data from different sources (local or from servers) can be visualised, and, moreover, vector data can be edited. The app is developed using the Flutter framework, employing an offline-first approach to meet the needs of farmers working under varying (i.e., often bad or inexistent) network coverage conditions. This framework was chosen for its ability to facilitate the writing of platform-agnostic code while maintaining native performance and accommodating the integration of platform-specific implementations that are crucial for incorporating hardware sensors.

The modular structure of the *FieldMApp* allows for easy extensibility and adaptability. As such, incorporating the plant vitality information explained above as an additional visualisation layer was uncomplicated. Since Flutter’s geospatial visualisation library “Flutter\_Map” does not yet support the rendering of GeoTIFFs, the datacube exposes the anomaly rasters via a WMS. Through this standardised data service, the *FieldMApp* can load the appropriate data by setting the “style” parameter of the request according to the needed crop type and desired vegetation index. While the latter is to be specified on presentation, information about the crop type is part of the field metadata that the app stores anyway, so is already known. They also contain the field’s boundaries, which are utilised to mask out the areas of the delivered image that do not belong to the field.

## 4 Discussion and Outlook

While the individual building blocks of the solution presented here are not fundamentally new, we argue that our integrated end-to-end approach is quite distinguished and will be helpful in advancing the uptake of EO-based methods in the agricultural sector. As such, our datacube can be a facilitator towards increasing the technology readiness of EO products: the simplification of prohibitively complicated steps increases real-world usage. Our datacube offers both the familiar Jupyter interface as well as state-of-the-art APIs. This empowers scientists and programmers to utilise the wealth of available data with the flexibility of a coding environment and thus to supply the latest methodological developments to farmers. The developed infrastructure leverages software packages that are tried-and-tested yet incorporate recent developments, ensuring the system to be both stable and modern. The free and open-source concept of the datacube also ensures that data supply and interfaces remain customisable towards the specific needs of end users. It is also a strategic advantage over existing solutions such as Google Earth Engine, which is powerful, but eventually a black box dependent on the good will of one company.

Overall, our datacube is an effective tool for bringing together users of various backgrounds and expertise, due to its variety of access levels from simple app-based visualisation to coding environments. It is publicly available to some extent through the website <https://eo2cube.org/>. Field tests with farmers will bring insights into the real-world usage of the developed system. It will be expanded by including further project-driven use cases such as drone-based irrigation monitoring. Also, even more output channels are to be unlocked, e.g. through a dedicated plugin that connects to established GIS platforms.

### Bibliography

- [As22] Asam, S. et al.: Mapping Crop Types of Germany by Combining Temporal Statistical Metrics of Sentinel-1 and Sentinel-2 Time Series with LPIS Data. *Remote Sensing* 14/13, 2022.
- [Eu22] European Commission; Joint Research Centre; Åstrand, P.; Devos, W.; Loudjani, P.: Controls with remote sensing in the CAP2020+. Publications Office of the European Union, 2022.
- [HL22] Haßelbusch, K.; Lucas-Moffat, A.: Rasterdaten für die Agrarmeteorologie: Vergleich verschiedener Interpolationsverfahren am Beispiel AgriSens Demmin 4.0, 2022.
- [Lo23] Lobert, F. et al.: A deep learning approach for deriving winter wheat phenology from optical and SAR time series at field level. *Remote Sensing of Environment* 298/, pp. 113800, 2023.
- [LUC21] Löw, J.; Ullmann, T.; Conrad, C.: The Impact of Phenological Developments on Interferometric and Polarimetric Crop Signatures Derived from Sentinel-1: Examples from the DEMMIN Study Site (Germany). *Remote Sensing* 13/15, 2021.
- [Tr19] Truckenbrodt, J. et al.: Towards Sentinel-1 SAR Analysis-Ready Data: A Best Practices Assessment on Preparing Backscatter Data for the Cube. *Data* 4/3, 2019

## Automatisierte Unterscheidung von Feldarbeit und Straßenfahrt für Landmaschinen mit Hilfe von unüberwachten KI-Methoden

Manuel Geil<sup>1</sup>, Jan-Henrik Helmig<sup>1</sup>, Julian Jour<sup>1</sup>, Bodo Mistele<sup>1</sup>, Jens Peters<sup>1</sup>, Katharina Stahl<sup>1</sup> und Andreas Wübbecke<sup>1</sup>

**Abstract:** Die Dokumentation von Daten in der Agrarwirtschaft erweist sich für Landwirte als zunehmend aufwändige Tätigkeit, welche meist immer noch manuell erfolgt. Ziel unserer Forschungsarbeit ist es, Maschinendaten zu nutzen, um zwischen Feldarbeit und Straßenfahrt automatisch zu klassifizieren. Die Maschinendaten werden als kontinuierlicher Strom vom Maschinenstart bis zum Ausschalten der Maschine übermittelt und können Daten aus unterschiedlichen Tätigkeiten enthalten. Um ein manuelles Labeling als auch Erfassen der Feldgrenzen zu vermeiden, wird ein Ansatz verfolgt, mittels eines dichte-basierten Clustering-Verfahrens die Daten zu klassifizieren. Dieses Verfahren schien aufgrund der Dichte der Datenpunkte auf den Schlägen als vielversprechend. Im weiteren Verlauf konnte die Methode durch das Hinzuziehen der Fahrtgeschwindigkeit und das Bilden konvexer Hüllen weiter verbessert werden.

**Keywords:** Tätigkeitsklassifikation, Dokumentation, Maschinendaten, Clustering

### 1 Einleitung

Landmaschinen sind heute mit vielfältiger Sensortechnik ausgestattet, die über den ISO-Bus der Landmaschinen ausgelesen werden kann. Diese dabei entstehenden Messwerte können dann wiederum von Datenloggern aufgezeichnet werden. Im Falle des von uns verwendeten Loggers<sup>2</sup> wird mit dem Starten der Maschine (beispielsweise auf dem Hof des Landwirts) und bis zu deren Stoppen eine Logdatei geschrieben. Jeder Datenpunkt wird hier mit einem Zeitstempel sowie einer Geo-Position und der Fahrtgeschwindigkeit angereichert. Die aufgezeichneten Messwerte können dann als Datenbasis für eine automatisierte Bestimmung der Tätigkeit auf dem Schlag genutzt werden. Damit kann ein großer Beitrag zur automatisierten Dokumentation landwirtschaftlicher Betriebe geschaffen werden, was zu einer erheblichen Entlastung der Landwirte führen kann. Die

---

<sup>1</sup> FH Südwestfalen, Lübecker Ring 2, 59494 Soest, geil.manuel@fh-swf.de

<sup>2</sup> Exatrek: <https://exatrek.de/>

aufgezeichneten Daten enthalten nicht nur reine Feldarbeit, sondern unterschiedliche Arten, wie Straßenfahrten, Feld- und Hofarbeiten in beliebiger Reihenfolge, Häufigkeit und Dauer. In einem ersten Schritt werden die Daten hinsichtlich Straßenfahrten und Feldarbeit getrennt.

## 2 Diskussion von Lösungsansätzen

In diesem Beitrag führen wir diese Unterscheidung auf den durch den Datenlogger erfassten Daten durch, ohne dass weitere Informationen über beispielsweise die geographische Lage der Schläge hinzugezogen werden. Dazu nutzen wir ein Clustering-Verfahren, welches Fahrten auf einem Schlag, und damit die Feldarbeit als solche, als Cluster identifiziert und Straßenfahrten in Form von Rauschen aus den Messdaten eliminiert. Dieses liefert damit eine Vorklassifizierung der Daten, die als bereinigter Input zur Klassifikation mittels maschinellen Lernverfahrens genutzt werden können.

Im Rahmen eines vorhergehenden Forschungsprojektes wurden auf einem landwirtschaftlichen Betrieb im Zeitraum zwischen 2019 und 2021 an 358 Tagen insgesamt 8.168.956 Datenpunkte zu unterschiedlichen Tätigkeiten gesammelt. Im Rahmen unseres Vorgehens sollten diese Daten zunächst analysiert werden, wozu eine Trennung der Daten im Hinblick auf Straßenfahrten und Feldarbeit notwendig war.

Eine erste Überlegung war es, anhand des Kartenmaterials bestehender Geoinformationssysteme zu detektieren, ob sich eine Geoposition auf einer Straße befindet oder nicht. Dieser Ansatz konnte schnell verworfen werden, da einerseits viele Wirtschaftswege nicht in den Geoinformationssystemen dokumentiert sind, andererseits nie unterschieden werden konnte, ob der Punkt außerhalb der Straße ein Schlag oder beispielsweise der Hof des Landwirts ist. Ein weiterer diskutierter Ansatz war es, zur Unterscheidung die Feldgrenzen heranzuziehen. Eine Vielzahl an Forschungsprojekten [Ku21; NPB19; RB01; WO20; WM00] haben sich bereits mit der Erkennung von Feldgrenzen anhand von Kartenmaterial als auch Satellitenbildern beschäftigt. Dieser Ansatz wurde aufgrund der Komplexität verworfen, da unser Ansatz, um für den Nutzer einfach anwendbar zu sein, auf weitere externe Informationen (z. B. Satellitendaten und Feldgrenzen) verzichten sollte. Ein zu unserem Beitrag ähnlicher Ansatz ist in [PEN21] beschrieben. Hierbei liegt die Erkennungsrate auf ähnlichem aber leicht schlechterem Niveau.

Durch Visualisierung der Datenpunkte in einem geografischen Informationssystem (GIS) konnten wir erkennen, dass sich eine Vielzahl an Datenpunkten auf Schlägen sammelt, jedoch auf Straßen nur einzelne, oftmals weiter auseinanderliegende Punkte liegen. Daher verfolgten wir einen Ansatz, der einen dichtebasierten Clustering-Algorithmus verwendet, um die Daten in Straßenfahrten und Feldarbeiten aufzutrennen. Im Folgenden beschreiben wir die Implementierung, die wir in mehreren Stufen optimiert haben.

### 3 Umsetzung

Für die Umsetzung haben wir uns aufgrund der bereits festgestellten Punkte-Dichte in den erwarteten Clustern für den DBSCAN<sup>3</sup>-Algorithmus entschieden. Bei diesem Algorithmus wird mithilfe von dichte-basierten Parametern die Distanz zum nächsten Nachbarn eines Punktes und die Menge notwendiger Nachbarn bestimmt, bevor ein Punkt einem Cluster zugeordnet wird. Punkte, die keinem Cluster zugeordnet werden können, weisen nur wenige Messpunkte in einem vorgegebenen Radius auf und gelten hierbei als Noise-Points (Rauschen). Unsere Annahme war es, dass die Punkte auf den Schlägen einem Cluster zugeordnet werden und die Straßenfahrten als Rauschen verworfen werden.

Durch die manuelle Auswertung der Dichte-Punkteverteilung einer kleinen Stichprobe konnte als Parameter für den Nachbarradius des DBSCAN-Algorithmus  $0,00035^4$  bei 40 Nachbarpunkten ermittelt werden. Abbildung 1 zeigt eine erste Trennung von Straßenfahrten als blaue und Feldarbeit als rote Punkte. Mit diesen Werten konnten wir bei einer manuellen Kontrolle durch Visualisierung für 50 % der Datensätze eine korrekte Trennung der Cluster erreichen. Dieser Wert stellt eine schlechte Erkennungsrate für die Klassifizierung dar, weswegen wir im Folgenden weitere Modifikationen des Ansatzes diskutieren werden.

Als erstes Problem konnten wir Fahrten, die direkt am Schlag auf einer Straße oder einem Wirtschaftsweg vorbeiführen, identifizieren. Diese werden aufgrund der geringen Abstandsdistanz und hohen Dichte den Arbeitsclustern zugeschlagen (siehe Abbildung 1, orangene Markierung). Auch hier half uns der DBSCAN-Algorithmus: Dieser lässt sich nicht nur im zwei- sondern auch im mehrdimensionalen Raum anwenden. Wir haben als dritte Dimension, neben der Geo-Position, die Geschwindigkeit der Landmaschine genutzt. Mithilfe deskriptiver Statistik wurde eine Transformationskurve entwickelt (vgl. Abbildung 2), welche höhere Geschwindigkeiten (für Feldarbeiten eher ungewöhnlich) bestraft und niedrigere Geschwindigkeiten auf einen Einheitswert normiert. Dieser Ansatz basiert auf statistischer Auswertung der Geschwindigkeit von mehreren Straßenfahrten und Feldarbeiten. Der Median der Geschwindigkeit unterschied sich dabei signifikant. Die Genauigkeit des Auftrennens der Daten in Cluster stieg dadurch auf 70 %.

Als ein weiteres Problem beim Auftrennen der Daten konnten längere Halte an Straßenkreuzungen (siehe Abbildung 1, weiße Markierungen) und Arbeitsgänge, die auf dem Hof des Landwirtes stattfinden, identifiziert werden. Da der Datenlogger für jede Sekunde einen Datenpunkt erstellt, ergibt sich bei längerem Halt oder Hofarbeiten eine hohe Dichte an Punkten auf einer sehr kleinen Fläche. Um diese Ungenauigkeiten zu eliminieren, wurde zu jedem ermittelten Cluster mittels einer konvexen Hülle der Flächen-

<sup>3</sup> Density-Based Spatial Clustering of Applications with Noise

<sup>4</sup> Bei Verwendung von Koordinaten im WGS84 Format entsprechen  $0,00035 = 38,35 \text{ Metern}$  ( $0,00035 \cdot 111 \text{ km}$ )



Abb. 1: Als Arbeitsgang fehlklassifizierte Straßenfahrten direkt an einem Schlag

inhalt ermittelt und Cluster unter einem bestimmten, empirisch ermittelten Flächeninhalt verworfen. Die Genauigkeit der Cluster-Zuordnung stieg auf 75 %.

Final wurde versucht, die Gesamtgenauigkeit durch die Berücksichtigung einer vierten Dimension, der Zeit, erneut zu verbessern. Abbildung 3 links zeigt Erkennungsprobleme, wie einzelne Messwertausreißer und enorme Dichteschwankungen während der Feldarbeit dazu führen, dass die Datenpunkte falsch zugeordnet werden. Der zeitliche Aspekt kann nicht als zusätzliche Dimension in den Cluster-Algorithmus aufgenommen werden, da dies zu einer räumlichen Spreizung der Datenpunkte während der Feldarbeit führen würde. Daher werden die Ergebnisse des Clusterings in einem weiteren Klassifikations-Algorithmus weiterverarbeitet.

Der Cluster-Algorithmus bietet als Ausgabe eine Liste mit mehreren Clustern und den dazugehörigen Datenpunkten. Nun werden wieder alle Datenpunkte von vor dem Clustering betrachtet und jene, welche der DBSCAN-Algorithmus einem Cluster zugeordnet hat, markiert. Danach wurden alle Datenpunkte in ihrer zeitlichen Reihenfolge betrachtet und mittels der Übergänge zwischen Rausch-Punkten (Straßenfahrt) und Cluster-assoziierten markierten Punkten (Feldarbeit) Blöcke, wiederum in Form von Feldarbeit und Straßenfahrt, gebildet. Für einen gültigen Übergang müssen in einem neuen Block mindestens 30 Datenpunkte vorhanden sein. War der vorherige Block der Tätigkeit Feldarbeit und der neue Block eine Straßenfahrt, wird außerdem bis zu einer Anzahl von 400 Datenpunkten im Straßenfahrt-Block geprüft, ob die maximale Geschwindigkeit unter 6 m/s und die mittlere Geschwindigkeit unter 4 m/s liegt.






Abb. 2: Transformationskurve zur Trennung von Straßenfahrten direkt am Schlag

Trifft eine dieser Bedingungen zu, wird der Übergang verworfen und die Punkte werden dem vorherigen Tätigkeitsblock zugeordnet. Das Vorgehen sorgt dafür, dass die Aufteilung der Datensätze zu 99 % korrekt erfolgt. Die rechte Darstellung in Abbildung 3 zeigt die korrekt klassifizierten Datenpunkte. Um auf das Beispiel vom Anfang zurückzukommen, zeigt Abbildung 4 den korrekt klassifizierten Datensatz.



Abb. 3: Fehlerhaft geclusterte Datenpunkte (links). Verbesserung durch Klassifikationsalgorithmus (rechts)

#### 4 Zusammenfassung und Ausblick

In diesem Beitrag haben wir einen automatisierten Ansatz zur Unterscheidung von Straßenfahrt und Feldarbeit für landwirtschaftliche Maschinen dargestellt. Dieser Ansatz erreichte dabei eine 99 % korrekte Aufteilung der Datenpunkte zu den jeweiligen Tätigkeiten. Der Ansatz kommt dabei ohne manuelle Korrekturen oder externe Informationen wie Feldgrenzen aus und ist dadurch potenziell einfach in Kontexte wie Farmmanagement-Systeme zu integrieren.

Bisher ist der Ansatz auf den Daten des Forschungsbetriebes validiert worden. Zukünftig wäre eine Validierung mit einer noch größeren Menge an Datensätzen notwendig, um eine gute Generalisierung des Algorithmus auf neue Eingabedaten sicherzustellen. Insbesondere sollten Daten mit einbezogen werden, welche ungewöhnliche Topologien beinhalten, wie zum Beispiel Schläge am Hang.



Abb. 4: Final aufgetrennter Datensatz in fünf Cluster

#### Literaturverzeichnis

- [Ku21] Kuchkorov, T. et al.: Agro-field Boundary Detection using Mask R-CNN from Satellite and Aerial Images. In: 2021 International Conference on Information Science and Communications Technologies (ICISCT). Tashkent, Uzbekistan: IEEE, 2021 – ISBN 978-1-66543-258-0, S. 1–3, 2021.
- [NPB19] North, H. C.; Pairman, D.; Belliss, S. E.: Boundary Delineation of Agricultural Fields in Multitemporal Satellite Imagery. In: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing Bd. 12 (2019), Nr. 1, S. 237–251, 2019.
- [PEN21] Poteko, J.; Eder, D.; Noack, P. O.: Identifying operation modes of agricultural vehicles based on GNSS measurements, In: Computers and Electronics in Agriculture, Vol. 185, 2021.
- [RB01] Rydberg, A.; Borgefors, G.: Integrated method for boundary delineation of agricultural fields in multispectral satellite images. In: IEEE Transactions on Geoscience and Remote Sensing Bd. 39 (2001), Nr. 11, S. 2514–2520, 2001.
- [WO20] Wagner, M. P.; Ooppelt, N.: Extracting Agricultural Fields from Remote Sensing Imagery Using Graph-Based Growing Contours. In: Remote Sensing Bd. 12 (2020), Nr. 7, S. 1205, 2020.
- [WM00] Wei-Ying M.; Manjunath, B. S.: EdgeFlow: a technique for boundary detection and image segmentation. In: IEEE Transactions on Image Processing Bd. 9 (2000), Nr. 8, S. 1375–1388, 2000.

## Transformation von Maschinendaten als Eingabe für maschinelle Lernverfahren zur Klassifikation von landwirtschaftlichen Arbeitsgängen

Manuel Geil<sup>1</sup>, Jan-Henrik Helmig<sup>1</sup>, Julian Jour<sup>1</sup>, Bodo Mistele<sup>1</sup>, Jens Peters<sup>1</sup>, Katharina Stahl<sup>1</sup> und Andreas Wübbeke<sup>1</sup>

**Abstract:** Landwirte dokumentieren heutzutage noch immer häufig ihre Tätigkeiten auf Schlägen manuell, was eine aufwändige und fehleranfällige Tätigkeit darstellt. Dies wird zunehmend belastend, da die Dokumentationspflichten für Landwirte umfangreicher werden. In diesem Beitrag wurden bereits aufgenommene Maschinendaten zur Klassifikation von Maschinentätigkeiten analysiert und basierend darauf transformiert. Der daraus resultierende reduzierte Datensatz diente als Eingabe für maschinelle Lernverfahren zur Klassifikation von landwirtschaftlichen Tätigkeiten. Die Klassifikationsgenauigkeit der überprüften Verfahren lag bei über 93 %. Unter Einbezug von Daten einer fremden Landmaschine, mit denen die ML-Modelle vorher nicht trainiert wurden, war der Random Forest das Lernverfahren mit der höchsten Klassifikationsgenauigkeit. Die Ergebnisse dieser Arbeit zeigen, dass Klassifikationsmodelle maschineller Lernverfahren mit transformierten und reduzierten Maschinendaten Klassifikationsergebnisse zur automatisierten Tätigkeitsdokumentation liefern können.

**Keywords:** Klassifikation, maschinelle Lernverfahren, Maschinendaten, künstliche Intelligenz

### 1 Einleitung

Die zunehmende Verbreitung von Farmmanagementsystemen verspricht eine vereinfachte Dokumentation von landwirtschaftlichen Tätigkeiten, jedoch werden diese auch heute noch häufig manuell dokumentiert und führen damit zu hohen Kosten sowie einer erhöhten Fehleranfälligkeit. Demnach stellen hohe Anfangsinvestitionskosten, die fehlende Kompatibilität unterschiedlicher landwirtschaftlicher Systeme und die fragliche Wirtschaftlichkeit die Gründe hierfür dar [Ga21]. Der folgende Beitrag setzt an den stetig steigenden Dokumentationspflichten für Landwirten und den bisherigen Möglichkeiten zur automatisierten Tätigkeitsklassifizierung von Farmmanagementsystemen mittels georeferenzierter Daten an. Im Rahmen dieses Beitrags wurden händisch vorklassifizierte Maschinendaten analysiert und passende Merkmale ausgewählt, um anhand dieser

---

<sup>1</sup> FH Südwestfalen, Lübecker Ring 2, 59494 Soest, geil.manuel@fh-swf.de

maschinelle Lernverfahren zur Klassifizierung von Arbeitsgängen anzulernen. Die landwirtschaftlichen Rohdaten wurden mit dem Datenlogger des Herstellers exatrek<sup>2</sup> aufgenommen [Gö18].

## 2 Material und methodisches Vorgehen

### 2.1 Problembeschreibung

Dieser Beitrag beschäftigt sich mit der automatisierten Bestimmung von landwirtschaftlichen Tätigkeiten wie Düngen, Aussäen oder Pflügen auf Basis von Maschinenrohdaten. Aus den Daten eines landwirtschaftlichen Kooperationsbetriebes, die zwischen 2019 und 2021 aufgezeichnet wurden, sollten maschinelle Lernverfahren verwendet werden, um Modelle zur Klassifizierung von landwirtschaftlichen Arbeitsgängen zu erzeugen. Diese Daten lagen vorklassifiziert vor, da diese vom Landwirt zunächst manuell in Arbeitsgänge sortiert wurden.

Der Datensatz beinhaltet 1995 Dateien mit knapp 8,2 Millionen Zeilen. Die 16 landwirtschaftlichen Tätigkeiten darin wurden von dem Landwirt des Kooperationsbetriebes vorselektiert. Die Arbeitsgänge liegen in Zeitreihen als Rohdaten vor. Ein intuitives Vorgehen stellt deshalb eine Zeitreihenbetrachtung dar. Es ist jedoch zu vermuten, dass dies einen rechenintensiven Ansatz zur Mustererkennung erfordert.

### 2.2 Erste Analyseergebnisse

Aus den vorliegenden Daten wurden mit Hilfe der Methode aus [Ge23] die schlagrelevanten Daten extrahiert. Mit Hilfe deskriptiver Statistik wurden die vier Tätigkeiten Aussaat-Mais, Grubbern, Düngen und Pflügen genauer betrachtet. Diese Arbeitsgänge wurden ausgewählt, da diese im Mittel über überdurchschnittlich viele Daten verfügten.

Nach der Bereinigung der Daten (Spalten mit ausschließlich fehlenden Werten wurden eliminiert), wurden Häufigkeitsverteilungen für die Merkmale betrachtet. Dieses Vorgehen hatte das Ziel, herauszuarbeiten, ob die einzelnen Arbeitsgänge signifikante Unterschiede in der Ausgestaltung der Merkmalsausprägung aufweisen. Im Folgenden wird das Vorgehen am Beispiel der Tätigkeiten „Düngen“ und „Pflügen“ verdeutlicht. So bildeten die Daten beim Merkmal „Speed“ (Geschwindigkeit in m/s) bei den beiden Tätigkeiten im Histogramm ein Spektrum mit jeweils zwei Peaks, die sich von der Ausprägung voneinander deutlich unterscheiden (vgl. Abb. 1). So ist zu erkennen, dass bei der Geschwindigkeit während des Pflügens die Geschwindigkeit wesentlich häufiger

---

<sup>2</sup> <https://exatrek.de/index.html>

0 m/s beträgt als bei der Tätigkeit „Düngen“. Außerdem kann anhand der beiden Histogramme festgestellt werden, dass „Düngen“ bei höheren Geschwindigkeiten stattfindet als „Pflügen“.




Abb. 1: Häufigkeitsverteilung der Datenpunkte für das Merkmal „Geschwindigkeit“ bei den Tätigkeiten „Düngen“ und „Pflügen“

Basierend auf der Analyse der Häufigkeitsverteilung wurden fünf Merkmale (Stellung Heckkraftheber in %, Geschwindigkeit in m/s, Motorlast in %, Motordrehzahl in Umdrehungen/min und Kraftstoffverbrauch in l/h) ausgearbeitet, die aufgrund der tätigkeitsspezifischen Häufigkeitsverteilung für eine spätere automatisierte Detektion wertvollen Input liefern sollten.




Abb. 2: Darstellung der Korrelationen für den Arbeitsgang „Düngen“ und „Pflügen“ als Heatmaps

Um die Beziehungen zwischen Merkmalen zu untersuchen, wurden Korrelationsmatrizen betrachtet. Für die Korrelationsmatrix wurden die 20 Merkmale verwendet, die bei jeder Tätigkeit vorhanden waren. So konnte sichergestellt werden, dass Korrelationen der Merkmale zwischen den untersuchten Tätigkeiten verglichen werden konnten.

Die Korrelationsmatrizen wurden als Heatmaps optisch aufbereitet (vgl. Abb. 2). Geringe Korrelationen sind bei den abgebildeten Heatmaps blasser, stärkere Farben deuten auf eine hohe Korrelation zwischen Merkmalen hin. Ein Ziel der Datenanalyse war es, die Korrelationswerte zu bestimmen, die tätigkeitsübergreifend hohe Varianzen beinhalteten.

Unser Ansatz war, den Wert der Korrelation je Merkmalspaar von Interesse über eine Varianzmatrix zu ermitteln. In der Varianzmatrix wurden für jedes Feld die Varianzen der Korrelationsmatrizen der Arbeitsgänge „Düngen“, „Pflügen“, „Grubbern“ und „Aussaat-Getreide“ berechnet. Die Varianzen mit einem überdurchschnittlich hohen Wert (in unserem Fall > 0,1, empirisch ermittelt) stellen Indikatoren zur Ermittlung von Entscheidungsgrenzen dar, weiterhin sind niedrige Varianzen (Wert < 0,1) irrelevant für die Unterscheidung von landwirtschaftlichen Tätigkeiten (Abb. 3).

|          | SPEED    | ENG_Tor  | ENG_Spe  | ENG_Fue  | ENG_Loa  | WB_Spee  | ENG_Wat  | Veh_Hou  | TEMP_An  | PRESS_B  | ENG_ABL  | RHich_P  | RHich_In | Rear_Dra | Rear_Nfc | WB_Dir   | GB_Dir   | GB_Spee  | MachSelF | MachSelE |
|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| SPEED    | 0        | 0,001625 | 0,007767 | 0,002452 | 0,0038   | 0,038892 | 0,012252 | 0,001367 | 0,001092 | 0,020758 | 0,002833 | 0,165533 | 0,103892 | 0,097667 | 0,097667 | 0,016932 | 0,036067 | 0,061958 | 0,075632 | 0,0258   |
| ENG_Tor  | 0,007767 | 0        | 0,007767 | 0,0022   | 0,0035   | 0,038897 | 0,006232 | 0,001833 | 0,010167 | 0,000225 | 0,0055   | 0,39287  | 0,164492 | 0,1711   | 0,1711   | 0,033425 | 0,0242   | 0,041667 | 0,001    | 0,07358  |
| ENG_Spe  | 0,007767 | 0,007767 | 0        | 0,013367 | 0,019558 | 0,0459   | 0,168932 | 0,004467 | 0,021867 | 0,037158 | 0,013425 | 0,217533 | 0,164832 | 0,1539   | 0,1539   | 0,010425 | 0,0303   | 0,047825 | 0,0038   | 0,027    |
| ENG_Fue  | 0,002452 | 0,0022   | 0,013367 | 0        | 0,010067 | 0,0415   | 0,020367 | 0,001233 | 0,000467 | 0,0023   | 0,0014   | 0,228832 | 0,174632 | 0,196633 | 0,196633 | 0,002492 | 0,043158 | 0,058232 | 0,004367 | 0,027633 |
| ENG_Loa  | 0,0038   | 0,0035   | 0,019558 | 0,010067 | 0        | 0,046067 | 0,058758 | 0,014232 | 0,0411   | 0,085767 | 0,0278   | 0,177225 | 0,163767 | 0,152567 | 0,152567 | 0,000633 | 0,038825 | 0,058432 | 0,005667 | 0,010958 |
| WB_Spee  | 0,038892 | 0,038897 | 0,0459   | 0,0415   | 0,046067 | 0        | 0,063025 | 0,030267 | 0,005492 | 0,0026   | 0,053825 | 0,038025 | 0,060033 | 0,056825 | 0,056825 | 0,012232 | 0,113467 | 0,180158 | 0,066025 | 0,0135   |
| ENG_Wat  | 0,012252 | 0,008232 | 0,018892 | 0,020367 | 0,058758 | 0,063025 | 0        | 0,140632 | 0,040425 | 0,248367 | 0,088158 | 0,048825 | 0,033158 | 0,019    | 0,019    | 0,016467 | 0,058667 | 0,097425 | 0,031958 | 0,008833 |
| TEMP_An  | 0,001367 | 0,007633 | 0,004467 | 0,001233 | 0,014232 | 0,030267 | 0,140632 | 0        | 0,047425 | 0,038367 | 0,160632 | 0,017832 | 0,013067 | 0,003958 | 0,003958 | 0,0042   | 0,171933 | 0,156467 | 0,028432 | 0,010433 |
| PRESS_B  | 0,001092 | 0,01367  | 0,021867 | 0,000467 | 0,0411   | 0,005492 | 0,040625 | 0,047425 | 0        | 0,150167 | 0,018425 | 0,035032 | 0,0262   | 0,003032 | 0,003032 | 0,011625 | 0,010467 | 0,003025 | 0,043133 | 0,024225 |
| ENG_ABL  | 0,002833 | 0,0055   | 0,033425 | 0,0023   | 0,005767 | 0,0026   | 0,248367 | 0,038367 | 0,150167 | 0        | 0,150333 | 0,038233 | 0,027833 | 0,005467 | 0,005467 | 0,0228   | 0,017233 | 0,0182   | 0,042067 | 0,027032 |
| RHich_P  | 0,39287  | 0,164492 | 0,1711   | 0,228832 | 0,177225 | 0,163767 | 0,152567 | 0,152567 | 0,053825 | 0,038025 | 0,060033 | 0,056825 | 0,056825 | 0,012232 | 0,113467 | 0,180158 | 0,066025 | 0,0135   | 0,005667 | 0,010958 |
| RHich_In | 0,164492 | 0,1711   | 0,1711   | 0,196633 | 0,1539   | 0,1539   | 0,010425 | 0,0303   | 0,047825 | 0,0038   | 0,027    | 0,07358  | 0,001    | 0,07358  | 0,001    | 0,07358  | 0,001    | 0,07358  | 0,001    | 0,07358  |
| Rear_Dra | 0,097667 | 0,097667 | 0,097667 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 |
| Rear_Nfc | 0,097667 | 0,097667 | 0,097667 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 | 0,036067 | 0,016932 |
| WB_Dir   | 0,016932 | 0,036067 | 0,016932 | 0,002492 | 0,043158 | 0,058232 | 0,004367 | 0,027633 | 0,004367 | 0,027633 | 0,004367 | 0,027633 | 0,004367 | 0,027633 | 0,004367 | 0,027633 | 0,004367 | 0,027633 | 0,004367 | 0,027633 |
| GB_Dir   | 0,036067 | 0,0242   | 0,0303   | 0,043158 | 0,058232 | 0,113467 | 0,096667 | 0,179333 | 0,010467 | 0,017233 | 0,039333 | 0,015232 | 0,041632 | 0,012933 | 0,012933 | 0,064432 | 0        | 0,064432 | 0,024167 | 0,006333 |
| GB_Spee  | 0,061958 | 0,041667 | 0,047825 | 0,058232 | 0,058432 | 0,180158 | 0,097425 | 0,156467 | 0,030267 | 0,0162   | 0,088032 | 0,024633 | 0,062232 | 0,036632 | 0,036632 | 0,044167 | 0,044167 | 0        | 0,066632 | 0,030667 |
| MachSelF | 0,010958 | 0,001    | 0,0038   | 0,004367 | 0,005667 | 0,066025 | 0,031958 | 0,028432 | 0,043133 | 0,042067 | 0,0225   | 0,10167  | 0,185167 | 0,094867 | 0,094867 | 0,006333 | 0,065825 | 0,106832 | 0        | 0,0094   |
| MachSelE | 0,0258   | 0,017358 | 0,027    | 0,027633 | 0,019558 | 0,035    | 0,008833 | 0,010433 | 0,024225 | 0,027032 | 0,005967 | 0,021032 | 0,0531   | 0,023232 | 0,023232 | 0,0143   | 0,033967 | 0,036625 | 0,0094   | 0        |

Abb. 3: Varianzmatrix aus den Korrelationsmatrizen verschiedener Arbeitsgänge (Varianzen farblich unterlegt: weiß < 0,1; gelb = 0,1 – 0,15; orange = 0,15 – 0,2; rot > 0,2)

Die Erkenntnis aus der vorangegangenen Datenanalyse zeigte, dass sich Tätigkeiten mit anderen vorverarbeiteten Informationen klassifizieren lassen. Dadurch werden relevante Eigenschaften für eine erneute Merkmalsbildung gefunden und dadurch konnte ein neuer, transformierter und reduzierter Trainingsdatensatz erstellt werden.

### 2.3 Trainieren der maschinellen Lernverfahren

Mit Hilfe des Programms Orange wurden die erzeugten Trainingsdaten anschließend eingelesen und alle in dem Programm zur Verfügung stehenden maschinellen Lernverfahren trainiert. Die Trainingsdaten wurde anschließend in 70 % Trainingsdaten und 30 % Testdaten aufgeteilt. Die Standardeinstellungen des Programms Orange wurden hinsichtlich der Modellparameter (z. B. Lernrate, Anzahl der Baumtiefen, ...) genutzt.

Einen detaillierten Einblick in den Vergleich der maschinellen Lernverfahren in Bezug auf die Klassifikation für alle Tätigkeiten liefert die Tabelle 1. Sie zeigt die Klassifikationsergebnisse mit Hilfe des Parameters „Classification Accuracy in %“ für die

vier besten Modelle. Das Modell „Gradient Boosting“ weist demnach die höchste „Classification Accuracy“ auf.

| Model             | AUC  | CA   | F1   | Precision | Recall |
|-------------------|------|------|------|-----------|--------|
| Gradient Boosting | 99,6 | 94,3 | 94,2 | 94,5      | 94,3   |
| Neural Network    | 99,5 | 93,6 | 93,6 | 94,1      | 93,6   |
| Random Forest     | 98,7 | 93,0 | 92,6 | 92,6      | 93,0   |
| Ada Boost         | 94,1 | 89,8 | 89,2 | 89,8      | 89,8   |

Tab. 1: Vergleich der trainierten maschinellen Lernverfahren, Genauigkeit in %

### 3 Ergebnisse und Diskussion

#### 3.1 Evaluation

Damit sichergestellt werden kann, dass die drei Modelle mit den besten Kreuzvalidierungsergebnissen (Gradient Boosting, Neural Network und Random Forest) ausreichend gut generalisieren, wurden zudem dem maschinellen Lernverfahren gänzlich unbekannte Rohdaten des landwirtschaftlichen Betriebes aus dem Jahr 2023 verwendet.

Die neuen Roh- und Testdaten beinhalteten Daten von 33 ausgeführten Arbeitsgängen. In der Auswertung und Interpretation konnte festgestellt werden, dass die Modelle „Gradient Boosting“ (60,61 %) und „Neural Network“ (51,52 %) wenig aussagekräftige Klassifikationsergebnisse lieferten. Einzig das Modell „Random Forest“ konnte mit einer Genauigkeit von 81,82 % solide klassifizieren. Es ist daher festzuhalten, dass die Modelle Gradient Boosting und Neural Network einem Overfitting unterliegen und auf Trainingsdaten solide Klassifikationsergebnisse liefern, jedoch neue Testdaten unzureichend klassifizieren.

Auffälligkeiten konnten beispielsweise in der Betrachtung von Fehlklassifikation in Bezug auf den Arbeitsgang „Grubbern“ erkannt werden. Dieser wurde beispielsweise häufig als „Stoppelbearbeitung“ detektiert und weist in der Ausübung der Tätigkeit ähnliche Merkmalsausprägungen und -korrelationen auf.

#### 3.2 Diskussion

Aktuelle Forschungsvorhaben basieren im Wesentlichen auf der landwirtschaftlichen Aktivitätserkennung aufgrund von Zeitreihen und zusätzlichen Informationen wie z. B. externen GNSS-Daten. Dabei werden zum einen klassische maschinelle Lernverfahren

(z. B. Entscheidungsbaum oder K-Means, [PEN21; Ya22]) zur Unterscheidung zwischen Feld- und Straßenfahrt angewandt, allerdings nicht zur Klassifikation von Tätigkeiten auf dem Feld genutzt. Zum anderen stellen Deep-Learning-Verfahren und die Nutzung von Bildern, welche Zeitreihen visualisieren und anschließend als Input dienen, Computer-Vision-Ansätze dar [Ch23]. Dies ist im Vergleich zu dem in diesem Beitrag aufgezeigten Vorgehen ein sehr rechenintensiver Ansatz. In diesem Beitrag entwickelten wir einen Ansatz, der im Gegensatz zu den bisherigen Forschungsergebnissen nicht auf der Kenntnis der geographischen Position der Maschine oder von Feldgrenzen, sondern insbesondere auf die Merkmalsausprägung von verfügbaren Arbeitsdaten stützt. Der entwickelte Ansatz arbeitet auf enorm reduzierten Daten, bei denen jede vollständig abgeschlossene Feldtätigkeit einen Datenpunkt für das Klassifikationsmodell darstellt.

Dieser Beitrag zeigt, dass maschinelle Lernverfahren Klassifikationsmodelle mit transformierten reduzierten Maschinendaten gute Klassifikationsergebnisse zur automatisierten Tätigkeitserkennung liefern. Der beschriebene Ansatz kann mit der Bereitstellung von weiteren landwirtschaftlichen Daten und einer damit einhergehenden Vergrößerung des Trainingsdatensatzes, für die zu trainierenden maschinellen Lernverfahren, eine Verbesserung der Klassifikationsleistung mit sich bringen.

#### Literaturverzeichnis

[Ch23] Chen, Y. et al.: Field-road classification for GNSS recordings of agricultural machinery using pixel-level visual features. *Computers and Electronics in Agriculture*, Vol. 210, 2023.

[Ga21] Gabriel, A. et al.: Nutzung und Hemmnisse digitaler Technologien in der Landwirtschaft. In: *Berichte über Landwirtschaft, Zeitschrift für Agrarpolitik und Landwirtschaft* 99 (1), Hrsg. Bundesministerium für Ernährung und Landwirtschaft, 2021.

[Ge23] Geil, M. et al.: Automatisierte Unterscheidung von Feldarbeit und Straßenfahrt für Landmaschinen mit Hilfe von unüberwachten KI-Methoden, 2023 to appear.

[Gö18] Göggerle, T. (2018): Mit Exatrek-App über Isobus Maschinendaten auslesen. In: *agrarheute*, online verfügbar unter <https://www.agrarheute.com/technik/traktoren/exatrek-app-ueber-isobus-maschinendaten-auslesen-547743>, zuletzt geprüft am 18.10.2023.

[PEN21] Poteko, J.; Eder, D.; Noack, P. O.: Identifying operation modes of agricultural vehicles based on GNSS measurements, In: *Computers and Electronics in Agriculture*, Vol. 185, 2021.

[Ya22] Yang, L. et al.: Identifying Working Trajectories of the Wheat Harvester In-Field Based on K-Means Algorithm, In: *Agriculture*, Vol. 12(11), 2022.



## Exploring explainability formats to aid decision-making in dairy farming systems

### A small case study using the example of mastitis infection

Mengisti Berihu Girmay<sup>1</sup>, Felix Möhrle<sup>1</sup> and Jens Henningsen<sup>2</sup>

**Abstract:** In this paper, we examine different approaches to explaining decision support in herd management systems for their effects on comprehensibility and trust. To this end, we present a hypothetical system for assessing the risk of mastitis, a common infectious disease in dairy cattle. For this system, we design four explanation formats to present risk assessments to farmers. We collect their feedback in a survey to get suggestions for designing systems that are well accepted. In our work, it was not possible to identify one explanation format that is preferable to all others. Rather, a finding was that herd management systems should optimally support multiple explanation formats and allow switching between them depending on the situation.

**Keywords:** explainability, decision support, dairy farming, trust

## 1 Introduction

Dairy farming is an important sector of agriculture dedicated to the rearing and milking of cattle. It has evolved over time from small family farms to large commercial operations. In 2021, Germany held the position of largest EU milk producer with an estimated 31.9 million tons of milk [De23]. However, profit margin is still a big challenge for many dairy farmers, who face unstable prices, high capital investments, regulatory burdens and growing societal demands for greater sustainability and animal welfare.

Digitalization is a promising means for addressing these challenges. Modern systems such as feeding or milking machines enable the automation of formerly manual processes. By collecting and correlating animal data, it is also possible to draw conclusions about animal welfare or susceptibility to disease [Sh20]. However, besides the potential benefits, the introduction of digital systems also brings along new challenges. Their acquisition often involves high costs and training efforts, which can be a burden for small farms with limited resources [AW11]. In addition, trust in new technologies and the perceived loss of control can be barriers [TKT19]. Ultimately, the low adoption rate of many systems, as shown for

---

<sup>1</sup> RPTU Kaiserslautern-Landau, Digital Farming, Erwin-Schrödinger-Str., 67663 Kaiserslautern, mengisti.berihu@rptu.de, felix.moehrle@cs.rptu.de

<sup>2</sup> Fraunhofer-Institut für Experimentelles Software Engineering IESE, Fraunhofer-Platz 1, 67663 Kaiserslautern, jens.henningsen@iese.fraunhofer.de

example by [Ba19], suggests that current systems are not optimally adapted to the needs of farmers.

Many researchers are investigating possible reasons for the low level of adoption, such as a lack of explainability [BRT21], which is also the focus of our work. While recent research in explainability is focused predominantly on AI, many features of herd management systems rely on traditional programming methods. For this reason, we widen the definition to include any form of decision support offered by digital systems. We borrow from the following definitions:

- The process of generating a description of how an outcome was reached [Br21]
- The degree to which a human observer can understand the reason behind a decision [DTG18]

In short, the term implies that results or suggestions are not presented in isolation, but with additional reasoning that makes it easier to understand the underlying rationale.

The aim of this work is to contribute to improving user acceptance of herd management systems. To this end, we examine (1) how explainability influences comprehensibility and trust and (2) how well different explanation formats are accepted by farmers.

## 2 Methodology

We introduce a hypothetical herd management system for the detection of mastitis. Mastitis is a commonly encountered infectious disease among dairy cattle and is a leading cause for the administration of antimicrobial agents [Mi12]. Signs of infection include an increased number of somatic cells in the milk, increased body temperature, and a change in the pH value of the milk. In designing the hypothetical system, we assume that the dairy farms in question are equipped with milking machines that record these parameters during the milking process. The system presents assessments of mastitis infection based on these parameters in four different explanation formats that we will introduce in the following.

### 2.1 Explanation Formats

When designing the hypothetical herd management system, we followed the classification of Valone et al. [VL21]. The authors classify techniques from the field of explainable AI (XAI), among others, by their scope (local, global) and their output format (numerical, rule-based, textual, visual). Although our hypothetical system is not necessarily based on AI, we found this classification useful in selecting potential explanation formats and corresponding representations. We adopted the classes textual (F1), rule-based (F2), global (F3), and local (F4) that can be readily applied to our use case. The global class (F3) refers to explanations involving multiple animals in the herd, while the local class (F4) concerns only a single animal. We did not explicitly include the classes numerical

and visual, since all explanation formats include numbers and visualizations in some form. In designing the explanation formats, we examined existing herd management systems to get a realistic picture of how systems currently present assessments. For each adopted class, we designed an exemplary representation of the evaluation of mastitis infection.

## 2.2 Data Collection and Analysis

We presented the explanation formats to dairy farmers in an online survey which was completed by 14 participants. Participants were asked to rate with a 5-point Likert scale:

1. How comprehensible they consider each format to be
2. How much they would trust a system using each format

Furthermore, the participants were asked:

3. Which of the four alternative formats they ultimately prefer (single choice)
4. What the rationale for their choice is (free text input)

## 3 Survey: Explaining Mastitis Risk in Dairy Farming

The four explanation formats are presented in Figure 1. The textual format (F1) provides the user with explanations based on natural language. The rule-based format (F2) evaluates and highlights three conditions. The herd comparison (F3) relates the values of multiple cows. The time series (F4) shows the values of a single animal over time.

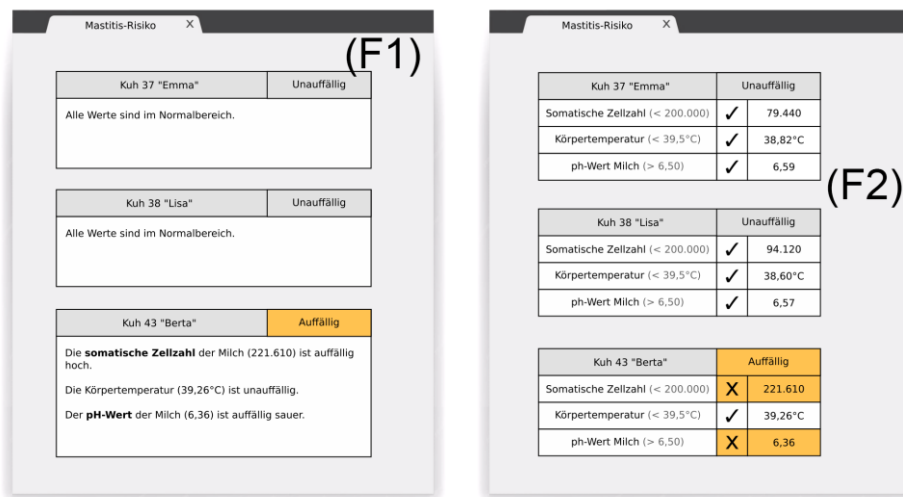




Fig. 1: Formats: textual (F1), rule-based (F2), herd comparison (F3), time series (F4)

## 4 Results

### 4.1 Quantitative Analysis

The numerical results are shown in Table 1. It contains the ratings (1: low, 5: high) for comprehensibility and trust, and the number of farmers favoring each format.

|                      | Comprehensibility           | Trust                       | Favored |
|----------------------|-----------------------------|-----------------------------|---------|
| (F1) Textual         | 5,2,4,1,5,5,3,1,1,5,5,5,5,3 | 4,1,5,4,5,4,3,5,2,4,5,3,3,3 | 1       |
| (F2) Rule-based      | 5,5,5,1,5,5,4,1,1,2,5,5,5,5 | 4,5,5,2,5,4,3,2,1,2,4,4,3,5 | 5       |
| (F3) Herd comparison | 4,5,4,1,5,4,5,1,2,3,5,5,5,3 | 3,5,5,1,5,4,4,1,1,2,5,4,3,2 | 2       |
| (F4) Time series     | 5,5,4,1,5,4,5,1,1,5,5,5,1,3 | 3,5,5,1,5,4,4,1,1,2,2,4,2,2 | 6       |

Tab. 1: Survey results (N=14)

We calculated the median, minimum, maximum, and the first and third quartile for each format for both comprehensibility and trust. The results are illustrated in Figure 2.




Fig. 2: Quantitative analysis results for comprehensibility (left) and trust (right)

The results did not reveal any clear differences regarding comprehensibility. Farmers trusted the textual (F1) and rule-based (F2) formats slightly more, while the time series (F4) received the lowest trust. Ratings varied widely with each format receiving both the lowest (1) and the highest (5) rating at least once. The time series (F4) was the most frequently favored format with 6 votes, followed by the rule-based format (F2) with 5 votes. The herd comparison (F3) and the textual format (F1) received 2 and 1 vote, respectively. Overall, no format emerged as generally superior and opinions varied widely.

## 4.2 Qualitative Analysis

The text feedback is summarized in Table 2. The textual format (F1) was found to be inferior to the more expressive time series (F4) by one farmer. The rule-based format (F2) was generally rated as clear and self-explanatory. The herd comparison (F3) was valued for its efficient and time-saving overview of affected animals in large herds, although one farmer found F3 unclear. The time series (F4) was valued for showing all relevant information such as changes in individual animals over time, facilitating decision making, and providing insight into potential treatments. Some farmers added that combining F3 and F4 is beneficial to enable comparisons between animals with a historical perspective.

| Textual (F1)   | Rule-based (F2)  |
|--|--|
| - Unnecessary as F4 contains all information and more (1)  | + Shows problems most clearly (4)<br>+ Easy to understand and self-explanatory (1)<br>- Not clear (1)  |
| Herd comparison (F3)   | Time series (F4)   |
| + Shows at a glance which animals are affected (2)<br>+ Useful as each herd is unique (2)<br>+ Complements well with F4 (2)<br>- Not clear (1) | + Changes in an individual animal are most relevant for decision making (5)<br>+ Useful as each animal is unique (1)<br>+ Shows relevant information at a glance (1)<br>+ Complements well with F3 (2) |

Tab. 2: Statements from the text feedback (with the number of occurrences)

In summary, all formats (except F1) were considered useful at least once in the text feedback. The results do not suggest that any explanation format is generally superior to all others. Some farmers recommended a combination of F3 and F4.

## 5 Conclusion

Our work examined how different explanation formats in a hypothetical herd management system are perceived by farmers. The findings suggest that perceptions are very subjective. Even in our small test group, responses varied widely, and no format stood out significantly. It is conceivable that a larger sample group could help reveal tendencies. The time series (F4) was rated by many farmers as helpful for decision-making and

treatment selection. The herd comparison (F3) was appreciated for its concise overview. A good user interface could therefore combine both and allow switching depending on the situation. The participants saw value in all four formats. A conclusion for promoting user acceptance is that herd management systems should ideally support multiple explanation formats. Our study did not allow us to identify a format that is superior to all others.

**Acknowledgements:** The research was conducted within the scope of Sustainable Embedded AI and funded by Carl Zeiss.

### Bibliography

- [AW11] Allen, J.; Wolfert, J.: Farming for the Future: towards better information-based decision-making and communication-Phase I: Australasian stocktake of Farm management tools used by farmers and rural professionals. AgFirst Consultancy/Wageningen University and Research Centre, Palmerston North, 2011.
- [Ba19] Barnes, A. P. et al.: Exploring the adoption of precision agricultural technologies: A cross regional study of EU farmers. *Land use policy* 80, S. 163-174, 2019.
- [Br21] Broniatowski, David A. et al.: Psychological foundations of explainability and interpretability in artificial intelligence. NIST, Tech. Rep, 2021.
- [BRT21] Ben David, D.; Resheff, Y. S.; Tron, T.: Explainable AI and adoption of financial algorithmic advisors: an experimental study: Proceedings of the 2021 AAAI/ACM Conference on AI, Ethics, and Society, S. 390–400, 2021.
- [DE23] Deutschland EU-weit größter Kuhmilcherzeuger, Statistisches Bundesamt, <https://www.destatis.de/Europa/DE/Thema/Land-Forstwirtschaft-Fischerei/Milchquote.html>, last accessed: 13.07.2023.
- [DTG18] Dam, H. K.; Tran, T.; Ghose, A.: Explainable software analytics: Proceedings of the 40th int. conf. on software engineering: New ideas and Emerging results, S. 53-56, 2018.
- [Mi12] Minst, K. et al.: Streptococcus species isolated from mastitis milk samples in Germany and their resistance to antimicrobial agents. *Journal of dairy science* 95(12), S. 6957-6962, 2012.
- [Sh20] Sharma, A. et al.: Machine learning applications for precision agriculture: A comprehensive review. In: *IEEE Access* 9, S. 4843-4873, 2020.
- [TKT19] Tummers, J.; Kassahun, A.; Tekinerdogan, B.: Obstacles and features of Farm Management Information Systems: A systematic literature review. *Computers and electronics in agriculture* 157, S. 189-204, 2019.
- [VL21] Vilone, G.; Longo, L.: Classification of explainable artificial intelligence methods through their output formats. *Machine Learning and Knowledge Extraction*, 3(3), S. 615-661, 2021.

## Möglichkeiten der Analyse und Interpretation der visuellen Darstellung von Tierpositionen im Zeitverlauf

Sven Götz<sup>1</sup>, Alexander Kühnemund<sup>2</sup> und Johannes Schmidt-Mosig<sup>1</sup>

**Abstract:** Die Darstellung von Tierpositionen über die Zeit als Heatmaps ermöglicht Einblicke in das Verhalten der Tiere sowie über die Funktionalität der Technik und des Klimas im Stall. Heatmaps meint hierbei die Darstellung der Tierpositionen als farbige Karten. Laut Tierschutznutztierverordnung müssen Tierhalter das Wohlbefinden ihrer Tiere täglich überwachen. Diese Tierkontrolle basiert jedoch auf Momentaufnahmen des Stalldurchganges und spiegelt nicht das „normale“ Tierverhalten wider, da die Anwesenheit des Menschen das Verhalten beeinflusst. Die beschriebene Technik macht sich KI und Überwachungskameras zunutze, um die Positionen von Schweinen zu erfassen und in Form von Tierverteilungskarten zu visualisieren. Diese Darstellung ermöglicht es dem Tierhalter, viele Informationen in vereinfachter Form aufzunehmen und zu analysieren. Durch die frühzeitige Erkennung von Missständen bietet dies den Tierhaltern ein wichtiges Werkzeug zur Verbesserung des Tierwohls. Daher sind Heatmaps ein nützliches Tool, um Verhalten schnell und vereinfacht sichtbar zu machen. Jedoch sind sie oftmals nicht selbsterklärend und benötigen zur korrekten Interpretation fachliche Expertise.

**Keywords:** Tierverhalten, Schwein, Tierwohl, Tiergesundheit, KI, Kameras

### 1 Einleitung

Tierhalter und mit der Aufsicht vertraute Personen sind gesetzlich verpflichtet, mindestens einmal am Tag Kontrollen in ihren Ställen durchzuführen. Diese Kontrolle ist in der Tierschutznutztierverordnung im ersten Abschnitt Paragraph 4 geregelt [TN06]. Für diese Arbeiten hat der Tierhalter im Schnitt 0,32 – 0,7 Stunden je Mastplatz und Mastdurchgang Zeit, um in der Schweinemast wirtschaftlich arbeiten zu können [RVE22]. Das bedeutet, bei einer durchschnittlichen Mastdauer von 111 Tagen bleiben circa 0,00360 Stunden/Tier und Tag (~ 30 Sekunden).

Viele Informationen gehen aufgrund der begrenzten Beobachtungszeit und der Störung des natürlichen Verhaltens durch den Beobachter verloren [A174; Sc50]. Dies führt zu einem verfälschten Bild der tatsächlichen Ist-Situation im Stall. Infolgedessen können Landwirte erst reagieren, wenn Probleme in Form von Erkrankungen oder technischen Defekten in sehr ausgeprägter Form in Erscheinung treten, sprich, sie schon längere Zeit

---

<sup>1</sup>VetVise GmbH, Bünteweg 2, 30559 Hannover; sven.goetz@vetvise.com, johannes.schmidt-mosig@vetvise.com

<sup>2</sup>Hochschule Osnabrück, Fachgebiet Landwirtschaftliche Betriebswirtschaftslehre, Am Krümpel 31, 49090 Osnabrück, alexander.kuehнемund@hs-osnabrueck.de

wirken konnten. Beispiele aus der Praxis wären hierfür festliegende oder verendete Tiere, die beim Betreten des Stalles nicht mehr aufstehen oder sich bewegen.

Um diesen Herausforderungen zu begegnen, greifen Landwirte auf moderne Managementunterstützungen zurück, darunter auch künstliche Intelligenz und hochauflösende Kameras [DG23; DL21; NA19; Ri20; TO23; YX20]. Diese Hilfsmittel ermöglichen es, tierbezogene Daten wie Tierbewegungen, Verhaltensweisen und Leistungsdaten umfassend aufzunehmen und aus- bzw. zu bewerten. Die Ergebnisse werden in vereinfachter und konzentrierter Form ausgegeben und helfen dem Tierhalter bei seiner täglichen Arbeit, indem sie den Arbeitskräfteeinsatz fokussieren und lenken helfen. Eine mögliche Form der vereinfachten Darstellung von komplexen Informationen sind die sogenannten Heatmaps. Diese Darstellungsform wird verwendet, um Muster und Unterschiede in großen Datensätzen zu visualisieren. Sie basiert auf einer farbcodierten Matrix, wobei verschiedene Farben oder Schattierungen unterschiedliche Werte oder Intensitäten repräsentieren.

In der Ethologie ist es gängige Praxis, Präferenzen oder Abneigungen durch sogenannte Wahlversuche zu bestimmen. Dies geschieht unter der Annahme, dass Tiere bei quasi freier Wahl ihrer Verhaltensweisen immer das Verhalten wählen, das zu ihrem aktuellen Zustand am besten passt. Ähnlich ist es mit ihrem Verhalten innerhalb der Stallumgebung [FM97; KP06]. Schweine unterteilen ihre Bucht in sogenannte Funktionsbereiche [Ri89; ZG84]. So gibt es neben dem Fress-/Trinkplatz häufig einen Schlafbereich sowie eine Kotecke. Während der Schlafbereich häufig von vielen Tieren aufgesucht wird, ist die Kotecke unter normalen Umständen ein eher gemiedener Bereich. Diese Verhaltensweisen erlauben es einem Beobachter, bei ausreichend Zeit wichtige Informationen aus dem Tierverhalten abzuleiten. Die Auslastung von Futterplätzen und Wassertränken lässt zum Beispiel Rückschlüsse auf die Funktionalität der technischen Einrichtungen zu. Änderungen in der zuvor präferierten Ruhezone können hingegen ein Hinweis auf sich ändernde klimatische Bedingungen sein oder eine Krankheit ankündigen.

Deshalb sollen in dieser Arbeit die Möglichkeiten der Analyse und Interpretation der visuellen Darstellung von Tierpositionen im Zeitverlauf anhand von Beispielen aus Praxisbetrieben dargestellt werden. Zudem soll eine solche Visualisierung in Form von Heatmaps als Managementtool in der Schweinehaltung diskutiert werden.

## **2 Material und Methoden**

Zur Erstellung der Heatmaps wurden Kameras des Typs DS-2CD2046G2-IU (Hikvision, Hangzhou, Zhejiang, China) und das VetVise-Server-System sowie die firmeneigene VetVise-Software (VetVise GmbH, Hannover, Deutschland) genutzt. Die Kameras werden über den Köpfen der Tiere in senkrechter Ausrichtung zum Boden aufgehängt, um somit den gesamten zu beobachtenden Bereich abdecken zu können.



Die Tierposition wurde während der Beobachtungszeit durch das VetVise-System ermittelt. Diese Softwarelösung nutzt ein Objekttrackingverfahren, um Schweine auf den Kamerabildern zu detektieren. Neben der Position innerhalb des Kamerabildes wird noch zwischen verschiedenen Körperhaltungen (Liegen, Sitzen, Stehen) unterschieden, was genauere Analysen der Buchtenausnutzung zulässt. Die Positionsdaten werden in einem weiteren Schritt in einer Datenbank abgelegt und weiterverarbeitet. Dazu werden sie in Cluster gruppiert und die Häufigkeit des Auftretens einer Position innerhalb des Clusters bestimmt. Diese Summe der Häufigkeiten an erkannten Tieren pro „Positionscluster“ wird danach anhand einer logarithmischen Farbskala auf ein hexagonförmiges Raster übertragen, der sogenannten „Heatmap“. Dies führt dazu, dass Bereiche, die häufiger von Tieren frequentiert wurden, in einer rötlichen Farbe dargestellt werden, und Bereiche mit wenig Erkennungen erscheinen in bläulicher Einfärbung. Die folgende Darstellung (Abb. 1) zeigt den Vorgang in stark vereinfachter Form. Zur Erstellung der eigentlichen Tierverteilungskarte (Heatmap) wird zusätzlich noch ein Zeitraum angegeben, aus dem die Summe aus Positionsdaten aggregiert wird. Dies erlaubt Veränderungen im Tierverhalten in einem Zeitverlauf darzustellen zu können.



Abb. 1: Schematische Darstellung der Erstellung der Heatmap

Die Interpretation der Tierverteilungskarte erfolgt dann in mehreren Schritten. Grundannahme ist, dass Tiere sich freiwillig den Platz aussuchen, der ihren Bedürfnissen am ehesten entspricht. Die Beurteilung der Tierverteilung erfolgt entlang der baulichen Buchtenstrukturierung. So wird die Nutzung der Liegefläche kontrolliert, welche als definierter rot eingefärbter Bereich auf der Karte erscheinen sollte. Die Fress- und Tränkeeinrichtungen sollten mit einem deutlich sichtbaren roten Kranz umrandet sein, da Tiere dort regelmäßig vor Ort sind und vom System detektiert werden. Der Kotbereich hingegen sollte sich als bläulicher Bereich abzeichnen, da sich die Tiere hier nur kurz und vereinzelt aufhalten. Kommt es zu Verschiebungen oder Wegbleiben der erwarteten Einfärbungen, ist dies ein Indiz, dass hier eine genauere Betrachtung der Bucht erfolgen muss. Auch ist die Verteilung der Tiere innerhalb der Bucht ein wichtiger Indikator. Das Klima innerhalb der Bucht beeinflusst maßgeblich die Verteilung der Schweine. Eine Verteilung entlang der Buchtenwände oder vermehrtes Liegen im Kotbereich sind häufig ein Indiz für zu hohe Temperaturen. Eine Häufung in einer Ecke der Bucht kann wiederum ein Indiz für Haufenlage der Schweine sein und somit auf eine zu kalte Stallumgebung oder Zugluft hinweisen [ZG84].

### 3 Ergebnisse

Das untenstehende Bild (Abb. 2.) zeigt exemplarisch ein Aufzuchtabelteil aus der Schweinehaltung. Das Bild entstand durch eine Aufsummierung der Positionsdaten über 24 Stunden mit allen erkannten Körperpositionen.




Abb. 2: Tierverteilungskarte (l.) (1. a, b Futter- und Tränkebereich, 2. Liegefläche, 3. a, b Randbereich, 4. Kotbereich) und Live-Bild (r.) aus diesem Zeitraum

Die Betrachtung der Tierverteilungskarte (l.) gibt dem Betrachter verschiedene Informationen und zeigt mehrere Probleme in dieser Bucht auf. Die erste wichtige Aussage ist die Nutzung der Tröge und Tränkeeinrichtungen (1. a, b). Diese zeichnen sich deutlich durch die roten „Halbkreise“ um den Trog und die Tränke vom Rest ab, da sich hier immer wieder vermehrt Tiere aufhalten und vom System erkannt werden. Bei weiterer Betrachtung fällt die „grünliche“ Fläche (2.) in der Mitte der Bucht auf. Dieses als Ruhebereich bzw. Liegefläche angedachte planbefestigte Areal wird von den Schweinen eher gemieden. Die einzelnen roten Flecken entstehen durch Tiere, die sich dennoch auf der Fläche niederlegen oder zum Koten darauf stehen (r.). Die Schweine liegen über den Tag verteilt vermehrt im Randbereich (3. a, b), im hinteren Bereich (4.) der baulichen Kotecke, oder zwischen den Trögen (1. a, b). Erkennbar ist ebenfalls, dass sich die Tiere entlang der Buchtenwand verteilen.

Abbildung 3 zeigt eine weitere Tierverteilungskarte mit optimalen klimatischen Bedingungen. Die Schweine nutzen Tränke und Futtertröge (1.) und liegen als Gruppe im spaltenreduzierten Bereich (2.). Der Kotbereich im hinteren Teil (4.) wird gemieden und ist klar abgegrenzt. Kein Schwein liegt deutlich an die Wand angelehnt (3.).




Abb. 3: Beispiel einer „guten“ Tierverteilungskarte (1. Futter- und Tränkebereich, 2. Liegefläche, 3. Randbereich, 4. Kotbereich) mit Live-Bild Overlay

#### 4 Diskussion und Fazit

Die Betrachtung der Tierverteilungskarte zeigt, dass sie die Möglichkeit bietet, komplexe Sachverhalte in vereinfachter und konzentrierter Form darzustellen. Sie bietet dem Landwirt einen Überblick und erlaubt Aussagen zum Tierwohl, den technischen Einrichtungen im Stall sowie den klimatischen Gegebenheiten. Abbildungen 2 und 3 zeigen dies als Positiv- und Negativbeispiel. Anhand der beiden Karten können Aussagen zum Klima innerhalb des Stalles gemacht werden. So wäre im Fall von Abbildung 2 die Temperatur innerhalb des Stalles zu senken, da die Tiere im Randbereich und der Kotecke liegen. Abbildung 3 zeigt eine gute Tierverteilung und macht kein Eingreifen erforderlich [HMS04; ZG84]. Die Aussage zur Nutzung der Tränke und Fütterung ist ebenfalls ein wichtiger Indikator zum Tierwohl [TN06]. Jedoch muss dabei beachtet werden, dass bei einer Betrachtung über 24 Stunden die Technik zwischenzeitlich ausfallen könnte und der Kranz um die Fütterung wäre immer noch sichtbar. Sie lässt in dieser Form keine quantitativen Aussagen zur Ausnutzung zu. Auch wäre es möglich, dass nur einzelne Tiere diese Bereiche stark frequentieren und andere Tiere diesen Bereich nicht nutzen können. Dies macht eine Inaugenscheinnahme des Tierbestandes durch den Landwirt unabdingbar. Ein weiterer Nachteil ist, dass Heatmaps immer nur retrospektivische Aussagen zulassen, da die Erstellung der Positionsdaten Zeit benötigt. Jedoch erlauben sie Aussagen zu Ereignissen, welche nur durch längere Beobachtungszeiträume erkennbar wären, wie z. B. die Nutzung der Buchtenstruktur.

Untersuchungen im Bereich der Datenvisualisierung und der Nutzerakzeptanz haben gezeigt, dass eine einfache Darstellung einer komplexen vorzuziehen ist und den Nutzen beim Benutzer erhöht [He17]. Mithilfe dieser Untersuchung zeigt sich eine weitere Möglichkeit, vereinfacht Informationen für Landwirte bereitzustellen und so in der Tierhaltung unterstützend zu wirken. Heatmaps können somit Landwirten dabei helfen, fundierte Entscheidungen zur Verbesserung des Tierwohls und der Effizienz ihrer Betriebe zu treffen.

## Literaturverzeichnis

- [Al74] Altmann, J.: Observational study of behavior: Sampling methods. *Behaviour* 49, 227–267, 1974.
- [FM97] Fraser, D., Matthews, L.R.: Preference and motivation testing, M.C. Appleby & B.O. Hughes (Eds.) *Animal Welfare*, 159-173, 1997.
- [He17] Van Hertem, T. et al.: Appropriate data visualisation is key to Precision Livestock Farming acceptance, *Computers and Electronics in Agriculture*, Volume 138, 1-10, 2017.
- [HMS04] Hillmann, E., Mayer, C., Schrader, L.: Lying behaviour and adrenocortical response as indicators of the thermal tolerance of pigs of different weights. *Animal Welfare*, 13(3), 329-335, 2004.
- [KP06] Kirkden, R. D., Pajor, E. A.: Using preference, motivation and aversion tests to ask scientific questions about animals' feelings. *Applied Animal Behaviour Science*, Volume 100, 29-47, 2006.
- [MW91] Mollet, P., Wechsler, B.: Auslösende Reize für das Koten und Harnen bei Hausschweinen. *Akt. Arb. z. artgem. Tierhltg., KTBL 344*, Darmstadt, 150-161, 1991.
- [Na19] Nasirahmadi, A. et al.: Automatic scoring of lateral and sternal lying posture in grouped pigs using image processing and Support Vector Machine. *Comput. Electron. Agric.*, 156, 475–481, 2019.
- [Ri20] Riekert, M. et al.: Automatically detecting pig position and posture by 2D camera imaging and deep learning, *Comput. Electron. Agric.*, 174, 2020.
- [Ri89] Rist, M.: *Artgemäße Nutztierhaltung*, Forschungsring für Biologisch-Dynamische Wirtschaftsweise e.V. Freies Geistesleben, Stuttgart, 1989.
- [RVE22] Rohlmann C., Verhaagh M., Efken J.: *Steckbriefe zur Tierhaltung in Deutschland: Ferkelerzeugung und Schweinemast*, 17.p, Thünen-Institut für Betriebswirtschaft, Braunschweig, 2022.
- [Sc50] Schneirla, T.C.: The relationship between observation and experimentation in the field study of behavior. *Ann. N. Y. Acad. Sci.* 51, 1022–1044, 1950.
- [TO23] top agrar online, <https://www.topagrar.com/perspektiven/news/technik-fuer-tierwohl-13490977.html>, Stand: 17.10.2023.
- [TN06] *Tierschutz-Nutztierhaltungsverordnung*; <https://www.gesetze-im-internet.de/tierschnutztv/TierSchNutzTV.pdf>, Stand: 16.10.2023.
- [YX20] Yang, Q.; Xiao, D.: A review of video-based pig behavior recognition, *Appl. Anim. Behav. Sci.*, 233, 105-146, 2020.
- [ZG84] von Zerboni, H.N., Grauvogl, A.: *Verhalten landwirtschaftlicher Nutztiere*. Ulmer, Stuttgart, 246-297, 1984.

## Adaptive Mesh-Netzwerke zur Steigerung der Konnektivität von Landmaschinen

Julian Hager<sup>1</sup>, Benjamin Striller<sup>1</sup>, Tobias Földner<sup>1</sup>, Andreas Hecker<sup>2</sup>,  
Bernd Turkowski<sup>2</sup>, Jennifer Schwardt<sup>3</sup>, Thomas Herlitzius<sup>1</sup> und Gerhard Fettweis<sup>2</sup>

**Abstract:** Die Versorgung landwirtschaftlicher Regionen und Flächen mit öffentlichem Mobilfunk ist nach wie vor unzulänglich und bremst den Einsatz digitaler Werkzeuge in der landwirtschaftlichen Produktion. Private, nomadische Campusnetze bieten einen Lösungsansatz, der durch zusätzlichen Einsatz von Ad-hoc-Netzen eine vollumfängliche praktische Nutzung ermöglicht. Im Beitrag wird die Möglichkeit, die Reichweite über ein WiFi-basiertes Mesh-Netzwerk zu vergrößern und als Folge dessen die Konnektivität von Maschinen zu erweitern, vorgestellt. Basierend auf vorbereitenden Messungen zu unterschiedlichen Netzparametern wurden Feldversuche konzipiert, Hardware auf Landmaschinen integriert und Daten erhoben. Die Auswertung der aufgezeichneten Daten gibt Aufschluss über die Eignung vermaschter Netzwerke in der landwirtschaftlichen Praxis.

**Keywords:** Mesh-Netzwerke, Ad-hoc-Netzwerke

### 1 Einleitung

Die Grundlage für digitale Anwendungen in der Landwirtschaft stellt der automatisierte Informationsaustausch zwischen verschiedenen Geräten dar. Dabei sind sowohl die Kommunikation „Machine-to-Machine“ (M2M) als auch der Austausch mit Management- und Informationssystemen, die dem Anwender zugänglich sind, von hoher Relevanz für den Erfolg entsprechender digitaler Lösungen [KMS21]. Dafür ist eine Verfügbarkeit von drahtlosen Kommunikationswegen elementar. Die mangelnde Versorgung in ländlichen Regionen durch öffentliche Mobilfunknetze ist dabei ein Hindernis für die Digitalisierung. Die Vor-Ort-Errichtung lokaler privater Mobilfunkstrukturen in Form von beweglichen Ad-hoc-Campusnetzwerken stellt einen Lösungsansatz dar, welcher beispielsweise im Rahmen des Projekts „LANDNETZ“ realisiert wurde [HSF22]. Die dabei verwendeten privaten 5G-Mobilfunksysteme in Verbindung mit lokalen Edge-Clouds bieten große Vorteile in Bezug auf Latenz, Geräteanzahl und Verbindungsqualität. Für sich allein sind sie allerdings in ihrer räumlichen Ausdehnung auf wenige Kilometer begrenzt.

---

<sup>1</sup> Technische Universität Dresden, Professur für Agrarsystemtechnik, Bergstraße 120, 01069 Dresden, agrarsystemtechnik@tu-dresden.de

<sup>2</sup> Technische Universität Dresden, Vodafone Stiftungslehrstuhl Mobile Nachrichtensysteme, 01062 Dresden, mcs@ifn.et.tu-dresden.de

<sup>3</sup> Meshmerize GmbH, August-Bebel-Straße 23, 01219 Dresden, jennifer.schwardt@meshmerize.net

Für die Kommunikation zwischen landwirtschaftlichen Maschinen auf dem Feld ist auch eine dezentrale Kommunikationsstruktur unter Nutzung von WiFi-Funkverbindungen denkbar [La23]. Dabei können Kommunikationswege nicht nur durch direkte Verbindungen, sondern auch in Form von vermaschten Netzwerken („Mesh-Netzwerken“) hergestellt werden. Die Firma Meshmerize GmbH hat eine Technologie entwickelt, welche die Anwendung meshbasierter WiFi-Netzwerke auf bewegten, mobilen Arbeitsmaschinen erlaubt. Nachdem diese Technik bereits auf Drohnen [Pa19] und kleineren autonomen Robotern [BM22] erprobt wurde, soll nun eine Nutzung auf landwirtschaftlichen Fahrzeugen geprüft und der Einsatz in der Landwirtschaft evaluiert werden. Die Einbindung der adaptiven Mesh-Netzwerke in ein 5G-Campusnetz verbindet schließlich die Landmaschinen mit zentralen Management- und Informationssystemen.

## **2 Material und Methoden**

### **2.1 Funktionsweise adaptiver Mesh-Netzwerke**

Die Kommunikation mittels WiFi-basierten Funkverbindungen (IEEE 802.11) bietet vielfältige Möglichkeiten zur Vernetzung von Maschinen. Von besonderer Relevanz sind dabei „Ad-Hoc“-Verbindungen, welche ohne verwaltende Infrastruktur direkt zwischen Geräten hergestellt werden können. Die Verbindungen können dabei zu mehreren Geräten gleichzeitig aufgenommen werden, sodass in Folge ein vermaschtes, kabelloses Netzwerk zur Verfügung steht. Die dabei entstehenden, verzweigten Routen zwischen den Geräten können nun durch Routing-Algorithmen ausgewählt werden, um die Übertragungseigenschaften zu optimieren. Während klassische Routingprotokolle hauptsächlich die Ermittlung eines einzelnen, optimalen Pfads zum Ziel haben, werden durch die Technologie der Firma Meshmerize mehrere verfügbare Routen vorgehalten und hinsichtlich ihrer Übertragungseigenschaften bewertet. Dies bietet Vorteile hinsichtlich der Robustheit der Verbindungen, beispielsweise gegenüber Signalschwankungen, Verbindungsabbrüchen und sich ändernden Mesh-Teilnehmern [PWF18]. Gerade in Bezug auf bewegte Maschinen, die landwirtschaftlichen Prozessen inhärent sind, kann eine solche adaptive und dynamische Konfiguration des kabellosen Netzwerks Vorteile bieten.

Da die Reichweite direkter WiFi-Verbindungen auch im Optimalfall nur einige hundert Meter beträgt, sind solche Systeme besonders für Prozesse relevant, bei denen Landmaschinen in näherer Umgebung (kooperative) Feldarbeiten verrichten und Informationen ausgetauscht werden sollen. Im Folgenden ist beispielhaft die mögliche Anwendung eines adaptiven, meshbasierten Netzwerkes in der Häckselkette bei der Maiseernte dargestellt (Abb. 1).

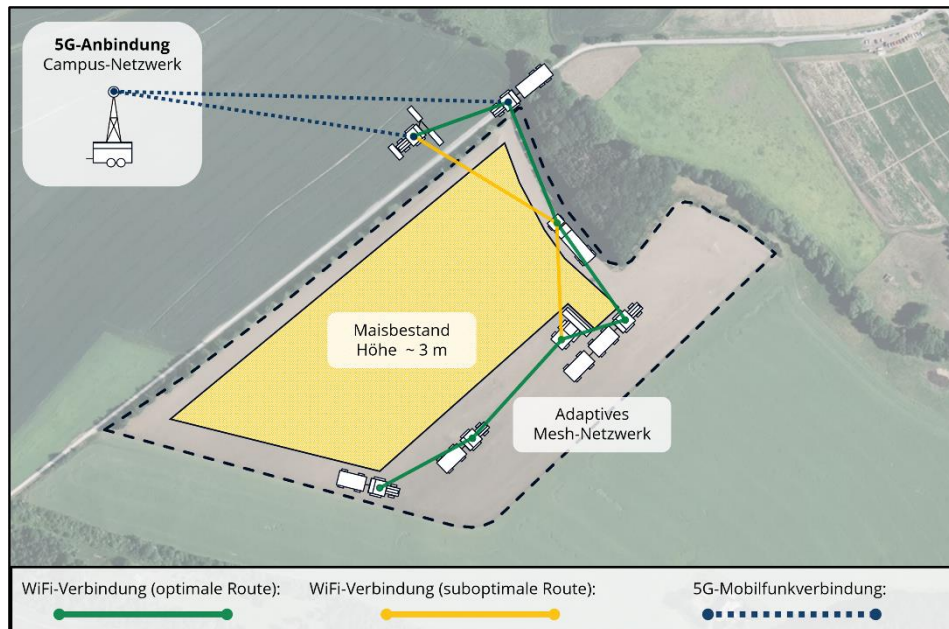


Abb. 1: Einsatz adaptiver Mesh-Netzwerke in der Häckselkette bei der Maisernte

Die dynamische Auswahl der besten Verbindungspfade bietet dabei die Möglichkeit, Hindernisse oder anderweitige Signalstörungen zu umgehen. Die Verkettung erlaubt zudem die Übertragung von Daten zwischen Maschinen, die keine direkte Funkverbindung haben. So ist beispielsweise selbst dann der Austausch von Daten mit mobilfunkbasierten Campusnetzen denkbar, wenn nur einige der Maschinen des Mesh-Netzes das Mobilfunksignal empfangen können.

## 2.2 Versuchsaufbau zur Erprobung in der landwirtschaftlichen Praxis

Die Anwendbarkeit der Technologie und die damit einhergehende Steigerung der Konnektivität in landwirtschaftlichen Prozessen ist zu überprüfen, weshalb Feldversuche geplant und durchgeführt werden. Dabei werden die eingesetzten Landmaschinen in der Kabine mit Versuchsträgern ausgestattet. Diese wasser- und staubgeschützten Einheiten beinhalten WiFi-Router, welche mit Außenantennen auf dem Kabinendach verbunden sind. Die Versuchsträger werden durch das Bordnetz der Fahrzeuge mit Energie versorgt und sind mit der Meshmerize-Software ausgestattet, sodass sie sich automatisch mit den anderen ausgerüsteten Fahrzeugen zu Mesh-Netzwerken verbinden können. Um eine spätere Bewertung der hergestellten Verbindungen durchführen zu können, ist zusätzlich ein Empfänger für satellitengestützte Positionsbestimmung (GNSS) vorgesehen. Auf einen angeschlossenen Datenträger werden damit alle 5 s Datenpunkte gespeichert, welche neben Orts- und Zeitangaben auch detaillierte Informationen über die aufgebauten

Drahtlosverbindungen enthalten. So werden neben Signalstärken auch Metriken hinsichtlich der verfügbaren Modulationsschemata (Modulation Coding Schemes) gesammelt. Zudem sind Daten zu den ausgewählten und genutzten Verbindungen und Routen des Routing-Algorithmus verfügbar.

Um über den Versuchszeitraum von mehreren Wochen jederzeit auf die bisher gespeicherten Verbindungsdaten zugreifen zu können, erfolgt eine Anbindung zu einem mobilen LANDNETZ-Campusnetz-Anhänger. Wird über das Mesh-Netzwerk eine Verbindung zu diesem Trailer hergestellt, beispielsweise am Anfang oder Ende des Arbeitstages, so werden die gesammelten Daten auf einen im Anhänger installierten Edge-Server übertragen. Auf die dort redundant gespeicherten Daten kann dann aus der Ferne per Mobilfunk- oder Satelliteninternetverbindung zugegriffen werden.

### 2.3 Versuchsplanung und -durchführung

Die Feldversuche konzentrierten sich auf Arbeitsprozesse, bei denen eine möglichst große Anzahl an Maschinen innerhalb eines begrenzten Radius arbeitet. Dazu wurden im Herbst 2023 zwei landwirtschaftliche Betriebe in Sachsen nacheinander mit der Mesh-Technik ausgestattet (Tab. 1).

| Versuchsbetrieb | Ort und Zeitraum                | Untersuchte Prozesse                         | Ausgestattete Maschinen (Anzahl) |
|-----------------|---------------------------------|--|----------------------------------|
| Betrieb 1       | Raum Mittelsachsen<br>Okt. 2023 | Häckselkette<br>Maisernte                    | Feldhäcksler (2)                 |
|                 |                                 |  | Standardtraktor (6)              |
|                 |                                 |  | Lastkraftwagen (1)               |
| Betrieb 2       | Raum Meißen<br>Okt. / Nov. 2023 | Häckselkette<br>Grasernte<br>Körnermaisernte | Feldhäcksler (1)                 |
|                 |                                 |  | Mähdrescher (1)                  |
|                 |                                 |  | Standardtraktor (5)              |
|                 |                                 |  | Raupentraktor (1)                |

Tab.1: Übersicht der ausgewählten Versuchsbetriebe

An den Betrieben wurde zudem ein LANDNETZ-Anhänger als zentraler Datenspeicher vor Ort installiert, womit in diesem konkreten Szenario zehn Versuchseinheiten zur Vernetzung genutzt werden konnten. Die Versuche auf Betrieb 2 dauern an (Stand November 2023). Darüber hinaus sind im Frühjahr 2024 weitere Feldversuche in der Gülleausbringung geplant, um auch diesen logistisch anspruchsvollen Prozess abzubilden.

## 3 Auswertung erster Feldversuche

Erste Auswertungen der Daten ergeben ein komplexes Netzwerkverhalten, das sich durch ständige Neu- und Rekonfiguration der Netzwerkteilnehmer auszeichnet. Exemplarisch soll hierbei der Prozess der Häckselkette zur Silomaisernte betrachtet werden.



Der Feldhäcksler tritt dabei über die Arbeitszeit hinweg mit verschiedenen Fahrzeugen in Kontakt, welche das Häckselgut aufnehmen und abtransportieren. Da diese Fahrzeuge ebenfalls mit Mesh-Technologie ausgestattet waren, konnte eine Verbindung hergestellt werden. Die Anzahl und Verteilung der dabei durch den Häcksler erreichbaren Kommunikationspartner ist in Abbildung 2 dargestellt.




Abb. 2: Hergestellte direkt und indirekte Verbindungen eines Feldhäckslers mit Mesh-Technologie

Die betrachteten Daten entsprechen einem Versuchszeitraum von drei Tagen, wobei der Feldhäcksler das Erntegut abwechselnd auf fünf verschiedene Transportgespanne überlud. Erwartungsgemäß zeigt sich hierbei der häufigste Fall von einer einzelnen Kommunikationsverbindung, welche dann dem Fahrzeug entspricht, welches gerade aktiv beladen wurde. Da die Transportstrecken mit ca. 10 km lang waren, gab es zudem Zeitpunkte, an denen der Arbeitsprozess unterbrochen werden musste und die Erntemaschine allein auf dem Feld pausierte. Zu diesen Zeitpunkten waren keine anderen Netzwerkteilnehmer erreichbar. Es ist außerdem zu erkennen, dass die Anzahl der verfügbaren Kommunikationspartner durch den Einsatz der Mesh-Technologie erhöht werden konnte, was durch die Nutzung indirekter Verbindungen im maschenbasierten Netz möglich ist.

#### 4 Diskussion und Ausblick

Es zeigt sich bereits in den ersten Ergebnissen, dass während bestimmter landwirtschaftlicher Prozesse wie der Häckselkette mehrere Kommunikationspartner für die Schlüsselmaschine zur Verfügung standen. Im Folgenden soll betrachtet werden, inwieweit durch adaptive Mesh-Netzwerke diese Anzahl der zur Verfügung stehenden Kommunikationspartner genutzt und somit die mögliche Kommunikationsstrecke erweitert werden kann. Dafür werden während der noch laufenden Messkampagne weitere Daten erhoben.

Für den gesamten Datensatz sind umfassende und detaillierte Auswertungen vorgesehen. Dabei ist auch die quantitative und qualitative Bewertung der hergestellten Verbindungen sowie die Betrachtung der Robustheit des Netzes vorgesehen.

Der Einsatz von adaptiven Mesh-Netzwerken in landwirtschaftlichen Prozessen kann nach erfolgreicher Validierung die Konnektivität der verwendeten Maschinen steigern. Dabei bieten sich besonders hochgradig kooperative Prozesse wie die Arbeit des Feldhäckslers für den Einsatz der Technik an. Gerade bei diesen Vorgängen kann die gesteigerte Kommunikation zwischen den Maschinen die anspruchsvolle Zusammenarbeit, beispielsweise durch Platooning oder ferngesteuerte Assistenzfunktionen, erleichtern.

**Förderhinweis:** Die Untersuchungen zu adaptiven Mesh-Netzwerken sind Bestandteil des Experimentierfelds LANDNETZ. Die Förderung des Vorhabens erfolgt aus Mitteln des Bundesministeriums für Ernährung und Landwirtschaft (BMEL) aufgrund eines Beschlusses des deutschen Bundestages. Die Projektträgerschaft erfolgt über die Bundesanstalt für Landwirtschaft und Ernährung (BLE) im Rahmen der Förderung der Digitalisierung in der Landwirtschaft mit dem Förderkennzeichen 28DE101A18.

#### Literaturverzeichnis

- [BM22] Biggie, H.; McGuire, S.: Heterogeneous Ground-Air Autonomous Vehicle Networking in Austere Environments: Practical Implementation of a Mesh Network in the DARPA Subterranean Challenge. arXiv e-prints, arXiv:2203.12832, 2022.
- [HSF22] Hecker, A.; Striller, B.; Franchi, N.: Private mobile ad hoc communications and the application in LANDNETZ: Land.Technik 2022. The forum for agricultural engineering innovations February 25th 2022. VDI-Verlag GmbH, Düsseldorf, S. 251–258, 2022.
- [KMS21] Kehl, C.; Meyer, R.; Steiger, S.: Digitalisierung der Landwirtschaft: gesellschaftliche Voraussetzungen, Rahmenbedingungen und Effekte. Teil II des Endberichts zum TA-Projekt. Büro für Technikfolgen-Abschätzung beim Deutschen Bundestag (TAB), 2021.
- [La23] Lautenschläger, K.: Suitability of Modern Wi-Fi for Wireless-Infield-Communication of Agricultural Machines. Diploma Thesis (Diplomarbeit), Dresden, 2023, [https://github.com/klautenschlaeger/diploma\\_thesis](https://github.com/klautenschlaeger/diploma_thesis)
- [Pa19] Pandi, S. et al.: MESHMERIZE: An Interactive Demo of Resilient Mesh Networks in Drones: CCNC 2019: 2019 16th IEEE Annual Consumer Communications & Networking Conference (CCNC). 2019 16th IEEE Annual Consumer Communications & Networking Conference (CCNC) took place 11-14 January 2019 in Las Vegas, NV, USA. IEEE, Piscataway, NJ, S. 1–2, 2019.
- [PWF18] Pandi, S.; Wunderlich, S.; Fitzek, F. H. P.: Reliable low latency wireless mesh networks – From Myth to reality: 2018 15th IEEE Annual Consumer Communications & Networking Conference (CCNC). IEEE, Piscataway, NJ, S. 1–2, 2018.

## Bilddatenakquisition zur Entwicklung eines Machine-Learning-Detektors für Grünlandunkräuter

Ingo-Leonard Haußmann<sup>1</sup>, Lukas Petrich<sup>2</sup>, Georg Lohrmann<sup>1</sup>, Volker Schmidt<sup>2</sup> und Albert Stoll<sup>1</sup>

**Abstract:** Giftpflanzen wie die Herbstzeitlose (*Colchicum autumnale*) können sich besonders gut in extensiv bewirtschaftetem Grünland ausbreiten. Gelangen Pflanzenteile in das Erntegut, drohen bei der Aufnahme durch Nutztiere Vergiftungserscheinungen, die zum Tode führen können. Ohne Maßnahmen zur Regulierung werden betroffene Flächen zunehmend unattraktiv und es droht eine Nutzungsaufgabe, einhergehend mit einer naturschutzfachlichen Abwertung. Zur Steuerung eines innovativen Bekämpfungsgertes gegen Grünlandunkräuter wird ein Pflanzendetektor basierend auf einem Machine-Learning-Ansatz entwickelt. Die Methode zur Bilddatensammlung dafür wird in vorliegendem Artikel beschrieben.

**Keywords:** Grünland, Unkrautbekämpfung, Bilddaten, Machine-Learning, Labeln

### 1 Einleitung

Extensives Grünland mit hohem Artenreichtum hat einen besonderen Stellenwert als Habitatfläche für Flora und Fauna. Für den Erhalt ist maßgeblich die Art der Nutzung dieser Flächen entscheidend, die sich durch ein- oder zweimaliges Mähen mit Abfuhr des Schnittgutes und keiner oder nur geringfügiger Düngung auszeichnet. Neben der damit erreichbaren Aufrechterhaltung der Artenzusammensetzung des Grünlandbestandes können sich aber neben den erwünschten Arten auch Giftpflanzen, wie die Herbstzeitlose (*Colchicum autumnale*), etablieren. Da zum Zeitpunkt des ersten Schnitttermins die Frühjahrsentwicklung der Herbstzeitlose bereits abgeschlossen ist, wird sie durch den späten Nutzungstermin nicht in Mitleidenschaft gezogen [WPK11]. Gelangen Pflanzenteile in das Erntegut, drohen bei der Aufnahme durch Nutztiere Vergiftungserscheinungen, die zum Tode führen können, denn auch die Futterkonservierung sorgt nicht für eine Abnahme der Toxizität [Br00]. Damit ist nicht nur die landwirtschaftliche Verwendung des Schnittgutes wesentlich eingeschränkt, sondern auch die aus Sicht des Naturschutzes gewünschte Offenhaltung der Landschaft gefährdet. Zu einer Regulierung der Herbstzeitlosen auf landwirtschaftlich genutztem Grünland wird daher geraten [Gr20]. Effektive Methoden sind das händische Ausreißen der Blätter im Frühjahr oder das

---

<sup>1</sup> Hochschule für Wirtschaft und Umwelt Nürtingen-Geislingen, Institut für Technik, Schelmenwasen 8, 72622 Nürtingen, haussmann@hfwu.de, georg.lohrmann@hfwu.de, albert.stoll@hfwu.de

<sup>2</sup> Universität Ulm, Institut für Stochastik, Helmholtzstr. 18, 89069 Ulm, lukas.petrich@uni-ulm.de, volker.schmidt@uni-ulm.de

Ausmähen einzelner Pflanzen mit dem Freischneider. Ein Einsatz von Herbiziden widerspricht jedoch klar der extensiven Grünlandnutzung im naturschutzfachlichen Sinn und ist auch auf vielen der in Frage kommenden Flächen verboten [HBK22]. Das flächendeckende Mulchen stark befallener Flächen hat sich daher bewährt [SE14] und ist am ökonomischsten, jedoch wiederum schädlich für Insekten [HBK22]. Die Rückdrängung der Herbstzeitlose muss daher unbedingt bei den ersten Anzeichen einer Ausbreitung erfolgen, um großflächige Maßnahmen mit negativen Auswirkungen auf die übrige Vegetation und die Fauna zu vermeiden [ebd.].

Aus diesen Gründen sollte ein innovatives Unkrautbekämpfungsgerät entwickelt werden, welches durch kleinräumig arbeitende Werkzeuge nur dort einwirkt, wo sich eine Zielpflanze befindet. Durch diese selektive Arbeitsweise halten sich die Ernteverluste in Grenzen und die Ernte des Nutzbestandes kann wie gewohnt stattfinden, wohingegen beim Mulchen der bisherige Aufwuchs komplett verloren geht. Die Auswahl geeigneter Werkzeuge mittels Nutzwertanalyse und deren Wirkung wurde in [SLM23] beschrieben. Für die traktorgebundene Anwendung wurde ein 2,5 m breites Prototypgerät mit Wasserstrahltechnik aufgebaut [MLS22]. Das entwickelte Detektionsverfahren zur Ermittlung der Einzelpflanzenstandorte basiert auf drohnengestützten Luftbildaufnahmen. Blühende Herbstzeitlosen können im daraus zusammengefügtten Orthofoto mit einem Machine-Learning-Ansatz detektiert werden. Dabei wurden 89 % aller Giftpflanzen erkannt [Pe20]. Zusätzlich wurde das Detektionsverfahren auch für das Jakobskreuzkraut (*Senecio jacobaea*) entwickelt [PSS21], um das zukünftige Einsatzspektrum zu erweitern.

Da der optimale Zeitraum einer Bekämpfungsmaßnahme, die oberirdische Pflanzenteile von Herbstzeitlosen entfernt, im Frühjahr liegt [SE14], was durch Verfahrensversuche auch bestätigt werden konnte [MLS22; SLM23], ergibt sich ein Zeitversatz zwischen der Pflanzendetektion im Herbst und der Bekämpfungsmaßnahme im folgenden Frühjahr. Zudem wird nicht der Pflanzenteil detektiert, der später behandelt wird, sodass es zu Abweichungen zwischen ermittelter Blütenposition im Herbst und tatsächlichem Austrieb kommen kann. Eine Ausbildung mehrerer zeitversetzt auftretender Blüten pro Knolle erschwert die Terminierung der Drohnenflüge ist nicht unerheblich, da neben Faktoren wie Genehmigungen und Witterung auch Vorarbeiten auf der betroffenen Fläche für die Georeferenzierung der Bildaufnahmen zu berücksichtigen sind. Diese Punkte führten dazu, dass im derzeitigen Verbundprojekt „Selektive Bekämpfung von Grünlandunkräutern mit Wasserstrahlen“ eine Weiterentwicklung des Verfahrens hin zu einer Echtzeit-Pflanzendetektion verfolgt wird. In diesem Artikel wird die Vorgehensweise zur Entwicklung eines solchen Pflanzendetektors näher beschrieben, dabei wird auf die grundsätzlichen Überlegungen eingegangen und insbesondere das Sammeln von Trainingsdaten für den Machine-Learning-Ansatz beschrieben. Diese Daten können darüber hinaus zur Entwicklung eines stochastischen Strukturgenerators dienen, der wiederum die Datengrundlage für einen Machine-Learning-Detektor generieren kann und so den manuellen Aufwand reduziert.

## 2 Material und Methoden

Für den Aufbau einer KI sind viele Samples als Trainingsdaten nötig. Diese müssen unter möglichst ähnlichen Umständen – z. B. hinsichtlich Entwicklungsstadium der Zielpflanze – aufgezeichnet werden, die in der Anwendung vorherrschen. Die verwendete Kameratechnik und deren Anordnung sollte ebenfalls dem späteren Anwendungsfall am Gerät entsprechen, da sonst Nachteile für die Erkennungsleistung zu erwarten sind.

Ein mobiles Trägerfahrzeug basierend auf einer Elektroschubkarre mit stufenlos regelbarem Antrieb wurde dazu entsprechend umgebaut. An einem Rahmengestell aus Aluminiumprofilen wurden zwei Robust-Kameras in einem Abstand von 160 cm zueinander angebracht. Galgenausleger führen die Kameras vorgelagert mit paralleler Ausrichtung der Linse zum Bodenhorizont über den Grünlandbestand, sodass der gesamte Aufnahmebereich keine Teile des Fahrgestells enthält. Diese Anordnung sorgt für eine Überlappung der Sichtbereiche jeder Kamera, um so einer möglichen geringeren Erkennungsleistung im äußeren Bildbereich durch Verzeichnung, hervorgerufen durch die verbaute Optik, entgegenzuwirken. Durch diese Überschneidung besteht die Möglichkeit, dass eine der benachbarten Kameras durch einen vorteilhafteren Blickwinkel die Zielpflanze trotzdem detektiert. Die Stromversorgung der Kameras erfolgt über die Batterien für den Fahrantrieb des Trägerfahrzeuges. Aufgezeichnet werden Videos im RGB-Farbspektrum mit einer FullHD-Auflösung (1920 x 1080 Pixel) bei 11 Einzelbildern pro Sekunde. Die Aufnahme wird für beide Kameras simultan über einen Schalter gestartet und auf einen kamerainternen Speicher geschrieben, dessen Größe für eine Aufnahmedauer von ca. sechs Minuten ausreicht. Die Aufnahmen werden hierbei mit dem MJPEG-Codec [Jo19] codiert, um eine hohe Bildqualität und Ausfallsicherheit zu gewährleisten. Anschließend werden die Videos auf einen Laptop übertragen, um den Speicherplatz für weitere Aufnahmefahrten freizugeben.

Von April bis Mitte Mai erstreckte sich der Zeitraum, indem mit Herbstzeitlosen besetzte Wiesen im Nürtinger Raum aufgenommen wurden. Das Befahren der Wiesen in parallelen Bahnen während der Aufnahme fand tagsüber bei unterschiedlichen Bedeckungsgraden des Himmels statt. Die Fahrgeschwindigkeit betrug dabei entsprechend der Höchstgeschwindigkeit der Elektroschubkarre ca. 4 km/h. Eine wiederholte Aufnahme gleicher Wiesen mit zeitlichem Abstand wurde gewählt, um die veränderte Erscheinungsform der Pflanzen mit fortschreitendem Wachstumsstadium einfangen zu können. Zusätzlich wurde für die Zielpflanze Jakobskreuzkraut ein Aufnahmetermin im Landkreis Göppingen durchgeführt.

Beim sogenannten Labeling werden die Bilddaten anschließend gesichtet und die Zielpflanzen manuell mit einer Bounding Box, d. h. einer rechteckigen Markierung um die Pflanzenregion, versehen. Um die einzelnen Labeling-Aufgaben überschaubar zu halten, werden die aufgezeichneten Videos in etwa 10 Sekunden lange Videoclips zerlegt. Jeder dieser Clips wird mit Metadaten ausgestattet, die insbesondere den SHA-1-Hashwert [Ha11] enthalten, sodass das Ursprungsvideo später eindeutig identifiziert werden kann. Das eigentliche Labeln wird dann mittels LabelStudio [LS], einer Webanwendung, die das

Arbeiten am Webbrowser ermöglicht, durchgeführt. Bevor die Videoclips allerdings hochgeladen werden können, müssen sie in ein webkompatibles Format (H.264 [Jo19]) konvertiert werden. Jedes Vorkommen einer Zielpflanze muss mit einer Bounding Box und der entsprechenden Art des Unkrautes (Herbstzeitlose oder Jakobskreuzkraut) versehen werden. Im Gegensatz zur Bearbeitung von Einzelbildern kommt hier allerdings der Vorteil von Videos zum Tragen: Es müssen nur Labels an ausgewählten Zeitpunkten im Video gesetzt werden. Die Position und Größe der Bounding Boxen für die dazwischen liegenden Zeitpunkte können dann anhand dieser sogenannten Keyframes automatisch interpoliert werden, was den Arbeitsaufwand reduziert.

Nach der Erstellung der Labels werden diese heruntergeladen und basierend auf den Metadaten mit den Ursprungsvideos zusammengeführt. Durch die Verwendung der Ursprungsvideos wird sichergestellt, dass die bestmögliche Bildqualität ohne zusätzliche Kompressionsartefakte verwendet wird. Bevor die einzelnen Frames der Videos mit den zugehörigen Labels extrahiert werden können, muss eine Aufteilung in Trainings-, Validierungs- und Testdatensatz erfolgen. Diese Datensätze werden dafür verwendet, um Vorhersagemodelle zu trainieren und unter allen trainierten Modellen das beste auszuwählen, bzw. dieses dann auf seine Erkennungsleistung hin zu untersuchen. Aufgrund der vorliegenden Datensituation werden alle Ursprungsvideos zufällig einem der drei Datensätze zugeordnet, wobei sich überlappende Videos dem gleichen zugewiesen werden. Alle extrahierten Einzelbilder dieser Videos mit den zugehörigen Labels bilden dann die jeweiligen Datensätze. Um ein effizientes Einlesen der Daten während des Trainings und der Auswertung zu gewährleisten, werden die Datensätze anschließend in das TFRecord-Format konvertiert. Obwohl bereits bei der Aufnahme des Bildmaterials darauf geachtet wird, ein möglichst breites Spektrum an Szenarien, z. B. hinsichtlich der Wetterbedingungen, einzufangen, kann dieses auch noch während des Trainings eines Detektors durch die sogenannte Image Augmentation künstlich erweitert werden. Dabei werden zufällige Veränderungen an den Bilddaten und falls nötig auch an den Labels durchgeführt, wie etwa die Skalierung der Bilder (und der zugehörigen Bounding Boxen) zur Simulation von größer bzw. kleiner abgebildeten Pflanzen.

### 3 Ergebnisse und Diskussion

Während sechs Aufnahmeterrinen konnten mit oben beschriebener Methode Videodaten in einer Größe von 157 GB für die Zielpflanze Herbstzeitlose gesammelt werden. Dieser Datensatz beinhaltet 126 Einzelvideos mit einer gesamten Wiedergabedauer von knapp 2,5 Stunden. Für das Labeling von 85 % des Datensatzes wurden bisher über 450 Arbeitsstunden nötig, was damit im Verhältnis zur Aufnahme der Bilddaten den zeitaufwändigeren Teil darstellt. Über 18.000 Herbstzeitlosenpflanzen sind zum aktuellen Zeitpunkt manuell detektiert und markiert worden. Der Datensatz für das Jakobskreuzkraut besteht aus 42 Einzelvideos mit einer Größe von 55 GB, dies entspricht 35 Minuten Wiedergabedauer. Zum aktuellen Zeitpunkt wurde noch nicht mit dem Labeling für diese Zielpflanze begonnen.

Die präsentierte Methode zur Bilddatenakquisition hat sich in der ersten Saison als gut geeignet und praktikabel herausgestellt. Ein mobiler Aufbau mit eigenem Antrieb ermöglicht es, viel Fläche in kurzer Zeit abdecken zu können. Zudem ist die Effizienz durch die Verwendung von zwei Kameras parallel erhöht. Nachteilig war dies jedoch für die Datenübertragung nach einer Aufnahmefahrt. Die doppelte Zeit wurde nötig, da mit vorhandener Ausstattung keine simultane Übertragung von den kamerainternen Speichern möglich war. Allgemein war der Zeitbedarf zur Datenübertragung größer als die Aufnahmedauer der Kameras. Eine schnellere Methode oder der automatisierte Transfer beendeter Aufnahmen während der nächsten Fahrt könnte hier zur Optimierung beitragen. Faktoren wie Ausrichtung und Abstand zum Boden der Kameras sind durch den starren Aufbau gleichbleibend. Eine stativähnliche Konstruktion, die über den Pflanzen für eine Einzelbildaufnahme platziert wird, verspricht zwar eine bessere Bildqualität, ist aber abweichend vom späteren dynamischen Anwendungsfall einer Pflanzendetektion während der Überfahrt. Schwingungen, die sich durch Bodenunebenheiten vom Fahrwerk auf das Kameragestell übertragen haben, führten zu keiner merklichen Beeinträchtigung der Bildqualität. Durch den relativ leichten Aufbau mit voluminöser Bereifung ist selbst das Befahren von höheren Grasbeständen ohne bleibende Schäden möglich.

#### **4 Schlussfolgerungen und Ausblick**

Die unmittelbar anschließenden Arbeiten betreffen hauptsächlich das Trainieren des neuronalen Netzes und die folgende Validierung zur Überprüfung der Erkennungsleistung. Unter simulierten Umgebungsbedingungen soll die Kamera-Applikationssoftware danach im Zusammenspiel mit dem Pflanzendetektor erprobt werden, bevor Testphasen im realen Feldeinsatz durchgeführt werden. Um den Detektor sukzessive zu verbessern, werden über die Projektlaufzeit weitere Bilddaten gesammelt und verarbeitet. Zusätzlich ließe sich der zukünftige Labeling-Aufwand reduzieren, indem ein stochastischer Strukturgenerator entwickelt wird, der digitale Zwillinge der Ziel- und Umgebungspflanzen generieren kann.

**Förderhinweis:** Die Förderung des Vorhabens erfolgt aus Mitteln des Bundesministeriums für Ernährung und Landwirtschaft (BMEL) aufgrund eines Beschlusses des deutschen Bundestages. Die Projekträgerchaft erfolgt über die Bundesanstalt für Landwirtschaft und Ernährung (BLE) im Rahmen des Programms zur Innovationsförderung.

## Literaturverzeichnis

- [Br00] Briemle, G.: Giftpflanzen des Grünlandes - Wirkung auf Nutztier und Mensch, sowie Bekämpfungsmaßnahmen. Bildungs- und Wissenszentrum Aulendorf (LVVG), 2000.
- [Gr20] Grant, K. et al.: Herbstzeitlose (*Colchicum autumnale*) in Mulchschicht führt zu leichter Kontamination mit Colchizin eines Pflanzenbestandes im Folgeaufwuchs. In (Nordmeyer, H., Ulber, L., Hrsg.) Tagungsband 29. Deutsche Arbeitsbesprechung über Fragen der Unkrautbiologie und - bekämpfung; 3. - 5.3.2020, Julius-Kühn-Archiv Bd. 464, 2020.
- [Ha11] Handschuh, H.: SHA-0, SHA-1, SHA-2 (Secure Hash Algorithm). In (van Tilborg, H. C. A., Jajodia, S., Hrsg.) *Encyclopedia of Cryptography and Security*. Springer, S. 1190–1193, 2011.
- [HBK22] Hoiß, B.; Berg, M.; Krämer, M.: Die Herbstzeitlose im extensiven Grünland. *ANLiegen Natur* 44/1, S. 123–126, 2022.
- [Jo19] Joshi, M. A. et al.: *Image and Video Compression*. Taylor & Francis, 2019.
- [LS] LabelStudio Webseite: <https://labelstud.io/>, 27.10.2023.
- [MLS22] Martin, F.; Lohrmann, G.; Stoll, A.: Selective weed control in grassland using high-pressure water jets. In (VDI Wissensforum GmbH, Hrsg.) *Proceedings of the Conference 79th International Conference on Agricultural Engineering LAND.TECHNIK/AgEng 2022* (VDI-Berichte Nr. 2395), S. 105–110, 2022.
- [Pe20] Petrich, L. et al.: Detection of *Colchicum autumnale* in drone images, using a machine-learning approach. *Precision Agriculture* 6/21, S. 1291–1303, 2020.
- [PSS21] Petrich, L.; Stoll, A.; Schmidt, V.: Detection of *Senecio jacobaea* in drone images, using a machine-learning approach. In (Astor, T., Dzene, I., Hrsg.) *Proceedings of the 21st Symposium of the European Grassland Federation*, 17-19.5.2021, S. 178–180, 2021.
- [SE14] Seither, M.; Elsässer, M.: Bekämpfungsstrategien gegen Herbstzeitlose (*Colchicum autumnale*) und deren Auswirkungen auf die botanische Zusammensetzung artenreicher Wiesen. In (Thüringer Landesanstalt für Landwirtschaft, Hrsg.) *58. Jahrestagung der Arbeitsgemeinschaft Grünland und Futterbau der Gesellschaft für Pflanzenbauwissenschaften e.V.*, 28.-30.8.2014, S. 61-67, 2014.
- [SLM23] Stoll, A.; Lohrmann, G.; Martin, F.: Kleinräumig arbeitende Werkzeuge zur nicht-chemischen Zurückdrängung von Herbstzeitlosen (*Colchicum autumnale*). In (Bibic, V., Prof. Dr. Schmidtke, K., Hrsg.) *Tagungsband 16. Wissenschaftstagung Ökologischer Landbau*, 7.-10.3.2023, S. 178–181, 2023.
- [WPK11] Winter, S.; Penker, M.; Kriechbaum, M.: Die Herbstzeitlose – eine Problempflanze für Landwirtschaft und Naturschutz? *Jahrbuch der Österreichischen Gesellschaft für Agrarökonomie* 20/2, S. 221–230, 2011.



## Entwicklung eines vielfältigen und anspruchsvollen Benchmark-Datensatzes für die Detektion von Schweinen in Bildern

Jonathan Henrich<sup>1</sup>, Christian Post<sup>2</sup>, Thomas Kneib<sup>1</sup>, Ramin Yahyapour<sup>3</sup>, Sven Bingert<sup>3</sup>  
und Imke Traulsen<sup>4</sup>

**Abstract:** Die Lokalisation von Schweinen in Videobildern mittels Objektdetektion spielt eine Schlüsselrolle bei der Gestaltung digitaler Überwachungssysteme in der Schweinehaltung. Um leistungsstarke Schweinedetektionsmodelle zu trainieren und systematisch miteinander zu vergleichen, bedarf es diverser und für Detektionsmodelle anspruchsvoller annotierter Datensätze. Aktuell sind solche Ressourcen nur begrenzt verfügbar. Dem soll im Rahmen dieser Arbeit nachgegangen werden, indem die Grundlage für einen anspruchsvollen Benchmark-Datensatz für die Schweinedetektion geschaffen wird. Anspruchsvolle Bilder, d. h. anfällig für fehlerhafte Detektionen, wurden mithilfe eines interaktiven prädiktionsbasierten Ansatzes identifiziert. Die experimentellen Ergebnisse legen nahe, dass sich diese gezielte Auswahl von anspruchsvollen Bildern positiv auf die Leistung von trainierten Schweinedetektionsmodellen auswirkt.

**Keywords:** Objektdetektion, Schweine, Datensatz

### 1 Einleitung

In der Schweinehaltung wird die Unterstützung der Tierbeobachtung durch digitale Systeme immer wichtiger. Besonders von Interesse sind dabei Methoden für die Verhaltenserkennung und das Tracking von Gruppen von Schweinen. Ein grundlegender Baustein solcher Methoden ist die zuverlässige Lokalisation einzelner Tiere. In der Regel werden dafür Objektdetektionsmodelle verwendet, welche darauf abzielen, einzelne Schweine mittels Bounding-Boxen zu lokalisieren. Mit diesem Thema haben sich in der Vergangenheit bereits zahlreiche Forschungsarbeiten beschäftigt; in vielen Fällen verwendeten die Autoren für das Training und die Evaluation der Modelle eigens annotierte Datensätze, welche nicht frei verfügbar gemacht wurden [Ha22; Ma23].

---

<sup>1</sup> Georg-August-Universität Göttingen, Department für Volkswirtschaftslehre, Humboldtallee 3, 37073 Göttingen, {jonathan.henrich; tkneib}@uni-goettingen.de

<sup>2</sup> Georg-August-Universität Göttingen, Department für Nutztierwissenschaften, Albrecht-Thaer-Weg 3, 37075 Göttingen, christian.post@uni-goettingen.de

<sup>3</sup> Gesellschaft für wissenschaftliche Datenverarbeitung mbH Göttingen, Burckhardtweg 4, 37077 Göttingen, {ramin.yahyapour; sven.bingert}@gwdg.de

<sup>4</sup> Christian-Albrechts-Universität zu Kiel, Institut für Tierzucht und Tierhaltung, Olshausenstrasse 40, 24098 Kiel, itraulsen@tierzucht.uni-kiel.de

Studien mit öffentlich zugänglichen Datensätzen sind selten und in der Diversität der erfassten Stallumgebungen beschränkt [Ri20; Be21]. Dieser Mangel an qualitativ hochwertigen und diversen Datensätzen, die öffentlich verfügbar sind, hat zwei Konsequenzen: (1) Die Vergleichbarkeit bisheriger Ansätze ist wegen der Verwendung verschiedener Datensätze nicht gewährleistet und (2) das Training von robusten Schweinedetektoren ist aufgrund der mangelnden Datenbasis erschwert. Bei der Erstellung eines Detektionsdatensatzes ist neben der Diversität der Stallumgebungen die gezielte Auswahl von anspruchsvollen Bildern für die Annotation entscheidend. Das Vorhandensein solcher Bilder ist eine Grundvoraussetzung für das Training von leistungsstarken Schweinedetektoren und die Erstellung eines anspruchsvollen Testdatensatzes, der für einen differenzierten Vergleich verschiedener Methoden verwendet werden kann.

Das Ziel der vorliegenden Arbeit ist es, die Basis für einen Benchmark-Datensatz für die Schweinedetektion zu bilden, welcher im Rahmen des dieser Arbeit zugrundeliegenden Forschungsprojektes öffentlich gemacht werden soll. Anspruchsvolle Bilder werden anhand von fehlerhaften Prädiktionen in einem interaktiven Labeling-Tool identifiziert. Dieser Ansatz ist konzeptionell simpel und ermöglicht aufgrund der Interaktivität den Einbezug von Expertenwissen bei der Erstellung des Datensatzes. Es wird untersucht, ob die gezielte Auswahl von anspruchsvollen Bildern zur Annotation im Vergleich zur zufälligen Auswahl eine Verbesserung der Detektionsgüte mit sich bringt.

## 2 Material und Methoden

Für den Versuch standen Videoaufnahmen (max. 1280 x 800 Pixel, 10–15 Bilder/s) von Mastschweinen (Anfangs- bis Endmast) in vier verschiedenen, konventionellen Stallumgebungen, davon zwei Ställe im Forschungsprojekt Inno Pig (BLE, Fkz.: 28RZ372060), und je ein Stall aus den Forschungsprojekten FriSch (BLE, Fkz.: 2817902315), und Old Breed New House (Fkz.: EIP-Agri-Ni-2019-LPTT-03) zur Verfügung. Die vorliegenden Buchten unterscheiden sich, auch innerhalb der verschiedenen Forschungsprojekte, in einer Vielzahl von Merkmalen (Größe, Form, Inventar, Bodenbelag, Alter und Anzahl der Schweine) und wurden von oben mittig oder schräg oben 24h/d aus verschiedenen Perspektiven aufgenommen, nachts z. T. mit Infrarotlichtkameras. Aus diesen Videodateien wurde jeweils ein Einzelbild an zufälliger Stelle extrahiert. Diese Bilder wurden zunächst manuell gesichtet, und Bilder mit zu schlechten Licht- und Sichtverhältnissen (z. B. Okklusion durch Kabel) entfernt, bis 1331 Bilder zur Verfügung standen. Auf jedem dieser Bilder wurde mittels des Programms Labelme [Wa23] um jedes eindeutig erkennbare einzelne Schwein eine rechteckige Bounding-Box gezeichnet (siehe Abb. 1).

Zusätzlich zum oben beschriebenen Annotationsprozess für zufällig ausgewählte Bilder wurde ein Verfahren entwickelt, um gezielt anspruchsvolle Bilder auszuwählen. Dafür wurde zuerst ein Detektor (YOLOX, [Ge21]) mit den zufällig ausgewählten Bildern

trainiert. Anschließend wurde dieser Detektor in das Labeling-Tool pylabel integriert [He23]. Dieses erlaubt modellgestütztes Labeling, d. h. für ein Bild wurden zunächst mithilfe des Modells Detektionen generiert und anschließend vom Anwender überprüft. Bei Vorhandensein von groben Fehlern (fehlende, zu viele oder stark falsche Bounding-Boxen) wurden Bilder als „anspruchsvoll“ klassifiziert und die Fehler im Labeling-Tool korrigiert. Auf diese Weise wurden 242 anspruchsvolle Bilder identifiziert und annotiert, sodass insgesamt 1573 annotierte Bilder zur Verfügung standen.

Die annotierten Bilder eines der Ställe (n=173; davon 42 gezielt und 131 zufällig) wurden als Validierungsdaten und die restlichen Bilder als Trainingsdaten verwendet (n=1400; 200 gezielt, 1200 zufällig). Um das beste Modell für ein Training auszuwählen, wurde standardmäßig die Average Precision (AP) verwendet, welche erstmals bei der Pascal VOC 2007 Challenge eingeführt wurde [Ev10]. Die AP ist ein Maß für die Güte der vorhergesagten Bounding-Boxen. Einerseits wird die AP mit einer Intersection-over-Union-Schranke von 0,5 berichtet (AP50). Diese gibt Aufschluss darüber, wie gut Schweine prinzipiell erkannt werden, wobei die Genauigkeit der vorhergesagten Bounding-Boxen keinen Einfluss hat. Andererseits wird auch die mean Average Precision (mAP) mit Intersection-over-Union-Schranken von 0,5 bis 0,95 in Schritten von 0,05 berichtet. Diese bezieht zusätzlich die Genauigkeit der vorhergesagten Bounding-Boxen ein und ist somit ein differenzierteres Maß für die Detektionsgüte. Der bestmögliche AP50- und mAP-Wert ist 1 bei perfekt vorhergesagten Bounding-Boxen.



Abb. 1: Beispiel für ein mit Bounding-Boxen annotiertes Bild

Es wurde ein Experiment mit den zwei Faktoren „Anzahl Trainingsbilder“ und „zufällig vs. gezielt“ durchgeführt. Die Anzahl der für das Training verwendeten Bilder wurde bei „zufällig“ in neun Stufen (50, 100, 150, 200, 400, 600, 800, 1000, 1200) und bei „gezielt“ in vier Stufen (50, 100, 150, 200) variiert. Zusätzlich zu diesen Versuchsvarianten wurde das Modell auch mit einem Datensatz mit allen 1400 Bildern (zufällig + gezielt) trainiert, sodass es insgesamt 14 Versuchsvarianten gab. Für jede Variante wurden 10 Trainings durchgeführt (insgesamt 140 trainierte Netzwerke), wobei die Trainingsdaten jeweils zufällig aus den gesamten annotierten Daten ausgewählt wurden. Es wurde eine konstante

Learning Rate von  $6,25 \times 10^{-4}$  verwendet, um eine Vergleichbarkeit der Bedingungen zu gewährleisten; ansonsten wurden die standardmäßigen Modell- und Trainingsparameter der offiziellen Implementation von YOLOX beibehalten und die mittlere Modellgröße „YOLOX-m“ verwendet. Zuerst wurde so lange trainiert, bis die mAP der Validierungsdaten für 20 Epochen stagnierte. Dann wurde für weitere 25 Epochen ohne die standardmäßig implementierten Datenaugmentierungen trainiert, mit dem Ziel eines zusätzlichen Performance-Boosts.

### 3 Ergebnisse und Diskussion

In der Variante „zufällig“ erhöhte sich wenig überraschend die mAP, je mehr Trainingsbilder verwendet wurden (Abb. 2a). Jedoch nahm die Verbesserung mit wachsender Anzahl an Trainingsbildern ab. Beispielsweise war die Verbesserung zwischen 600 und 1200 Trainingsbildern (mAP-Differenz von 0,81 %) im Vergleich zur Verbesserung zwischen 50 und 600 Trainingsbildern (mAP-Differenz von 8,75 %) marginal. Bei der AP50 wurde ein ähnliches Muster beobachtet (Abb. 2b).




Abb. 2: Mittlere Validierungsperformance über 10 Trainings für alle Versuchsvarianten gemessen in (a) mAP und (b) AP50. Die Balken zeigen die Standardabweichung an

Bei gleicher Anzahl an Trainingsbildern war die mAP für gezielt ausgewählte Bilder im Schnitt besser als die für zufällig ausgewählte. Darüber hinaus verbesserte sich durch die Hinzunahme der gezielt ausgewählten Bilder zu allen zufällig ausgewählten Bildern (1200 Bilder vs. 1400 Bilder) die mAP um 0,63 %. Dieser Unterschied war größer als der zwischen 800 und 1200 zufällig annotierten Bildern (mAP-Differenz von 0,52 %). Die Verbesserung der AP50 zwischen den Varianten mit 1200 Bildern und 1400 Bildern war mit 0,64 % besonders markant.

Die Ergebnisse dieser Arbeit legen nahe, dass ab einer gewissen Datenmenge eine Verbesserung der Detektionsperformance bei ausschließlicher Verwendung von zufällig ausgewählten Bildern kaum oder gar nicht mehr zu erreichen ist. Dies unterstreicht die Notwendigkeit der gezielten Auswahl von anspruchsvollen Bildern, da diese neue Informationen enthalten, von denen Detektionsmodelle noch lernen können. Nur so können leistungsstarke Detektionsmodelle trainiert und differenziert miteinander verglichen werden. Die dafür benötigten Bilder können grundsätzlich erfolgreich anhand eines interaktiven prädiktionsbasierten Ansatzes identifiziert werden. Es sollte jedoch angemerkt werden, dass diese Art der Identifikation einen hohen subjektiven Anteil besitzt. Letztendlich entscheidet der Anwender des interaktiven Tools, welche Bilder mit Detektionsfehlern als zu schwierig erachtet werden (z. B. aufgrund von übermäßigen Okklusionen) und welche nicht. Die im hier gezeigten Verfahren entstandenen annotierten Bilder decken somit keinesfalls die gesamte Palette an möglichen Szenarien in der Schweinehaltung ab, was sich selbstverständlich in den Fähigkeiten der mit den Bildern trainierten Detektionsmodelle widerspiegelt.

In zukünftiger Arbeit soll der vorliegende Datensatz nach den FAIR-Prinzipien [Wi16] veröffentlicht und mit weiteren offen verfügbare Bilddaten aus der Schweinehaltung [Ps19, Ri20, Be21] ergänzt werden, um einen anspruchsvollen und diversen Benchmark-Datensatz für die Schweinedetektion zu kreieren. Detektoren sind häufig direkt in komplexere Methoden für Tracking [ZWZ23; Ya23] oder Verhaltenserkennung [Si23] integriert. Daher sind leistungsstarke Objektdetektoren ein entscheidender Faktor für umfassende digitale Tierbeobachtungssysteme.

**Förderhinweis:** Das diesem Beitrag zugrunde liegende Vorhaben wurde mit NextGenerationEU-Mitteln der Europäischen Union durch das Bundesministerium für Bildung und Forschung unter dem Förderkennzeichen 16DKWN038 gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren.

#### Literaturverzeichnis

- [Be21] Bergamini, L. et al: Extracting Accurate Long-term Behavior Changes from a Large Pig Dataset. In: Proceedings of the 16th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, S. 524–533, 2021.
- [Ev10] Everingham, M. et al.: The Pascal Visual Object Classes (VOC) Challenge. International Journal of Computer Vision 88, 2, 303–338, 2010.

- [Ge21] Ge, Z. et al.: Yolox: Exceeding yolo series in 2021. arXiv preprint arXiv:2107.08430, 2021.
- [Ha22] Hao, W. et al.: A Novel Improved YOLOv3-SC Model for Individual Pig Detection. *Sensors* 22, S. 8792, 2022.
- [He23] Heaton, A.: pylabel, <https://github.com/pylabel-project/pylabel>, 2022.
- [Ma23] Mattina, M. et al.: An efficient anchor-free method for pig detection. *IET Image Processing*. 17, 2, S. 613–626, 2023.
- [Ps19] Psota, E. et al.: Multi-Pig Part Detection and Association with a Fully-Convolutional Network. *Sensors*. 19, 4, S. 852, 2019.
- [Ri20] Riekert, M. et al.: Automatically detecting pig position and posture by 2D camera imaging and deep learning. *Computers and Electronics in Agriculture*. 174, S. 105391, 2020.
- [Si23] Singh, G. et al.: Spatio-Temporal Action Detection Under Large Motion. In: 2023 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). S. 5998–6007, 2023.
- [Wa23] Wada, K.: Labelme: Image Polygonal Annotation with Python. <https://github.com/wkentaro/labelme>, 2023.
- [Wi16] Wilkinson, M. D. et al. (15. Marz 2016). The FAIR Guiding Principles for scientific data management and stewardship. In: *Scientific Data* 3.1, S. 160018.
- [Ya23] Yang, F. et al.: Hard to Track Objects with Irregular Motions and Similar Appearances? Make It Easier by Buffering the Matching Space. In: 2023 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). S. 4788–4797, 2023.
- [Zh23] Zhang, Y. et al.: MOTRv2: Bootstrapping End-to-End Multi-Object Tracking by Pretrained Object Detectors. In: 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). S. 22056–22065, 2023.

# Entwicklung eines Algorithmus zur automatischen Belegung von freibehlegbaren Bedienelementen auf der Armlehne eines Ackerschleppers via ISOBUS

## Adaptive Interface-Systeme auf Ackerschleppern 2.0

Björn-Gerrit Hülle<sup>1</sup> und Stefan Böttinger<sup>1</sup>

**Abstract:** Der Ackerschlepper fungiert als universelle Plattform, an die eine Vielzahl von Arbeitsgeräten angekoppelt wird. Dementsprechend ist auch das HMI universell ausgelegt und nicht auf einen bestimmten Arbeitsprozess optimal für den Benutzer angepasst. Die Projektpartner entwickeln gemeinsam ein neues Softwarekonzept auf Basis von ISO 11783 und SAE J1939. Parallel dazu wird der Prototyp der Armlehne weiterentwickelt und um notwendige statische Traktorfunktionen ergänzt. Die neue Softwarekommunikation beinhaltet als zentrales Element einen Algorithmus, der die Funktionen des Arbeitsgerätes automatisch den frei belegbaren Bedienelementen des Ackerschleppers zuordnet. Derzeit wird die erste Version dieses Algorithmus zusammen mit der neuen Hard- und Software in den Versuchstraktor integriert, der Anfang 2024 in Betrieb gehen soll. Parallel dazu wird der Algorithmus weiterentwickelt, um die vorgeschlagene Konfiguration des Algorithmus zu optimieren. Dazu werden Untersuchungen durchgeführt, um ein Bewertungsraster für Bedienarmlehnen auf Ackerschleppern zu entwickeln, das dann in den Algorithmus integriert werden kann.

**Keywords:** HMI, Usability, adaptiv, ISOBUS

## 1 Einleitung

Ackerschlepper dienen in der heutigen Land-, Forst- und Kommunaltechnik als Universalmaschinen für verschiedenste Arbeiten mit den unterschiedlichsten Anbaugeräten. Im Projekt adaptive Interface Systeme auf Ackerschleppern 2.0 (aISA 2.0) beschäftigt sich das Projektteam mit der Verbesserung der Ergonomie der Bedienarmlehne von Ackerschleppern. Die im Vorgängerprojekt entwickelte Armlehne wird nach den Kriterien der kognitiven und physischen Ergonomie weiterentwickelt [Ka17]. In diesem Beitrag steht die Optimierung der kognitiven Ergonomie im Vordergrund. Grundvoraussetzung für den Einsatz eines Ackerschleppers mit Anbaugeräten sind genormte Kuppelstellen und die genormte Kraftübertragung vom Ackerschlepper zum Anbaugerät. Dies ist z. B. in der ISO 730 und ISO 500 definiert. [In09b; In14]. Seit Mitte des 20. Jahrhundert hat die Datenkommunikation zwischen Anbaugerät und

---

<sup>1</sup> Universität Hohenheim, Institut für Agrartechnik – Fachgebiet Grundlagen für Agrartechnik, Garbenstraße 9, 70599 Stuttgart, bjoern-gerrit.huelle@uni-hohenheim.de, boettinger@uni-hohenheim.de

Ackerschlepper, aber auch generell bei Nutzfahrzeugen, an Bedeutung gewonnen. Erste Standardisierungen in der Kommunikation zwischen Ackerschlepper und Anbaugerät wurden in der DIN 9684 [De89], die später in die ISO 11786 übergang [In95], definiert. Hier werden Traktordaten einseitig an das Arbeitsgerät übertragen, um z. B. die Ausbringmenge von Mineraldünger an die Fahrgeschwindigkeit anzupassen. Dadurch kann auf zusätzliche Sensoren beim Arbeitsgerät verzichtet werden. Aktueller Stand der Technik ist die ISO 11783 [In09a]. Hier kommunizieren der Ackerschlepper und das Anbaugerät über ein CAN-BUS System, welches auf dem Kommunikationsprotokoll SAE J1939 basiert [Tr18]. Das System wird allgemein als „ISOBUS“ bezeichnet und hat den Vorteil, dass verschiedene Arbeitsgeräte über ein einziges separates Terminal, das „Universal Terminal“ (UT), im virtuellen Bereich bedient werden können. Zusätzlich können frei belegbare Bedienelemente, nach ISO 11783 als „Auxiliary Control“ bezeichnet, an der Armlehne des Ackerschleppers mit Funktionen des Arbeitsgerätes belegt werden. Auf deren unterschiedliche Bediencharakteristik, „AUX-N“, wird später noch näher eingegangen. Der Nachteil gegenüber der virtuellen Bedienung und Anzeige ist, dass der Funktion des Bedienelementes kein Symbol als Softkey zugeordnet ist und der Benutzer sich die Tastenbelegung merken muss. Außerdem muss der Benutzer die frei belegbaren Tasten vorher manuell konfigurieren. Diese beiden Punkte reduzieren die kognitive Ergonomie und werden mit dem in aISA 2.0 entwickelten System adressiert.

## 2 Material und Methoden

Die in aISA 2.0 entwickelte Armlehne verfügt über adaptive, frei belegbare Bedienelemente, die modular aufgebaut sind und somit in bestehende Systeme aller Traktorenhersteller integriert werden können. Das heißt, sie können ihre Bewegungsrichtung, Form und Funktionsbelegung ändern. Zusätzlich verfügen sie über Displays, die mit einem Icon für die jeweilige Funktion belegt werden können. Beispielhaft für die verschiedenen adaptiven Bedienmodule ist in Abbildung 1 der 2-Wege-Kipphebel dargestellt.




Abb. 1: 2-Wege-Kipphebel-Module

Oberhalb des jeweiligen Kipphebels befinden sich die Displays, die die jeweilige Bedienfunktion anzeigen, die sich auf dem jeweiligen Element befindet. Zusätzlich kann



bei diesem Element die Bewegungsrichtung je nach Funktion von „vor/zurück“ auf „links/rechts“ geändert werden, wie bei dem dritten Element von links zu sehen ist. Somit kann die Bewegung des Stellgliedes analog zur Bewegung des Wirkgliedes erfolgen.

In diesem Beitrag wird auf zwei wesentliche Punkte des Projektes aISA 2.0 eingegangen. Zum einen wurde und wird ein Algorithmus entwickelt, der die Zuordnung der Funktionen des Anbaugerätes zu den frei wählbaren Bedienelementen der Armlehne ermittelt und dem Benutzer vorschlägt. Zum anderen wird ein funktionsspezifisches Icon auf einem Display am jeweiligen Bedienelement angezeigt. In den Algorithmus fließen zunächst drei Tabellen ein, die anhand verschiedener Kriterien verglichen werden. Diese Kriterien sind Teil einer anderen noch nicht veröffentlichten Publikation und können deshalb erst im Vortrag detailliert beschrieben werden. Die „resource table“ enthält die Informationen über die verfügbaren Bedienelemente der Armlehne, deren Ausprägung und ergonomische Position. Die „Operation Table“ enthält analog dazu die Informationen über die Funktionen des Anbaugerätes, wie diese auf der Armlehne dargestellt werden sollen und deren ergonomischem Rang. Die ähnlich aufgebaute „Tractor Table“ enthält die Funktionen des Traktors, z. B. Hydraulikventile und Zapfwelle.

Dem ergonomischen Rang und der ergonomischen Position liegen verschiedene Kriterien der physischen und kognitiven Ergonomie zu Grunde, wie zum Beispiel die Bewertung der Position auf der Armlehne in den Greifbereichen und nach Komfortwinkeln [De09; In18], und Erfahrungen aus eigenen Voruntersuchungen. Ein Kriterium für den ergonomischen Rang einer Funktion eines Arbeitsgerätes kann z. B. die Häufigkeit sein, mit der diese Funktion betätigt wird. Der Algorithmus gleicht diese Kriterien miteinander ab und stellt dem Benutzer eine Konfiguration in Form der „Final Configuration Table“ zur Verfügung. Der Benutzer hat dann die Möglichkeit, den Vorschlag zu akzeptieren oder ihn an seine Bedürfnisse anzupassen. Am Ende bestätigt er seine Auswahl und die endgültige Konfiguration wird auf der Armlehne eingestellt. Für den Fall, dass kein Anbaugerät angeschlossen ist, wird vom Hersteller eine „basic configuration proposal table“ im System hinterlegt. Ein Ausschnitt aus dem Kommunikationsschema der Software ist in Abbildung 2 dargestellt.

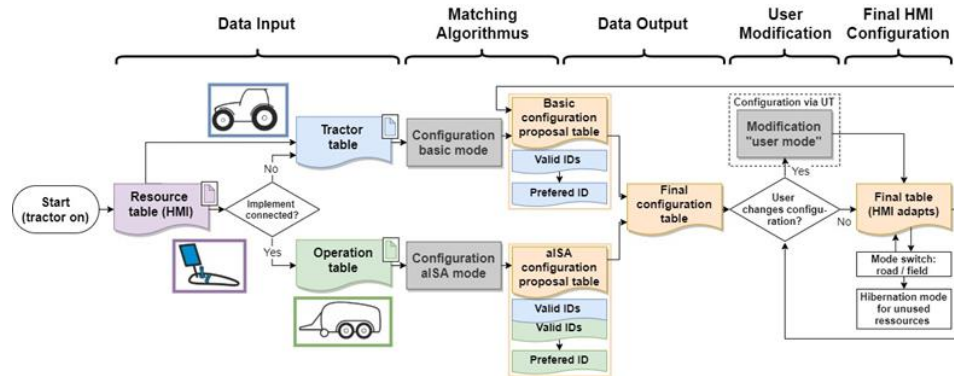


Abb. 2: Auszug aus dem Schema der Softwarekommunikation von aISA 2.0

Wenn die finale Konfiguration vorgenommen wurde, werden die funktionspezifischen Symbole an dem jeweiligen Bedienelement dargestellt. So kann der Benutzer jederzeit nachvollziehen, welche Funktion sich auf dem jeweiligen Bedienelement befindet. Die endgültige Konfiguration wird für diese Kombination aus Traktor und Anbaugerät gespeichert und beim nächsten Ankuppeln wieder geladen. Zusätzlich kann der Benutzer zwischen Straßen- und Feldmodus umschalten, um zu verhindern, dass Funktionen, die während der Straßenfahrt nicht benötigt werden, versehentlich bedient werden. Das Gesamtsystem ist abwärtskompatibel, so dass auch Arbeitsgeräte ohne ISOBUS oder ohne die Softwareoption aISA bedient werden können. In diesem Fall entfällt jedoch das funktionspezifische Symbol.

### 3 Ergebnisse und Ausblick

Als Ergebnis ist in Abbildung 2 eine beispielhafte Konfiguration für ein gezogenes Güllefass mit Schleppschuhverteiler auf der im Projekt aISA 2.0 entwickelten Armlehne dargestellt. Rot umrahmt sind zwei Module, die bereits in Abbildung 1 kurz vorgestellt wurden und deren Konfiguration hier beispielhaft betrachtet wird. Die Bewegungsrichtung der Kipphebel ist auf links/rechts eingestellt. Das Symbol zeigt an, dass im linken Modul die Zuschaltung der Teilbreiten auf der linken Seite und im rechten Modul die Zuschaltung der Teilbreiten auf der rechten Seite des Gestänges erfolgt. Somit ist eine Bewegungskompatibilität zwischen dem Stellteil und dem Wirkteil gegeben und damit eine Verbesserung der kognitiven Ergonomie. [Sc03].



Abb. 3: Exemplarische Konfiguration für ein Güllefass auf der aISA 2.0 Armlehne



Die Zuordnung der Funktionen zu diesen Bedienelementen und dass diese genau nebeneinanderliegen, ist dem Umstand geschuldet, dass das adaptive Bedienmodul es ermöglicht, die Funktionen am Bedienelement von links nach rechts und umgekehrt zu bedienen. Es ist also fast schon ein Zufall, dass die Funktionen örtlich nah und auch in ihrer Anordnung auf der Armlehne sinnvoll zum Ort am Arbeitsgerät sind. Diese beiden Punkte werden bei der Weiterentwicklung in den Algorithmus integriert werden. Zum einen sollen Funktionen, die zusammenhängen oder das gleiche Teil am Anbaugerät bedienen, örtlich nah zusammengefasst werden. Zum anderen sollen Funktionen, wie in diesem Fall der linke Teil der Deichsel, dem entsprechenden Bedienelement links auf der Armlehne zugeordnet werden. Analog dann die Zuordnung für den rechten Teil des Gestänges. Dies darf jedoch nicht dazu führen, dass wichtige und stark frequentierte Funktionen von einem ergonomisch günstigen Platz verdrängt werden.

Literaturverzeichnis

- [De09] DIN EN ISO 6682: Erdbaumaschinen - Stellteile - Bequemlichkeitsbereiche und Reichweitenbereiche, 2009 (ISO 6682:1986, einschließlich Änderung 1:1989).
- [De89] DIN 9684: Agricultural tractors and machinery - Interfaces for signal transfer, 1989.
- [In09a] ISO 11783: Tractors and machinery for agriculture and forestry - Serial control and communications data network, 2009.
- [In09b] ISO 730: Agricultural wheeled tractors - Rear-mounted three-point linkage - Categories 1N, 1, 2N, 2, 3N, 3, 4N and 4, 2009.
- [In14] ISO 500: Agricultural tractors - Rear mounted power take-off types 1, 2, 3 and 4, 2014.
- [In18] Institut für Arbeitsschutz der DGUV: Bewertung physischer Belastungen gemäß DGUV. <https://www.dguv.de/medien/ifa/de/fac/ergonomie/pdf/>, Stand: 2023-03-18.
- [In95] ISO 11786: Agricultural tractors and machinery - Tractor-mounted sensor interface - Specifications, 1995.
- [Ka17] Kaufmann, A. et al.: The Development of an Adaptive HMI - From the Idea to the Prototype 972, 2017.
- [Sc03] Schmid, M.: Benutzergerechte Gestaltung mechanischer Anzeiger mit Drehrichtungsinkompatibilität zwischen Stell- und Wirkteil. Dissertation Universität Stuttgart 2003. Institut für Maschinenkonstruktion und Getriebebau, Forschungs- und Lehrgebiet Technisches Design, Stuttgart, 2003.
- [Tr18] SAE J1939: Serial Control and Communications Heavy Duty Vehicle Network, 2018.

## Learning from hyperspectral remote sensing data for machine learning algorithms in earth science

### A case study to detect plastic-covered greenhouses and plastic-mulched farmlands

Christoph Jörges <sup>1</sup>, Sandra Dotzler<sup>1</sup>, Silke Migdall <sup>1</sup> and Heike Bach<sup>1</sup>



**Abstract:** Machine Learning in Earth sciences heavily depends on sufficient training data for proper generalization. Since in-situ ground truth data is rarely available and cost-intensive to obtain, this study presents a new approach of deriving training data from hyperspectral remote sensing satellites by physical spectral signatures to use them for data-driven models with operationally available multispectral data. Examples include monitoring of crop rotation, winter greening, soil organic matter, and detection of plastic covered greenhouses (PCGs).

**Keywords:** hyperspectral imaging; plasticulture; machine learning; land use classification; remote sensing

## 1 Introduction

In the last decades, numerous operational multispectral (MS) satellite missions have enabled various use cases, including land use and land cover mapping, crop type classification, ecosystem monitoring, and retrieval of environmental parameters. With an increasing availability of big data in Earth science, data-driven machine learning (ML) algorithms have become suitable [Yu20]. Nevertheless, high quality in-situ training data are rarely available and cost-intensive to obtain with measurement devices in the field. Generating a sufficient training data set can be very challenging, but is essential for generalizable ML models. In this study, we propose a new approach of generating ML training data from high spectral resolution hyperspectral (HS) remote sensing satellite imaging by using physical-based spectral signatures. The generated HS pins can be used by operational MS satellite data with high temporal and spatial resolution and coverage for agricultural applications. Examples are monitoring of crop type and crop rotation, winter greening, flowering strips, soil organic matter, and detection of photovoltaic power plants and plastic mulched farmlands (PMFs) or plastic covered greenhouses (PCGs). The latter serves as use case for demonstrating the HS training data generation in this study. In recent decades, the demand of PMFs and PCGs for fruits and vegetables has increased

---

<sup>1</sup> VISTA Remote Sensing in Geosciences GmbH, Gabelsbergerstr. 51, 80333 München, joerges@vista-geo.de, dotzler@vista-geo.de, migdall@vista-geo.de, bach@vista-geo.de,  <https://orcid.org/0000-0001-9254-1848>  
 <https://orcid.org/0000-0001-9089-6274>

significantly in e.g. Mediterranean countries like Spain and Italy, to support efficient horticulture or farming and increasing yields of e.g. strawberries.

## 2 Data and Methods

### 2.1 Data

#### *Hyperspectral data*

To generate a training dataset for the ML model, HS remote sensing data were utilized for ground truth (GT) retrieval. For the test case, an acquisition of 18/07/2022 from the German satellite mission Environmental Mapping and Analysis Program (EnMAP) of an area north-west of Almeria, Spain, was used (Fig. 1). The EnMAP satellite image has a spatial resolution of 30 m and covers an area of 37 x 35 km. The EnMAP data are only available on request. Most of the study area is covered by non-agricultural dry land with bare soil and bushes. Around the small urban areas plantations with olive trees and PCG and PMF can be found. The spectral resolution of EnMAP is about 6.5 to 10 nm in the ranges 418 to 895 nm (VNIR) and 902 to 2445 nm (SWIR). Original Level 2A EnMAP data have 224 spectral bands, which were reduced to 197 bands during the pre-processing to eliminate water vapor saturated bands and overlaps between the VNIR and SWIR sensors.

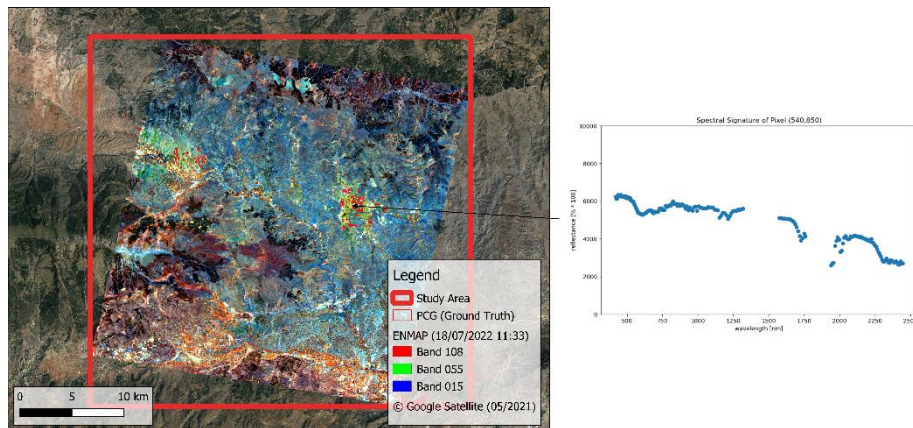


Fig. 1: Study area with HS EnMAP image and example of PCG spectral signature.

#### *Multispectral data*

MS Sentinel-2 (S2) data were used as features for the ML model together with the HS-derived GT. The S2 acquisition of 17/07/2022 covers the study area (tile 30SWG) only one day before the EnMAP acquisition. The Level 1C data were cirrus and atmospheric corrected and after pre-processing 9 spectral bands were used. The spatial resolution of S2

is 10 m with an operational revisit time of a few days for Europe. Thus, trained ML models with MS data can be applied to large-scale areas and applications.

#### *Ground Truth data*

For the GT of PCG, information of greenhouse locations in Andalusia of the year 2014 from the Spanish land cover and land use information system (SIOSE<sup>2</sup>) were used in combination with Google Satellite images from May 2021. The GT data describe the PCG locations nine months before the satellite acquisitions. The GT was rasterized and transformed to the spatial resolution of EnMAP and S2, respectively, by ensuring a minimum of 50% spectral mixture of the PCG per positive GT pixel.

## 2.2 Hyperspectral indices and pins

Plastic surfaces show a special spectral fingerprint, which can be seen by HS imaging. In this study, HS indices and special absorption depths were calculated to identify plastic materials. For the pixel-level segmentation of the satellite image, a logical AND operation of the condition  $\text{index} > \text{threshold}$  (or  $\text{index} < \text{threshold}$ ) was performed with all five indices described below.

#### *Normalized Hydrocarbon Index (nHI)*

The normalized hydrocarbon index (nHI) describes a significant absorption peak of hydrocarbon materials in the SWIR region around 1730 nm. [Ji21] developed the nHI by taking into account the absorption depth relative to its spectral shoulders  $\lambda_A = 1664$  nm and  $\lambda_C = 1749$  nm and center  $\lambda_B = 1728$  nm:

$$\text{nHI} = \text{HI} / R_{B'} = (R_{B'} - R_B) / R_{B'} \text{ with } R_{B'} = (\lambda_B - \lambda_A) * (R_C - R_A) / (\lambda_C - \lambda_A) + R_A \quad (1)$$

#### *Plastic Depth Index (nPDI)*

The normalized plastic depth index (PDI) was developed within this study to consider the characteristic absorption of plastic materials at about 1215 nm, as found by [Ta21]. The PDI works similar to the nHI but focuses on other wavelengths. Therefore, the PDI can be calculated from Eq. 1 with  $\lambda_A = 1187$  nm,  $\lambda_B = 1211$  nm, and  $\lambda_C = 1235$  nm.

#### *Index of average reflectance in the VNIR (aVNIR)*

The average reflectance in the VNIR (aVNIR) between 500 and 1000 nm is very high for PCG due to their white color and resulting high reflectance in the visible and near-infrared.

#### *PolyEthylene Peak in the visible range (VPEP)*

This index is used to explicitly detect polyethylene surfaces with greenish or reddish colors. It is calculated by

$$\text{VPEP} = R_{630} - R_{470} - 7/16 | R_{540} - R_{470}| \quad (2)$$

<sup>2</sup> <https://datos.gob.es/en/catalogo/e00125901-spaingnsiose2014>

*Retrogressive Plastic Greenhouse Index (RPGI)*

[Ya17] proposed the retrogressive plastic greenhouse index (RPGI) as a cohesive and robust measure of PCGs with medium resolution satellite data. The RPGI is calculated by:

$$\text{RPGI} = R_{\text{blue}} / (1 - \text{mean}(R_{\text{blue}}, R_{\text{green}}, R_{\text{nir}})) \quad (3)$$

### 2.3 Multispectral ML model

MS S2 data and retrieved HS labels as GT were used for the ML model training. In a preprocessing step, the unbalanced binary classes were balanced out to ensure a robust model training. Afterwards, the data were randomly shuffled and split into training data (130 773 data points) and test data (56 046 data points). The two models deep feed-forward artificial neural network (ANN) and random forest (RF) were compared for the demonstration and evaluation of the concept to use HS pins for MS ML models.

*Deep Artificial Neural Network*

An ANN with three hidden layers of 50, 100, and 50 neurons and ReLU activation function was built to learn the spectral features of PCGs in the 9-bands MS satellite data. The fuzzy ANN output is the probability of a pixel being classified as PCG. A model confidence of 0.95 was used to assign each pixel to the binary classification 0 (=No PCG) or 1 (=PCG).

*Random Forest*

A RF ensemble decision tree model with 150 independent estimators with a maximum depth of 50 nodes was built to learn the spectral features of PCGs in the 9-bands MS satellite data. The RF directly outputs a binary classification value.

## 3 Results and Discussion

### 3.1 Generating high-quality hyperspectral training data

By optimizing the thresholds of the HS indices using grid search, best classification of PCG with EnMAP data was achieved for  $n\text{HI} > 0.04$ ,  $\text{RPGI} > 0.15$ ,  $\text{VPEP} < 1200$ ,  $\text{AVNIR} > 2000$ , and  $\text{PAI} > 0.02$ . The accuracy of the HS physics-based satellite image segmentation on pixel-level is given in Tab. 1.

The higher user's accuracy might be explained by the fact that the coarse resolution of 30 m leads to mixed spectral signatures. Thus, pixels with only a small PCG contribution in the spectral response might not be detected which leads to a smaller producer's accuracy. Since the GT contains PCG locations nine months before the satellite acquisitions, an error was expected. Furthermore, the surface material of PCGs varies along the PCGs. The transparency of the plastic foil differs and PCGs with strong vegetation reflectance underneath a highly transparent foil might be more difficult to



detect. Due to this physics-based approach, the transferability to other regions is generally provided.

| <b>F1-Score</b> | <b>User's Accuracy</b> | <b>Producer's Accuracy</b> | <b>Overall Accuracy</b> |
|-----------------|------------------------|----------------------------|-------------------------|
| 71.1 %          | 81.8 %                 | 62.8 %                     | 99.8 %                  |

Tab. 1: Accuracy<sup>3</sup> of HS detection of PCG pins.

### 3.2 Multispectral ML model for plastic detection

The MS detection of PCGs with S2 data was performed with a data-driven ML approach, in contrast to the physics-based HS indices approach. Evaluation of the RF and ANN is shown in Tab. 2 for both, validation with HS pins and original GT data. The metrics were calculated for the test dataset only.

| <b>Model</b> | <b>Validation data</b> | <b>F1-Score</b> | <b>User. Acc.</b> | <b>Prod. Acc.</b> | <b>Overall Acc.</b> |
|--------------|------------------------|-----------------|-------------------|-------------------|---------------------|
| ANN          | Ground Truth           | 87.3 %          | 93.0 %            | 82.3 %            | 96.7 %              |
| ANN          | Hyperspectral Pin      | 81.8 %          | 69.7 %            | 99.1 %            | 94.0 %              |
| RF           | Ground Truth           | 77.3 %          | 99.4 %            | 63.2 %            | 92.7 %              |
| RF           | Hyperspectral Pin      | 88.7 %          | 84.5 %            | 93.4 %            | 95.8 %              |

Tab. 2: Accuracy of HS classification of PCG pins.

The ANN and RF model showed good performance with 81.8% and 88.7% F1-Score compared to the HS GT pin, respectively. Validated with the original GT, the RF achieved still good performance with F1-Score of 77.3%, while the ANN showed even better performance with F1-Score of 87.3%. This validates the method for HS generation of ML training data. Fig. 2 gives an example of the spatial prediction with the ANN segmentation. The ANN model was tuned to have a high producer's accuracy. By decreasing the threshold probability of the ANN model output for the binary classification, higher user's accuracies and lower producer's accuracies were obtained. Since the RF model was not fuzzy, no test with the binary classification threshold were performed for this approach. Due to the higher spatial resolution of S2, less area at the PCG boundaries showed spectral mixtures, which might explain the better performance of the ANN compared to the HS pins (Fig. 2).

<sup>3</sup> F1-Score: Harmonic mean of user's accuracy and producer's accuracy to balance out both metrics; User's Accuracy: probability that a pixel classified as PCG is a PCG pixel in the GT; Producer's Accuracy: probability that a pixel which is PCG in the GT, will be classified as such; Overall Accuracy: number of correctly classified pixels (PCGs and non-PCGs) divided by the total number of pixels.

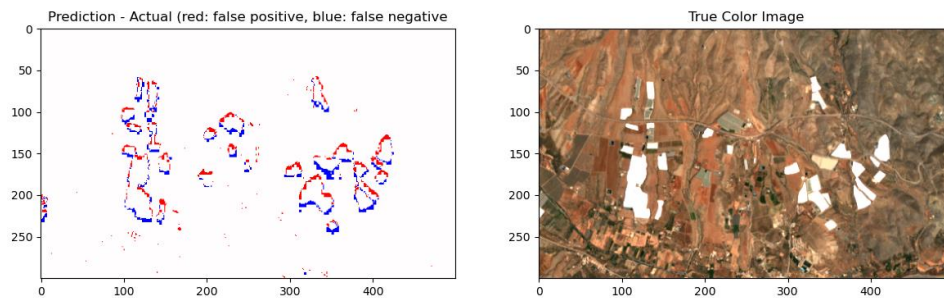


Fig. 2: PCG detection with ANN trained on HS derived GT. Left: false positives/false negatives indicating an offset between HS GT and S2. Right: S2 input data in true color.

## 4 Conclusions

This study presented a new workflow to use physics-based HS information to derive GT pins for the training of ML models using operationally available MS satellite data. This approach helps to provide essential data labels for data-driven ML models, if no real GT is available. Besides the use case of PCG monitoring, various further applications will be explored in the future. Nevertheless, for plastic monitoring it is necessary to further improve the quality of the HS derived training data with better indices, absorption depths, or radiative transfer model inversion. Also the ML models might be improved by using convolutional models (e.g. U-Net) to learn spatial patterns.

**Acknowledgements:** This research and development is funded by the Bavarian Ministry of Economic Affairs, Regional Development and Energy under the funding line BayVFP Förderlinie Mobilität-Raumfahrt within the project *HyperPin* as well as by the European Space Agency (ESA) project *INFER*.

### Bibliography



[Ji21] Ji, C. et al: Solar photovoltaic module detection using laboratory and airborne imaging spectroscopy data. *Remote Sensing of the Environment*, 266, 2021. doi: <https://doi.org/10.1016/j.rse.2021.112692>

[Ta21] Tasseron, P. et al.: Advancing Floating Macroplastic Detection from Space Using Experimental Hyperspectral Imagery. In: *Remote Sensing*, 13, 2021. doi: 10.3390/rs13122335.

[Ya17] Yang, D. et al.: Mapping plastic greenhouse with medium spatial resolution satellite data: Development of a new spectral index. In: *ISPRS Journal of Photogrammetry and Remote Sensing*, p. 47-60, 128, 2017.

[Yu20] Yuan, Q. et al.: Deep learning in environmental remote sensing: Achievements and challenges. In: *Remote Sensing of Environment*, 241, 2020. doi: 10.1016/j.rse.2020.111716.

## Digitalisierung als Beitrag zur Verbesserung des Tierwohls - die Sicht von Tierhaltenden in der Landwirtschaft

Miriam Kennade <sup>1</sup>, Laura Schmitz<sup>1</sup>, Carla Ollier<sup>1</sup> und Marcus Mergenthaler <sup>1</sup>

**Abstract:** Bei einer nachhaltigen und zielgerichteten Nutzung kann Digitalisierung auf betrieblicher Ebene einen wertvollen Beitrag für mehr Tierwohl leisten. Untersuchungen ergaben, dass zwar viele Landwirt:innen positive Auswirkungen der Digitalisierung auf das Tierwohl vermuten, selbst jedoch kaum digitale Tools einsetzen. Ziel der vorliegenden Untersuchung ist es, Einflussfaktoren auf die Digitalisierungsbewertung auf betrieblicher Ebene zu ermitteln. Im Ergebnis wirken sich vor allem die Erwerbsform und die Zukunftsorientierung der Befragten auf eine positive Bewertung der Digitalisierung zur Steigerung des Tierwohls aus. Diese Faktoren sollten neben stabilen Rahmenbedingungen für Investitionen bei der Weiterentwicklung und den Etablierungsstrategien digitaler Technologien besondere Berücksichtigung finden.

**Keywords:** Digitalisierung, Tierwohl, Bewertung, Einflussfaktoren, Nutzende

### 1 Einleitung

Die landwirtschaftliche Tierhaltung und das Tierwohl sind anhaltender Gegenstand fachlicher und öffentlicher Debatten [LM23]. Der positive Einfluss der Digitalisierung auf eine nachhaltigere Produktion und die Verbesserung des Tierwohls wurde bereits in verschiedenen Untersuchungen aufgegriffen [KG23]. Eine aktuelle Studie des Bitkom e.V. mit 500 Landwirt:innen ergab zudem, dass über 60 % durch Digitalisierung allgemein eine Steigerung des Tierwohls erwarten. Dennoch sind lediglich bei einem Drittel der Befragten bereits Farm- oder Herdenmanagementsysteme im Einsatz [RL22], was eine Diskrepanz zwischen allgemeiner Einstellung und empfundener Nützlichkeit sowie Adoption für den eigenen Betrieb anzeigt. Es ist damit entscheidend, Einflussfaktoren für den wahrgenommenen Nutzen von digitalen Tools zur Verbesserung des Tierwohls zu ermitteln, um deren tatsächlichen Einsatz in der landwirtschaftlichen Tierhaltung voranzutreiben. Dies betrifft nicht nur Hersteller von digitalen Lösungen, sondern auch Forschende und politische Entscheidungstragende.

Das Hauptziel dieser Untersuchung ist die Ermittlung der entscheidenden Faktoren, die die Wahrnehmung digitaler Technologien zur Steigerung des Tierwohls in der

---

<sup>1</sup> Fachhochschule Südwestfalen, Fachbereich Agrarwirtschaft, Lübecker Ring 2, 59494 Soest,

kennade.miriam@fh-swf.de,  <https://orcid.org/0009-0008-3507-9878> ;  
schmitz.laura@fh-swf.de; ollier.carla@fh-swf.de;

mergenthaler.marcus@fh-swf.de,  <https://orcid.org/0000-0002-7485-2383>

landwirtschaftlichen Tierhaltung beeinflussen. Damit sollen diese Faktoren zukünftig besser in den Entwicklungs- und Etablierungsprozess digitaler Lösungen integriert werden können, um sicherzustellen, dass sie den Bedürfnissen und Erwartungen der Landwirt:innen und Tierhalter:innen gerecht werden. Diese Erkenntnisse können schließlich einen Beitrag zur Förderung des Tierwohls und zur Steigerung der Effektivität und Nachhaltigkeit in der landwirtschaftlichen Tierhaltung leisten.

## 2 Methodisches Vorgehen

Im Winter 2022 wurde eine umfassende Online-Befragung mit insgesamt 619 Tierhaltenden in der Landwirtschaft in ganz Deutschland durchgeführt. Übergeordnetes Ziel dabei war es, die Einstellungen zur landwirtschaftlichen Tierhaltung aus der Sicht der Tierhaltenden selbst zu erfassen. Der Fragebogen aus 35 Fragen enthielt die Themenbereiche Betriebsangaben, Soziodemographie, eigene Tierhaltung sowie Einschätzungen und Bewertungen zum Tierwohl. In etwa die Hälfte der Stichprobe wurde durch ein Marktforschungsinstitut anhand vorgegebener, repräsentativer Quotierungen rekrutiert, die zweite Hälfte mithilfe von öffentlichen Organen, Fachmedien und Agrarbloggern. Der Fokus dieser Untersuchung liegt auf der Bewertung der Digitalisierung in Bezug auf das Tierwohl und die Einflussfaktoren darauf. Die Zustimmung bzw. Ablehnung zum Statement „*Digitalisierung auf meinem Betrieb ist förderlich für mehr Tierwohl*“ wurde anhand einer gleichverteilten 5-Punkte Likert Skala<sup>2</sup> gemessen. Für die Einflussfaktoren wurden jeweils die sich daraus ergebenden Teilstichproben einer bivariaten Analyse mittels eines unverbundenen T-Tests angenähert. Für die Ermittlung der Einflussfaktoren wurde aufgrund der Datengrundlage die Attributionsebene gewählt, da der Fokus auf der Einschätzung der Tierhaltenden gegenüber Digitalisierung zur Förderung des Tierwohls liegen sollte, für die damit nicht zwingend eigene Erfahrungen erforderlich waren.

## 3 Ergebnisse und Diskussion

### 3.1 Einordnung der Stichprobe

Die Einordnung der Stichprobe zur Online-Befragung (N = 619) ist in der folgenden Tabelle dargestellt (Tab. 1). Das durchschnittliche Alter und die Standardabweichung deuten auf eine breite Abdeckung verschiedener Altersklassen hin, was hinsichtlich des Alters für eine gewisse Repräsentativität in Bezug auf die landwirtschaftlichen Betriebsleitenden in DE spricht. Auch der Anteil nicht-männlicher Teilnehmender und ökologisch wirtschaftender Betriebe stellt sich ähnlich wie im Bundesdurchschnitt der landwirtschaftlichen Betriebsleitenden dar. Die Stichprobe ist tendenziell etwas höher

---

<sup>2</sup> 1= stimme gar nicht zu - 5= stimme voll und ganz zu

gebildet und bewirtschaftet größere Betriebe. Gleichmaßen sind vornehmlich Haupterwerbsbetriebe vertreten, was für die kommerziell rekrutierte Stichprobe Voraussetzung war. Dies muss bei der Interpretation der Ergebnisse Berücksichtigung finden. Die durchschnittliche Zustimmung zur Aussage „*Digitalisierung auf meinem Betrieb ist förderlich für mehr Tierwohl*“ lag in der Gesamtstichprobe bei  $3,32 \pm 1,21$ .

| Variable        | Ausprägung                                  | Mittelwert                         | DE-Ø <sup>3</sup> |
|-----------------|---|------------------------------------|-------------------|
| Alter           | Alter in Jahren                             | $47,69 \pm 11,97$<br>Median: 50    | > 45              |
| Geschlecht      | 1 wenn männlich;<br>ansonsten 0             | 0,86                               | 0,89              |
| Bildung         | 1 mit Hochschulabschluss;<br>ansonsten 0    | 0,31                               | 0,14              |
| Erwerbsform     | 1 im Haupterwerb;<br>ansonsten 0            | 0,92                               | 0,57              |
| Bewirtschaftung | 1 wenn konventionell;<br>ansonsten 0        | 0,90                               | 0,86              |
| Betriebsgröße   | Landwirtschaftliche<br>Nutzfläche in Hektar | $184,25 \pm 371,21$<br>Median: 100 | 64,13             |

Tab. 1: Einordnung der Stichprobe (N = 619)

### 3.2 Soziodemographische Einflussfaktoren

Bei der Unterteilung der Stichprobe in die älteren und jüngeren Partizipierenden (in Bezug zum Median) zeigt die Bewertung der Digitalisierung für das Tierwohl im eigenen Betrieb keine Unterschiede (Tab. 2). Eine ähnliche Studie zeigte dagegen schwach negative Korrelationen zwischen zunehmenden Alter und der Digitalisierungsbewertung [Mi19]. Die höher erwartete Bewertung der Digitalisierung von Landwirt:innen mit Hochschulabschluss bestätigt sich in der Untersuchung ebenfalls nicht. Ebenso ist kein Zusammenhang mit dem Geschlecht festzustellen. Hier zeigt sich, dass sich Hersteller und Officialstellen in ihren Beratungs- und Schulungskonzepten breit aufstellen und beispielsweise über verschiedene Formate versuchen sollten, die digitale Teilhabe für alle potentiellen Nutzenden zu ermöglichen.

### 3.3 Betriebsstrukturelle Einflussfaktoren

Die mittlere Zustimmung zur Förderlichkeit von Digitalisierung im eigenen Betrieb liegt bei den Haupterwerbsbetrieben bei  $3,36 \pm 1,20$ . Diese Bewertung ist signifikant höher als bei den Nebenerwerbsbetrieben mit  $2,81 \pm 1,21$ . Hier wurde u. U. das Potenzial, welches die Digitalisierung für die Förderung des Tierwohls bietet, auch gerade bei geringerer

<sup>3</sup> [St21]

Präsenz im Stall, wie es in vielen Nebenerwerbsbetrieben üblich ist, noch nicht erkannt. Die biologisch wirtschaftenden Betriebe sehen im Mittel in der Digitalisierung bei sich im Vergleich zu den konventionellen keinen geringeren oder größeren Beitrag zum Tierwohl. Ein Zusammenhang zwischen der Betriebsgröße und der Digitalisierungsbewertung lässt sich ebenfalls nicht ableiten (Tab. 2).

### 3.4 Zukunftsorientierung als Einflussfaktor

Zwischen der familiär gesicherten Zukunft des Betriebs und der Bewertung der Digitalisierung im Sinne des Tierwohls zeigt sich in der Stichprobe ein starker Zusammenhang. Ferner sind die Teilnehmenden, die in letzter Zeit in Technisierung und Automatisierung investiert haben, in ihrer Bewertung positiver. Diese Aspekte sprechen für zukunftsorientierte Betriebe, die die Vorteile der Digitalisierung vermutlich für den eigenen Betrieb zu nutzen wissen (Tab. 2).

| Variable                        | Ausprägung              | Mittlere Zustimmung Digitalisierung | p-Wert |
|---------------------------------|-------------------------|-------------------------------------|--------|
| Alter                           | <50 Jahre               | 3,29±1,24                           | 0,592  |
|                                 | >50 Jahre               | 3,34±1,17                           |        |
| Geschlecht                      | männlich                | 3,32±1,19                           | 0,904  |
|                                 | andere                  | 3,33±1,28                           |        |
| Bildung                         | Hochschulabschluss      | 3,35±1,09                           | 0,629  |
|                                 | Ohne Hochschulabschluss | 3,30±1,25                           |        |
| Erwerbsform                     | Haupterwerb             | 3,36±1,20                           | 0,004  |
|                                 | Nebenerwerb             | 2,81±1,21                           |        |
| Bewirtschaftung                 | konventionell           | 3,34±1,20                           | 0,182  |
|                                 | ökologisch              | 3,11±1,27                           |        |
| Betriebsgröße                   | <100 Hektar             | 3,27±1,22                           | 0,338  |
|                                 | >100 Hektar             | 3,37±1,19                           |        |
| Familiäre Hofnachfolge          | Gesichert               | 3,40±1,22                           | 0,011  |
|                                 | Nicht gesichert         | 3,14±1,15                           |        |
| Investition in Automat./ Techn. | Getätigt                | 3,79±1,15                           | 0,002  |
|                                 | Nicht getätigt          | 3,27±1,20                           |        |

Tab. 2: Mittlere Zustimmungswerte zur förderlichen Wirkung von Digitalisierung im eigenen Betrieb in Abhängigkeit verschiedener Einflussvariablen (N=619)

## 4 Schlussfolgerungen und weiterer Forschungsbedarf

Zusammenfassend wirken sich vor allem die Erwerbsform und die Zukunftsorientierung der Landwirt:innen positiv auf eine Bewertung der Digitalisierung zur Steigerung des Tierwohls aus. Neben der gesicherten familiären Hofnachfolge wird das auch an vergangenen Investitionen in Automatisierung und Technisierung festgemacht. Deshalb sollte das Thema Digitalisierung zur Förderung des Tierwohls insbesondere dann aufgegriffen und behandelt werden, wenn andere Zukunftsthemen der Tierhaltung fokussiert werden. Um die Vorteile der Digitalisierung zur Förderung des Tierwohls auch für Betriebe mit weniger starker Zukunftsausrichtung und im Nebenerwerb zugänglich zu machen, bedarf es technischer Lösungen mit noch höherer Nutzerfreundlichkeit und geringeren Einstiegshürden. Hier sind Hersteller gefordert, noch mehr in die Entwicklung für eine einfache und unabhängige Handhabbarkeit zu investieren.

Gleichermaßen zeigen jedoch auch die Faktoren, die sich in dieser Untersuchung nicht als Einflüsse erwiesen haben, dass das Feld an potenziellen Nutzenden digitaler Technologien groß und facettenreich ist. Unabhängig von sozio-demographischen Merkmalen sollten alle Zielgruppen – neben stabilen Rahmenbedingungen für Investitionen – bei der Weiterentwicklung und den Etablierungsstrategien digitaler Technologien besondere Berücksichtigung finden.

Limitierend an den Ergebnissen ist, dass sich die Einschätzung der Digitalisierung als Instrument für mehr Tierwohl in der Befragung auf den eigenen Betrieb bezog. Eine allgemeine Bewertung bezogen auf die Tierhaltung könnte möglicherweise anders aussehen. Die Daten stammen aus einer größer angelegten Befragung mit anderer Zielsetzung. Das Thema Digitalisierung wurde hier nur am Rande abgefragt, sodass bspw. der Digitalisierungsgrad des eigenen Betriebes nicht abgefragt wurde, welcher die Interpretation der Ergebnisse erleichtert hätte. Aufgrund der begrenzt verfügbaren weiteren Informationen bewegt sich diese Untersuchung vornehmlich auf der Attributionsebene, was die Einstellung zur Digitalisierung bei den Befragten gut abbildet, jedoch weitere Forschung zur tatsächlichen Wirkung auf das Tierwohl unabdingbar macht. Ferner sollten in künftigen Untersuchungen neben der Betriebsgröße weitere strukturelle Merkmale berücksichtigt werden, um die potentiellen Einflussfaktoren auf die Bewertung der Digitalisierung auf betrieblicher Ebene zu spezifizieren und konkrete Maßnahmen zu deren Hemmung oder Förderung abzuleiten. Auch vertiefende Untersuchungen zu den Gründen für die Einschätzung sind geboten.

Unter der Voraussetzung, dass Digitalisierung tatsächlich der Verbesserung des Tierwohls umfassend und substanziell auf allen landwirtschaftlichen Betrieben nutzen kann, gilt es die Gründe und Vorbehalte bei denjenigen Tierhaltenden besser zu verstehen, die geringe Zustimmungswerte für die Aussage haben. Wichtig wird es dabei auch sein, einer möglichen „Digitalisierungsmüdigkeit“ [De23] entgegenzuwirken, bei der digitale Tools vor allem durch einen hohen Aufwand in der Datenpflege gekennzeichnet sind und der Nutzen sich nicht intuitiv erschließt oder aus Mangel an Schnittstellen verschiedene Systeme parallel genutzt werden müssen. Um eine nachhaltige Nutzung zu erreichen

[KZ23], wird bei Weiterentwicklung und Etablierungsstrategien digitaler Tools vermutlich ihre Nutzbarkeit durch alle involvierten Personen und ihre Nützlichkeit in Betrieben unabhängig von Art und Größe stärker forciert werden müssen. Ferner gilt es für die Politik, stabile Rahmenbedingungen zu schaffen und zukunftsgerichtete Investitionen in Digitalisierung und Tierwohl zu fördern. Dabei ist insbesondere zu prüfen, ob es neben der Förderung für Stallbauten und Stallhaltungstechnik auch sinnvoll sein kann, die Investitionen in digitale Lösungen als eigenständigen Fördertatbestand in Betracht zu ziehen. Gerade für Nebenerwerbsbetriebe und Betriebe ohne gesicherte Betriebsnachfolge könnten damit auch weniger kapitalintensive Investitionen zur Verbesserung des Tierwohl ermöglicht werden, die sich insbesondere durch kürzere Abschreibungszeiträume auszeichnen.

**Danksagung und Förderhinweis:** Die Autor:innen danken allen Landwirt:innen, die sich an der Befragung beteiligt haben, sowie allen Personen und Organisationen, die die Rekrutierung unterstützt haben. Die Daten wurden im Rahmen des Forschungsprojektes „Social Lab 2 – Akzeptanz durch Innovation“ erhoben, welches vom Bundesministerium für Ernährung und Landwirtschaft (BMEL) aufgrund eines Beschlusses des Deutschen Bundestages finanziert wurde.

#### Literaturverzeichnis

- [De23] Demmelhuber, K.: Welche Geschäftsrisiken sehen Unternehmen ab 2023?, ifo Schnelldienst, 76(06), S. 29-35, 2023.
- [KG23] Kleen, J.L.; Guatteo, R.: Precision Livestock Farming: What Does It Contain and What Are the Perspectives? *Animals*, 13, 779, 2023.
- [KZ23] Krapscha, R.; Ziuliani, B.: Digitalisierung und ihre ökologischen Auswirkungen. Ein Interview mit Barbara Zuliani. *Magazin erwachsenenbildung.at*, 49, S. 75-79, 2023.
- [LM23] Lendle, M.; Meinders, L.: AFC-Issue-Monitor Report 2023 - Kritische Themen und Trends in der Agrar- und Ernährungsbranche., 2023.
- [Mi19] Michels, M. et al.: Zur Zahlungsbereitschaft von Landwirten für Schulungen zur Digitalisierung. *Berichte über Landwirtschaft*, Band 97 Heft 1, 2019.
- [RM22] Rohleder, B.; Meinel, T.: Die Digitalisierung der Landwirtschaft. Branchenverband der deutschen Informations- und Telekommunikationsbranche e.V., 2022.
- [St21] Statistisches Bundesamt: Ergebnisse der Landwirtschaftszählung 2020, 2021.



## „LeguDash“ – ein Prototyp eines Dashboards für mehr Transparenz am Leguminosenmarkt

Dennis Köpp<sup>1</sup>, Hendrik Bertram<sup>1</sup>, Bruno Kezeya<sup>1</sup>, Petra Zerhusen-Blecher<sup>1</sup>,  
Tanja Schäfer<sup>1</sup>, Mehmet Gültas<sup>1</sup> und Marcus Mergenthaler<sup>1</sup>

**Abstract:** In Deutschland verzeichnet man einen wachsenden Trend in der Nachfrage nach heimisch produzierten Körnerleguminosen. Allerdings ist der Markt für Körnerleguminosen intransparent, was erhebliche Unsicherheit für Landwirt:innen bei der Planung ihrer Anbauflächen verursacht. Um dieser mangelnden Transparenz des Marktes zu begegnen und neuen Marktteilnehmenden den Eintritt zu erleichtern, wurde das Leguminosen-Netzwerk ins Leben gerufen. Im Rahmen dieses Projekts wurde das Dashboard „LeguDash“ entwickelt, das zukünftig wichtige Marktdaten und Preisinformationen für Körnerleguminosen bereitstellen soll. Das Hauptziel von LeguDash besteht darin, nicht nur die Preistransparenz zu erhöhen, sondern auch den Wert und die Bedeutung von Körnerleguminosen in der Agrarwirtschaft zu verdeutlichen. Dieses Instrument bietet Landwirt:innen, Händler:innen und anderen Akteur:innen entlang der Wertschöpfungskette die Möglichkeit, auf umfassende Informationen zuzugreifen, die für die Preisabschätzung und die Marktorientierung für Körnerleguminosen unerlässlich sind. Die Implementierung von LeguDash soll zur Verbesserung der Marktsituation für Körnerleguminosen in Deutschland beitragen, indem es den Akteur:innen im Agrarsektor ermöglicht, fundierte Entscheidungen zu treffen und ihre Geschäftsstrategien zu optimieren. Zukünftig ist geplant, die Befragung von Akteur:innen in die Weiterentwicklung von LeguDash einzubeziehen und das Werkzeug in die Praxis einzuführen.

**Keywords:** Leguminosen, Dashboard, Datensammlung, LeguNet, LeguDash, Preisschätzungstools

### 1 Einleitung

Die Bedeutung von großkörnigen Leguminosen im Anbau sowie in der tierischen und menschlichen Verwertung hat in den letzten Jahren zugenommen [RK20]. Trotz dieses Wachstums sind die Märkte für Körnerleguminosen stark fragmentiert und intransparent [MH22; Ke18]. Eine resultierende Informationsasymmetrie über die aktuelle Preislage bei Körnerleguminosen führt zu einem Verhandlungsvorteil der Händler:innen gegenüber den Landwirt:innen, was den Neueinstieg in den Markt erschwert [Ke22]. Die Transparenz von Preisen für landwirtschaftliche Erzeugnisse spielt eine entscheidende Rolle in der Agrarwirtschaft und beeinflusst maßgeblich die Effizienz der Agrarmärkte. Sie ermöglicht eine Anpassung von Angebot und Nachfrage, was zur Verhinderung von Über- oder Unterangeboten beiträgt. Dies wiederum trägt wesentlich zur Stabilität des Agrarmarktes bei Preistransparenz bei. Es fördert die Entstehung eines wettbewerbsfähigen Agrarmarktes,

---

<sup>1</sup> Fachhochschule Südwestfalen, Fachbereich Agrarwirtschaft, Lübecker Ring 2, 59494 Soest,  
koepp.dennis@fh-swf.de, bertram.hendrik@fh-swf.de, zerhusen-blecher.petra@fh-swf.de,  
schaefer.tanja@fh-swf.de, gueltas.mehmet@fh-swf.de, mergenthaler.marcus@fh-swf.de

indem sie sicherstellt, dass die Preisbildung auf transparenten und nachvollziehbaren Parametern basiert. Diese Gewährleistung zielt darauf ab, unfaire Handelspraktiken und Marktmanipulationen zu verhindern, die insbesondere kleinere Akteur:innen in der Agrarwirtschaft benachteiligen könnten [Mo13].

Für Landwirt:innen ist Preistransparenz als Grundlage für Planung und Risikomanagement unverzichtbar. Durch ein klares Verständnis der aktuellen Marktpreise sowie Prognosen für zukünftige Preise können Landwirt:innen ihre Produktionspläne präziser gestalten und Risiken effektiver managen. Diese Erkenntnisse ermöglichen es ihnen, ihre Anbaustrategien anzupassen und flexibel auf Veränderungen in der Nachfrage und den Preisen zu reagieren, was ihre Rentabilität steigern kann [CS15]. Um Akteur:innen eine bessere Verhandlungsbasis zu schaffen, wurde im Projekt „Leguminosen-Netzwerk“ (LeguNet) der Prototyp eines Leguminosen-spezifischen Dashboards entwickelt. Das Dashboard (LeguDash) soll den Akteur:innen wichtige Kennzahlen liefern. Die verwendeten Preisindikatoren basieren auf dem Schätzmodell einer Regressionsanalyse sowie auf dem Futterwert nach der Methode von Löhr. Einer dieser speziellen Preisindikatoren wurde im Fachbereich Agrarwirtschaft an der Fachhochschule Südwestfalen in Soest entwickelt und aktualisiert [Ke22]. Preisindikatoren basieren auf historischen Daten. Sie können und sollen keinen Ersatz für tatsächliche Notierungen von Körnerleguminosen darstellen.

Das Hauptziel dieser Arbeit besteht darin, Akteur:innen entlang der Wertschöpfungskette ein zukunftsorientiertes Modell zur Preisabschätzung für Körnerleguminosen zur Verfügung zu stellen. Damit soll ein Beitrag geleistet werden, die Märkte für Leguminosen transparenter zu machen und Akteur:innen dadurch einen einfacheren Marktzugang zu ermöglichen.

## 2 Material und Methoden

Aufbauend auf ersten Befragungen wurden die Problematiken im Bereich Markttransparenz im Leguminosensektor analysiert, um qualitative Ergebnisse zu erzielen [Ke22]. Die Schwerpunkte der erarbeiteten Lösungsansätze wurden auf die im Markt identifizierten Fragen sowie Schwierigkeiten zur Preisentwicklung gerichtet. Für die Datensammlung, die für das Dashboard erforderlich ist, wurde eine sorgfältige Auswahl verschiedener Informationsplattformen durchgeführt. Diese umfassen Anbaudaten sowie Export- und Importmengen aus dem statistischen Amt der Europäischen Union (Eurostat) und dem statistischen Bundesamt Deutschland (Destatis) sowie Preisinformationen der Agrarmarkt Informations-Gesellschaft (AMI). Hinsichtlich einer zielgerichteten und passenden Darstellung der Information erfolgten diverse Abwägungen bezüglich der Form und Auswahl der Graphiken und der Einbindung von Zusatzinformationen. Im Vordergrund stand die praktische Nützlichkeit und Benutzbarkeit des Dashboards. Dementsprechend fand die Entwicklung des Prototypen sowie dessen Anforderungen unter Rücksprache mit Interessenvertretern aus LeguNet statt. Zum schnellen Prototypenbau wird das Dashboard gegen-

wärtig mit Hilfe des Python-Frameworks Django implementiert und umfasst eine Webseite. Zur Datensammlung werden diverse Dienste genutzt, die Daten entweder durch die Extraktion aus öffentlich zugänglichen Web-Schnittstellen sammeln oder mittels der BeautifulSoup-Bibliothek Informationen aus Webseiten akquirieren und anschließend in einer SQLite-Datenbank speichern. Zur visuellen Aufbereitung im Browser wird das Bootstrap-Framework genutzt. Die Erstellung von Graphiken erfolgt unter Verwendung der umfangreichen Graphik-Bibliothek Plotly. Im Prototypen wurde ein besonderer Wert auf die Einfachheit und Erweiterbarkeit durch weitere Datenintegration gelegt.

### 3 Ergebnisse

Das Dashboard mit der zugrundeliegenden Software dient als Datensammlung und zeigt Schlüsselinformationen für Deutschland übersichtlich an, einschließlich Marktdaten wie z. B. Erntemengen oder Anbauflächen, Preisdaten über Import und Export sowie Preisprognosen. Die einfache technische Gestaltung lässt eine schnelle Integration von zusätzlichen Daten und Datenquellen, welche bereits in Planung sind, mit geringem Zusatzaufwand zu. Es gibt in der Navigationsleiste separate Abschnitte mit Übersichten für jeden Bereich, jeweils mit interaktiven Diagrammen und erklärenden Beschreibungen. Abbildung 1 stellt einen Ausschnitt aus dem Dashboard beispielhaft dar. In jedem Diagramm sind aktuelle Entwicklungstrends angelegt.

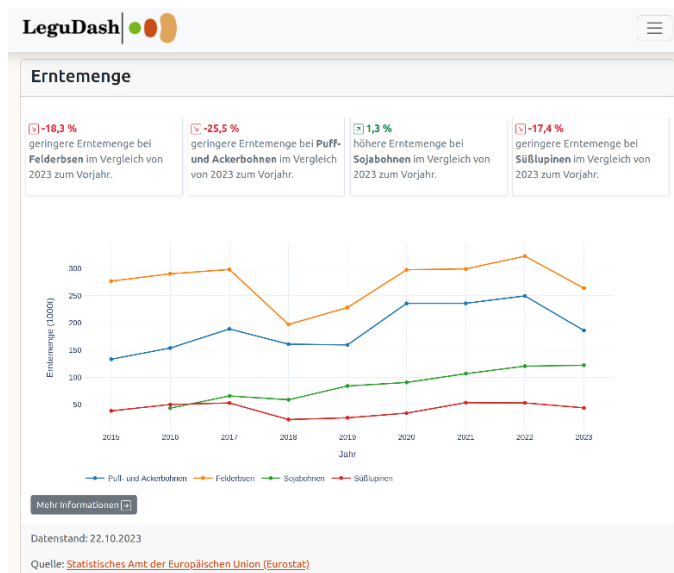


Abb. 1: Beispielhafte Darstellung einer Kachel mit Erntemenge-Daten und Trend-Anzeige im Leguminosen-Dashboard (LeguDash)

Zusätzliche Informationen und graphische Darstellungen sind unter den Diagrammen referenziert. Eine Großansicht einer beispielhaften Graphik mit Zusatzinformation ist in Abbildung 2 zu sehen. In dem obigen Reiter der Abbildung lassen sich verschiedene Darstellungsarten auswählen und sowohl Graphiken als auch Tabellen sind herunterladbar.




Abb. 2: Beispielhafte Darstellung einer Großansicht von Anbaufläche-Daten mit Zusatzinformationen in LeguDash

Es gibt drei Reiter für die Abschnitte Marktkennzahlen, Preisinformationen und Preisprognosen, und jeder dieser Abschnitte besteht aus mehreren Kacheln (vgl. Abb. 1 und Abb. 3). Im Preisprognose-Abschnitt liegen Darstellungen für das Löhrr'sche Austauschverfahren und eine Regressionsanalyse (siehe Abb. 3), welche sich auf Börsenpreise stützen, vor, um grobe Preisvorstellungen für Landwirt:innen zu bieten. Die Berechnungen der Regressionsmodelle basieren auf den zuvor genannten Datenquellen von 2016 bis 2023 zur Preisinformation und liefern die folgenden Formeln:

$$P.KE = 15,38 + 0,63 * P.FW + 0,22 * P.SES$$

$$P.AB = 12,03 + 0,92 * P.FW + 0,06 * P.SES$$

$$P.LU = 27,77 + 0,78 * P.FW + 0,14 * P.SES$$

Wobei P.KE = Preis Körnererbse; P.AB = Preis Ackerbohne; P.LU = Preis Stülplupine; P.FW = Preis Futterweizen; P.SES = Preis Soja Extraktionsschrot. Angaben in €/t.

Zu beachten ist, dass es sich um Schätzwerte handelt, welche als unverbindliche Orientierungshilfe dienen. Aufgrund fehlender öffentlicher Preisdaten sind die Preisprognosen besonders relevant.

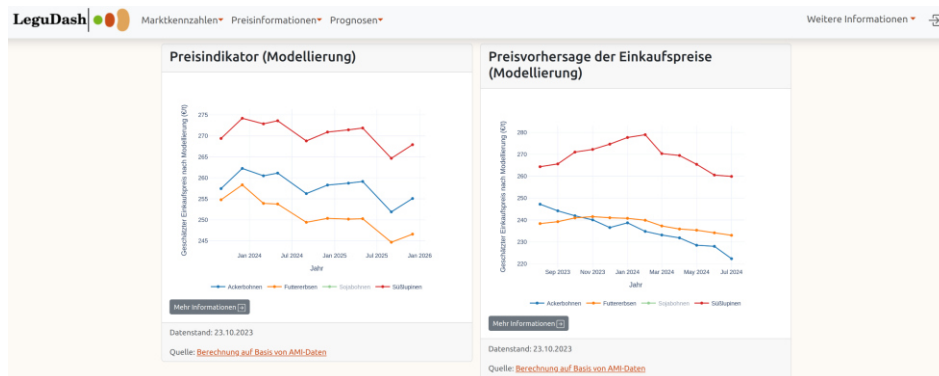


Abb. 3: Beispielhafte Darstellung der Preisprognosen in LeguDash

#### 4 Diskussion und Aussicht

LeguDash könnte eine Möglichkeit sein, Akteur:innen beim Handel mit Leguminosen eine stärkere Verhandlungsbasis zu geben. Die Preistransparenz trägt dazu bei, das Vertrauen in die gesamte Lebensmittelversorgungskette zu stärken [MMJ14].

Die methodische Herangehensweise und Schätzung von Preisindikatoren im Bereich der Leguminosen stellen eine Pionierarbeit dar. Da bisher wenig beobachtete Marktpreise in diesem Bereich vorliegen, gestaltet sich der Vergleich unterschiedlicher methodischer Ansätze als schwierig. Das Leguminosen-Dashboard LeguDash kann nach einer möglichen Etablierung zukünftig eine Orientierungshilfe sowohl für den Anbau als auch für die Vermarktung von Leguminosen darstellen. LeguDash könnte einen Anreiz bieten, die Marktpreisberichterstattung zu verbessern, wenn Marktakteur:innen die Schätzwerte des Modells nicht genügen sollten und belastbarere Werte notwendig werden.

In vorhandenen Datensätzen wird keine Unterscheidung zwischen ökologischen und konventionellen Leguminosen vorgenommen. Eine mögliche Verbesserung könnte darin bestehen, durchschnittlich übliche Preis auf- und -abschläge von ökologischen und konventionellen Produkten darzustellen. Zu diesem Zweck ist im Rahmen des Projekts LeguNet eine Befragung der beteiligten Demonstrationsbetriebe über ihre Leguminosenvermarktung in Arbeit. Auf Grundlage dieser Datenerhebung ist eine differenzierte Darstellung von konventionellem und ökologischem Anbau ausstehend. Mit der zunehmenden Datenerhebung zu Körnerleguminosen und der Nachfrage nach Milch- und Fleischersatzprodukten wird zukünftig im LeguNet darauf hingearbeitet, dass eine größere Anzahl an Betrieben zur Datentransparenz beitragen, um einen belastbaren Umfang von Meldungen zu

Leguminosenpreisen im konventionellen und ökologischen Bereich bieten zu können. Daher kann eine kooperative Zusammenarbeit zwischen staatlichen Institutionen, Branchenorganisationen und privaten Einrichtungen von entscheidender Bedeutung sein, um regelmäßig aktualisierte Preisinformationen zu sammeln und der Öffentlichkeit zugänglich zu machen. Idealerweise erfolgt die Bereitstellung dieser Daten auf einer spezialisierten Plattform, die als leicht zugängliche Informationsquelle für verschiedene Interessengruppen dient (vgl. [Ke22]). Zu diesem Zweck wurde LeguDash entwickelt. Um den Nutzen und die Stichhaltigkeit des Dashboards zu prüfen und Optionen einer zukünftigen Trägerschaft zu eruieren, sind Befragungen von Expert:innen sowie deren Auswertung geplant.

#### Literaturverzeichnis

- [CS15] Courtois, P., Subervie, J.: Farmer bargaining power and market information services. *American Journal of Agricultural Economics*, 97(3), 953-977, 2015.
- [Ke18] Kezeya, B. et al.: Möglichkeiten zur Bildung von verwertungsorientierten Preisindikatoren für Futtererbsen und Ackerbohnen im Vergleich zur veröffentlichten Marktpreisberichterstattung, *Berichte über Landwirtschaft, Zeitschrift für Agrarpolitik und Landwirtschaft*, Band 96, Heft 3, 2018. <https://buel.bmel.de/index.php/buel/article/view/226>.
- [Ke22] Kezeya, B. et al.: Verwertungsdifferenzierte Preisberichterstattung Futtererbsen und Ackerbohnen: Aktualisierung der Soester Preisindikatoren für Körnerleguminosen. *Forschungsnotiz des Fachbereichs Agrarwirtschaft, Soest*. Nr. 06, 2022.
- [MMJ14] Magesa, M.M., Michael, K., Jesuk, K.: Agricultural Market Information Services in Developing Countries: A Review. *Advances in Computer Science: An International Journal*, 3, 38-47, 2014.
- [Mo13] Molnár, A. et al.: Price transparency as a prerequisite for fair competition: the case of the European food prices monitoring tool. *The ethics and economics of agrifood competition*, 243-261, 2013.
- [MH22] Mittag, F., Hess, S.: „Der Markt für Körnerleguminosen in Deutschland – ein fragmentierter Markt?“, 62nd Annual Conference, 329594, German Association of Agricultural Economists, Stuttgart, 2022.
- [RK20] Rempe, C., Kirk-Mechtel, M.: Pflanzliche Alternative zu Fleisch. Seitan, Tofu, Lupino, Quorn – das „Who’s who“ der Fleischalternativen, Bundeszentrum für Ernährung, Bonn, <https://www.bzfe.de/nachhaltiger-konsum/orientierung-beim-einkauf/fleischer-satzprodukte/>, 2023, abgerufen am 19.01.2024.

## Assimilation von satellitenbasierten Reflexionsmessungen in einem Informationssystem für einen modernen Hopfenbaubetrieb

Hubert Linseisen<sup>1</sup>, Ioannis Manakos<sup>2</sup>, Eleftherios Katsikis<sup>2</sup> und Anastasios Delopoulos<sup>3</sup>

**Abstract:** Ziel des Artikels ist es, ortsbasierte Fernerkundungstechnologien verstärkt auch in die Praxis des Hopfenbaus zu bringen. Einleitend wird gezeigt, wie hierfür ein datenbasiertes Informationssystem mit Software und Datentransfer ausgestaltet sein muss. Der Schwerpunkt des Beitrags ist das Stickstoffmonitoring und die Ertragsschätzung im Hopfenbau durch Fernerkundungsdaten. Hierzu wurden Daten aus den letzten drei Jahren für einen Hopfenbaubetrieb aus der Hallertau ausgewertet. Gezeigt werden erste Schritte, welchen Beitrag hierbei die Fernerkundung leisten kann. Eine Diskussion mit Ausblick rundet den Beitrag ab.

**Keywords:** Hopfenbau, Fernerkundung, Informationssystem, GIS, GPS

### 1 Einleitung

Hopfen wird fast ausschließlich zur Bierproduktion verwendet. Weltweit werden auf gut 60 000 Hektar v. a. in den USA und Deutschland Hopfen angebaut. Die deutschen Anbaugebiete sind die Hallertau, Tettngang, Elbe-Saale und Spalt. Hopfen ist eine Dauerkultur. Die Stöcke werden in Reihen angelegt. Etwa 7 Meter hohe Säulen werden aufgestellt, an denen ein Eisengerüst befestigt wird. An das Eisengerüst werden Drähte befestigt, an denen die Pflanzen hochwachsen. Geerntet werden nur die nicht befruchteten weiblichen Blütenstände. Hopfen wächst äußerst schnell. Beginnend Anfang Mai wird die Gerüsthöhe schon Ende Juni/Anfang Juli erreicht.

Ein modernes Informationssystem für einen Hopfenbaubetrieb hat bestehende und zukünftige Anforderungen datentechnisch zu meistern. So sind hochwertige Geoinformationssysteme unerlässlich, um Daten der Fernerkundung mit u. a. Höhenmodellen, Datenlagen der Landwirtschaftsverwaltung zu halten und miteinander zu verknüpfen. Verknüpfungspunkt des Informationssystems sind die durch GPS ermittelten x-, y- und z-Koordinaten. Der Einsatz von GPS-Technologie im Hopfenbau ist aber noch überschaubar. Erfolgreich werden bereits beim Aufstellen der Gerüstanlagen und bei der

---

<sup>1</sup> Landwirtschaftsberater, Breitenwiese 6, 85283 Wolnzach, Hubert.Linseisen@web.de

<sup>2</sup> Information Technologies Institute, Centre for Research and Technology Hellas (CERTH), 6 km Harilaou-Thermi Rd., 57001, Thessaloniki, Greece, imanakos@iti.gr; lefkats@iti.gr

<sup>3</sup> Information Processing Laboratory, Department of Electrical and Computer Engineering, Aristotle University of Thessaloniki, Information Processing Lab, AUTH Campus, GR-54124, Thessaloniki, Greece, antelopo@ece.auth.gr

Bepflanzung GPS-Systeme eingesetzt [Fu23]. Der Einsatz von GPS-Trackern bei Abreißgeräten wurde zur Ermittlung von teilflächenspezifischen Ertragskarten getestet [La10]. Durch Auswertungen sind Aussagen u. a. über die Erntemenge, die Lage der abgeernteten Reihen und die Fahrzeiten möglich. Weiterhin sind Datenbanken erforderlich, um z. B. Wetterdaten zu speichern und betriebswirtschaftliche und ökologische Auswertungen zu speisen. Bewässerungscomputer mit ihrer Software sind in das Gesamtsystem zu integrieren. ISOBUS-Dateien für etwaige Anbaugeräte sind zu erstellen. Diese sind z. B. beim Düngerstreuen an die Besonderheiten im Hopfenbau anzupassen. So kann durch die derzeitige Software noch nicht dargestellt werden, wenn nur auf den Bifang gestreut wird [Kv22]. Ziel ist weiterhin auch für die Praxis, datentechnisch die Einzelpflanze ansprechen zu können. Dies ist derzeit schon v. a. im Versuchswesen interessant. Derzeit müssen die Pflanzen i.d.R. noch arbeitsaufwendig durch tragbare GPS-Vermessungssysteme lokalisiert werden. Probleme bereiten bei den dargestellten Komponenten die z. T. unterschiedlich verwendeten Datenformate. Wegen der Komplexität der dargestellten Software müsste diese teilweise überbetrieblich eingesetzt werden.

## 2 Reflexionsmessungen im Hopfenbau

Ein Schwerpunkt der Darstellung sind zukünftige Verbesserungen des Stickstoffmonitorings und der Ertragserwartung von Hopfenpflanzen mit Hilfe von georeferenzierten, multispektralen Aufnahmen. Gesetzliche Regelungen führen auch im Hopfenbau immer weiter dazu, dass v. a. Stickstoff nur noch begrenzt eingesetzt werden kann. Auch im Hopfenbau werden N-Sensoren getestet. Je Hopfensorte ist dabei mit unterschiedlichen Reflexionskurven zu kalkulieren [Lu23]. Von Waldinger wurden Spektralmessungen bei der gängigen Sorte Herkules in einem Hopfengarten mit Bewässerung in drei verschiedenen Messhöhen durchgeführt. Die Reflexion des Pflanzenbestandes im üblichen Wellenlängenbereich von 325 bis 940 nm wurde dabei erfasst. Es konnten gute Korrelationen zu den Parametern Trockenmasse und damit dem Ertrag, N-Gehalt und zur N-Aufnahme sowie Stickstoffversorgung durch die ermittelten Vegetationsindizes festgestellt werden. Bei den Untersuchungen zeigte sich, dass u. a. der Hauptwendepunkt, im Englischen REIP (Red Edge Inflection Point) genannt, in mittlerer und oberer Messhöhe gut den N-Gehalt und die N-Aufnahme darstellen kann. So hatte der REIP am 20. Juni, kurz vor der 3. N-Gabe, bei mittlerer Messhöhe eine Korrelation von 0,75 zur Stickstoffaufnahme [Wa19; St21]. Die Korrelationen Ende Mai, vor der 2. N-Gabe, müssen durch weitere Versuche noch verbessert werden.

Zu prüfen ist, ob auch im Hopfenbau durch fast in Echtzeit verfügbare Satellitenbilder Messungen am Boden ersetzt oder zumindest ergänzt werden können. Auch die Ermittlung der Höhe der Hopfenpflanze könnte in die Entscheidung der N-Düngegabenhöhe einfließen. Dies könnte in der Zukunft arbeitswirtschaftliche Erleichterungen bei der Bestandsbeurteilung bringen.



So wurden als erster Schritt 43 Satellitenbilder jeweils mit Pixeln, die für eine räumliche Auflösung von 10 Meter x 10 Meter stehen, ausgewertet. Die Daten stammen aus dem Zeitraum 25. Februar 2021 bis 21. August 2023. Zuerst wurde ein markanter Hopfengarten („Viehweide Umbruch“), für den mehrere georeferenzierte Datenlagen vorhanden sind, für den Betrieb Stefan Linseisen in Weikenhausen mit der Sorte Herkules ausgewertet (Abb. 1).




Abb. 1: Auswertungsübersicht von 43 Satellitendaten für den Hopfengarten Viehweide Umbruch (y-Achse links: REIP in nm; y-Achse rechts: Standardabweichung in nm; x-Achse: Datum)

Anfang Juli wird in der Regel die Gerüsthöhe erreicht. Durch die Seitenarmbildung erhält die Hopfenpflanze eine tonnige Form. Von oben gesehen sind der Boden und die Fahrspuren dann kaum mehr sichtbar. Der REIP steigt im Laufe der Vegetationsperiode. Da im Juli und August nur noch die Pflanzen sichtbar sind, ist hier auch die Standardabweichung geringer (Tab. 1).

| Zeitraum         | durchschnittl. REIP | durchschnittl. Standardabweichung |
|------------------|---------------------|-----------------------------------|
| Mai/Juni 2021    | 714,5               | 3,8                               |
| Juli/August 2021 | 721,8               | 1,2                               |
| Mai/Juni 2022    | 713,7               | 3,0                               |
| Juli/August 2022 | 718,5               | 2,7                               |
| Mai/Juni 2023    | 717,8               | 2,0                               |
| Juli/August 2023 | 719,3               | 2,0                               |

Tab. 1: REIP in nm und Standardabweichung in nm bei unterschiedlichen Zeiträumen beim Hopfengarten Viehweide Umbruch

Tendenziell konnten mit der Höhe des REIP u. a. im Juli und August im Hopfengarten Viehweide Umbruch mit einem Bestimmtheitsmaß von 0,85 auf den Ertrag Rückschlüsse gezogen werden. Ein Rückgang des REIP im August, der bei den Reflexionsmessungen an der Pflanze festgestellt werden konnte, war bei dieser Datenbasis aber nicht feststellbar [Wa19]. Auch die Steigung des REIP kann nach diesen vorläufigen Daten im Hopfen gut den Ertrag ex ante und ex post abbilden. Das Bestimmtheitsmaß für die Daten schon im Mai und Juni war bei 0,85 (siehe Abb. 2; [Ge16; MKS22]).




Abb. 2: Die Steigerung des REIP (y-Achse) in Abhängigkeit vom Ertrag (x-Achse in kg/ha) im Hopfengarten Viehweide Umbruch

Als zweiter Schritt wurden weitere Felder in die Untersuchungen einbezogen. Ausgangsbasis für die weiteren Berechnungen war eine durch den Landwirt erstellte Ertragspotenzialkarte. Als Attribute der Karte sind die Sorte und die durchschnittlichen Erträge je Sorte der Jahre 2021, 2022 und 2023 hinterlegt. Errechnet wurden REIP-Größen für Felder mit den gängigen Sorten Tradition, Perle und Herkules. Diese Auswertungen sind noch nicht endgültig abgeschlossen. Für jedes Pixel wurde eine lineare Regressionsanalyse für die Zeiträume Mai und Juni und Juni und Juli durchgeführt, um eine Trendlinie für die REIP-Größen zu ermitteln. Die REIP-Werte wurden auf der vertikalen Achse angeordnet, jeder einzelne Tag des Betrachtungszeitraumes auf der horizontalen Achse. Diese Vorgehensweise erlaubt ein indirektes Monitoring des Pflanzenwachstums und eine Verknüpfung von Messungen, die am Boden erhoben wurden. Die REIP-Werte wurden nebeneinandergestellt und mit den Erträgen der Jahre 2021, 2022 und 2023 verglichen. Die Wetterbedingungen wurden in die Betrachtung einbezogen. So herrschten 2021 gute Wetterbedingungen. Das Jahr 2022 war gekennzeichnet durch ein Hagelereignis am 20. Juni. Das Jahr 2023 war anfangs zu trocken. Regen im Juli und August ermöglichte es noch, eine leicht unterdurchschnittliche Ernte einzufahren.




Abb. 3: y-Achse links: durchschnittliche Werte der Steigung des REIP in Mai/Juni und Juni/Juli (Sentinel-2 Daten), y-Achse rechts: Ertrag in kg/ha, x-Achse: Jahr

Die Steigung des REIP im Mai und Juni hat nach diesen Auswertungen das Potenzial, den Ertrag, u. U. auch nach Sorte, gut abzubilden. Die Daten für Juni und Juli sind weniger aussagekräftig. Das Hagelereignis 2022 spiegelt sich in den Auswertungen für Juni/Juli 2022 wider. Die Steigerungsraten des REIP waren relativ hoch und die Zusammenhänge mit dem Ertrag 2022 schwach (Abb. 3).

### 3 Diskussion mit Ausblick

Das Zusammenfügen von Teilflächenergebnissen in Verbindung mit der Stickstoffausbringmenge und dem Ertrag dürfte weitere Korrelationen hervorbringen und für die Abbildung robusterer Zusammenhänge sorgen, die Voraussetzung für das Bestandsmonitoring und die Ertragsschätzung sein können. Notwendig wäre ein langjähriges Wissen über die Felder und deren Erträge, damit man die Hopfengärten in Hohertrags-, Mitteltrags- und Niedrigertragszonen einordnen kann. Diese Information müsste mit quantitativen Daten verknüpft werden, um eine Verbesserung der Resultate zu erreichen. Techniken der künstlichen Intelligenz wecken die Hoffnung, Hilfe bei der Auswertung von Reflexionsmustern zu erhalten, die auch die Pflanzenhöhe schätzen können [Al22]. Bereits in einem frühen Vegetationsstadium waren bei diesen ersten Schritten gute Zusammenhänge zum Ertrag sichtbar. Die Resultate stehen im Gegensatz zu den Ergebnissen aus bodennahen Reflexionsmessungen an der Pflanze, bei denen erst Anfang Juni brauchbare Reflexionskurven ermittelt werden konnten [Wa19; St21]. Das Potenzial für Aussagen mit Hilfe von Satellitenaufnahmen im Mai und Juni könnte tendenziell höher sein, soweit die Störfaktoren ausgeschaltet werden können. Weiterhin sollte durch intensivere Forschungsarbeit versucht werden, die hier ermittelten ersten Ergebnisse mit Reflexionsdaten, die direkt an der Hopfenpflanze erhoben wurden, besser zu verknüpfen. In der Fläche und in der Zeit hochauflösende Satellitenbilder haben das Potenzial, auch im Hopfenbau einen Beitrag zur Entscheidungsunterstützung bei den verschiedenen Arbeiten (v. a. der Stickstoffdüngung) zu liefern. Dies gilt insbesondere bei bewässerten Hopfengärten, in denen ein Störfaktor, die Wasserverfügbarkeit, ausgeschaltet ist.

## Literaturverzeichnis

- [Al22] Alagialoglou, L. et al.: A learnable model with calibrated uncertainty quantification for estimating canopy height from spaceborne sequential imagery, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, S. 1-13, 2022, Art no. 4410913, <https://doi.org/10.1109/TGRS.2022.3171407>
- [Fu23] Fuss, E.: persönliches Gespräch zum GPS-Einsatz bei der Firma Fuss, Lutzmannsdorf, Mainburg, am 7.10.2023.
- [Ge16] Geipel, J. et al.: A Programmable Aerial Multispectral Camera System for In-Season Crop Biomass and Nitrogen Content Estimation, *Agriculture* 2016, 6, 4, 2016, <https://doi.org/10.3390/agriculture6010004>
- [Kv22] Kverneland Group Deutschland GmbH, Applikationskarten für Kverneland Terminals, Soest, 2022.
- [La10] Landesanstalt für Landwirtschaft (LfL): Jahresbericht Hopfen 2010, Freising-Weihenstephan, 2011.
- [Lu23] Lutz, K.: persönliches Gespräch zum Einsatz von Satellitendaten zur N-Düngung im Hopfen, Hüll, am 25.1.2023.
- [MKS22] Marszalek, M.; Korner, M.; Schmidhalter, U.: Prediction of multi-year winter wheat yields at the field level with satellite and climatological data, *Computers and Electronics in Agriculture*, vol. 194, 2022, ISSN 0168-1699, <https://www.sciencedirect.com/science/article/pii/S0168169922000941>
- [St21] Stampfl, J.: Bedarfsgerechte Stickstoffernährung von Hopfen (*Humulus lupulus* L.) durch Düngesysteme mit Fertigation, Dissertation an der Universität Hohenheim, Institut für Kulturpflanzenwissenschaft, Stuttgart, 2021.
- [Wa19] Waldinger, M.: Auswirkung differenzierter Stickstoffdüngung auf Wachstumsverlauf und Ertragsbildung von Hopfen – Möglichkeiten der Nutzung von Reflexionsmessungen, Bachelorarbeit an der Technischen Universität München, Lehrstuhl für Ökologischen Landbau und Pflanzenbausysteme, Freising-Weihenstephan, 2019.

## Predictive task scheduler and ERP system for automated vegetable cultivation in an outdoor environment

Simon Maike<sup>1</sup>, Farooq Abbas<sup>2</sup>, Ting Sheng Lee<sup>1</sup>, Marvin Kühnast<sup>1</sup>, Bettina Weber<sup>1</sup>, Rolf Becker<sup>2</sup> and Josef Franko<sup>1</sup>

**Abstract:** Automated spot farming is a promising approach to overcome the ecological and economical challenges in modern agriculture. This requires sophisticated robotic controls and data management. The AgriPV-Bot, as a full farming system for mixed vegetable farming, achieves this by extending a classical ERP (enterprise resource planning) system towards monitoring single plant cultivation. The task scheduler analyzes this data, determines the resulting horticultural process for each specific plant individually and monitors the process execution that is performed by robotics. This paper introduces the features of the ERP system as well as the strategy for the predictive task scheduler.

**Keywords:** task scheduling, ERP system, Odoo, Robot Operating System (ROS), spot farming

### 1 Introduction

Nowadays, agriculture faces a variety of challenges. Society asks for ecological and sustainable farming concepts while the farmers struggle to stay economically stable. In addition, vegetable production in particular suffers from a shortage of affordable manual labor. Automation seems to be a promising tool to tackle these challenges to enable a precision vegetable cultivation. Many approaches have been made in recent years to achieve this goal with indoor farming concepts where automation is easier to implement in contrast to an outdoor environment. These concepts are very successful regarding yield per area and water efficiency. However, most products of these approaches are not competitive because of exceeding energy costs due to artificial lightning, among other things. Increasing energy prices within recent years have amplified this problem. This development redirects the interest towards automated vegetable cultivation in an outdoor environment. A review of recent smart farming developments is given in [Mo21]. Many of the current approaches, however, are limited to special purposes within growing vegetables. In contrast to this, the holistic AgriPV-Bot is a fully automated spot farming-system to grow vegetables in a highly efficient manner. All processes such as soil preparation, planting, fertilization, irrigation, weeding, monitoring, and harvesting are executed according to the specific need of each individual plant. The system is designed to provide a robust framework for automation. A long traverse is connected to a steady

---

<sup>1</sup> AI.Land GmbH, Siebenhäuser 7, 47906 Kempen, info@a-i.land

<sup>2</sup> Hochschule Rhein-Waal, Friedrich-Heinrich-Allee 25, 47475 Kamp-Lintfort, rolf.becker@hochschule-rhein-waal.de

pivot at one end and a main drive at the other. The traverse simultaneously serves as storage for vegetable boxes and rail for multiple carriages which can travel along the sides. These carriages include all tools needed for the field cultivation and enable them to hover over the acreage to avoid soil contact as much as possible. The AgriPV-Bot, which is designed for a traverse length of 24 meters, works self-sufficiently with energy being provided by the solar panels above the traverse. The current prototype with an 8-meter traverse is shown in Fig. 1. The idea of the concept is to cultivate different types of vegetables on the same acreage and directly stock mixed vegetable boxes according to customer wishes on the field daily for direct marketing.



Fig. 1: Prototype of AgriPV-Bot, side and top view

Key factors for such a holistic approach are the hardware itself, sensor and actuator process control, and the data management and decision making. This paper focusses on the latter in terms of the unique approach to include single plant cultivation into an ERP system and a predictive task scheduler to determine the tasks to be executed by the system for a successful vegetable cultivation. The importance of information and data management within modern agriculture is highlighted in [Sa17]. In the present approach, the open-source ERP system Odoo is taken as a basis and is extended towards a complete farm management system including field sections, single plant cultivation, fleet management as well as an online shop for the mixed vegetable boxes as the outcome of the AgriPV-Bot. A digital twin of the field section helps to simulate the vegetable cultivation and enables a predictive decision-making process for the task scheduler, compare [Ve21]. The task scheduler is crucial for an efficient system in terms of resources such as time, energy, water, or fertilizer. Planning for the latter has exemplary been studied in [GET20]. As an impression on the system requirements, each day about 600 plants have to be harvested and newly planted while harvesting is supposed to be done only overnight to assure optimal freshness of the product. Depending on previous and forecasted weather, irrigation must be considered. In addition to these cultivational tasks, the current and estimated customer demands add another level of complexity.

In general, farm management systems have evolved over the last years towards smart farming, and many competitors are entering the market. However, most systems are designed to support the operation of conventional farming strategies. In contrast to this,

the AgriPV-Bot mainly aims at single plant cultivation, which shifts the requirements of such a system. Plant growth is treated individually similar to a piece-by-piece industrial manufacturing process. The development of a farm management system based on a classical ERP system, which is open source, therefore appears to be advantageous over the alternative of modifying existing solutions, which in most cases cannot be customized to such a great extent. A well-proven platform such as Odoo provides a solid foundation for various extensions, which are necessary in order to digitalize and optimize farming in general. Of course, some features have to be added which are already standard in current farm management solutions. Nevertheless, in future agriculture, many farms will require individualized solutions which are easily applicable to an open-source framework compared to closed one-party software.

## 2 Methodology

The main idea of the AgriPV-Bot is the plant-based, respectively spot-based, cultivation of different types of vegetables on the same field. For that purpose, each plant is monitored individually to determine its needs independently from others. This leads to an enormous amount of information, which has to be stored in a database. Therefore, it is reasonable to include the data within an ERP system towards a farm management system where all segments of the farm can be tracked and visualized. Odoo, as an open-source environment, is taken as the starting point for this development. The overall workflow with respect to the AgriPV-Bot is depicted in Fig. 2. The tasks on the AgriPV-Bot are executed via ROS (robot operating system), which gives feedback to the task scheduler.




Fig. 2: System overview

Within Odoo, the crop growth is simulated in accordance with an industrial production process which is illustrated in Fig. 3. Therein, the field section acts as a warehouse and each plant position corresponds to one storage location. These locations include the crop, classified by type and BBCH level, the available resources necessary for plant growth and potential insect or disease information. If the target BBCH level is not reached for the individual plant, a virtual manufacturing order is automatically generated to reach the next BBCH level. For that purpose, bills of materials (BOMs) are given for all cultivation stages for all vegetable types which are available in the system. In case all required resources are in stock on the respective storage location, the virtual production can be executed, and the simulated plant growth reaches the next BBCH level. In the meantime, the monitoring of the real crop continues by regularly taking pictures of the plant.

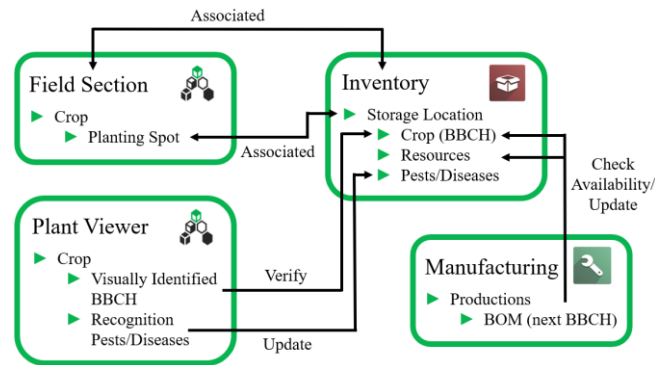


Fig. 3: Odoo module interactions

Machine learning algorithms define the current real BBCH level of the plant independently of the simulation such that the simulation can be corrected if needed. In turn, the simulation can help to improve the recognition models throughout the development phase. With this iterative scheme, it is possible to define the BOMs of the different growth stages with such precision that the cultivation can be optimized and the need of external input such as irrigation and fertilization can be minimized. In addition to that, such a system allows for extensive research on the compatibility of different crops on a small acreage to improve soil quality and biodiversity. An accurate recognition of current BBCH values allows for a good prediction of a possible harvesting date. This again enables the prediction of vegetable availability for the web shop with regard to direct marketing in Odoo. Customers can choose the ingredients of their personal vegetable box and place their order, which is forwarded to the task scheduler, so that the chosen vegetables can be included in the upcoming harvest.

The responsibility of the task scheduler can be divided into two parts besides the information transfer between Odoo and ROS. On the one hand, the required tasks that have to be executed need to be identified based on the database provided by Odoo. On the other hand, the determined tasks have to be sorted in an optimized manner. Some tasks are easy to identify since they are necessary on a regular basis as taking a picture of each plant every day to monitor its status. Another example is the harvest of the plants which has been triggered by the web shop or just by the fact that the target BBCH value has been exceeded. A little more challenging is the question which plant should be planted at which particular spot after one has been harvested. This decision is dependent on the available space, the season, the neighboring plants, the specific nutrient balance and predicted customer demand at the corresponding harvesting date. While the first two aspects are comparatively easy to answer, the last ones are highly dependent on the quality of the underlying database. There is no database which can be perfectly applicable to any location of the AgriPV-Bot but requires a learning algorithm depending on its specific demands and surroundings to aim for optimized efficiency. Decision making for irrigation is another example for a challenging task identification. Based on previous measured



rainfall on site in combination with soil water storage capabilities, specific plant growth requirements and local weather forecasts, a sophisticated model is required which will gradually gain precision during testing. The tasks of fertilization and weeding have a similar range of complexity, omitting detailed explanations. All identified tasks receive a time stamp at creation and a deadline until the task must be completed. The database provides predictions of energy, time, and additional resource consumption for each type of task and for moving the carriages and the traverse. Based on this information, the goal of the task scheduler is to find an efficient sequence for the tasks. Taking the simplest algorithm like first in first serve as a reference, the optimization potential of task scheduling is enormous but also demonstrates that it is crucial for the efficiency of the system. First improvements of the task sequence have taken the least travel time of traverse and carriage as well as the energy consumption into account. Multiple constraints add further complexity to this efficiency challenge. For example, harvesting should only be done by night just before delivery in the early morning to ensure optimal freshness of the product. Additionally, it is advantageous to place the traverse at angles where both carriages can execute multiple tasks at the same time. Another important aspect is the availability of resources such as water or fertilizer as well as executing energy intensive tasks preferably around noon when the solar panels provide most energy. The exemplary constraints offer a glimpse of how complex the interactions and requirements for the optimization of the task scheduler are with respect to its full development.

### 3 Results

Based on the open-source Odoo system, additional modules have been developed and implemented in order to enhance the platform towards a farm management system that can handle field sections, the monitoring of plants, fleet management, herd management for different species, the monitoring of a biogas plant and direct marketing. An important module for the AgriPV-Bot is the field sections module.



Fig. 4: Field section overview (left) and single view (right)

Field boundaries, tracks, crops, and additional information such as soil parameters can be displayed within the interface. Fig. 4 exemplarily shows a field section overview on the left-hand side and the real field section of the AgriPV-Bot prototype including the planted crops, color-coded by type, on the right-hand side. As described within the methodology,

these crops are associated with storage location within the inventory corresponding to the field section. Once a crop is planted, respectively added to the database, the virtual production pipeline is automatically established to reach the next BBCH level until the target level is reached. The pictures taken by the system to monitor the plants can be displayed within the plant viewer module, see Fig. 5 (left).




Fig. 5: Plant viewer (left) and path planning by the task scheduler (right)

The right-hand side of Fig. 5 shows a first approach to path planning by the task scheduler optimized for minimal energy consumption.

## 4 Summary and Outlook

This paper presents a strategy as well as first results of how the open-source ERP system Odoo can be extended towards a farm management system. The focus lies within the scope of the AgriPV-Bot on monitoring and scheduling single plant cultivation. First results are promising, but the development will continue over the next years with the goal of providing a system for fully automatized and digitalized vegetable cultivation as a huge step towards future farming.

**Acknowledgements:** We would like to thank Deutsche Bundesstiftung Umwelt (DBU) for their support within the project *AgriPV-Bot Synergetische Kombination von Photovoltaik und Agrarrobotik im Gemüsebau* (38214/01).

### Bibliography

- [GET20] Gallardo, M.; Elia, A.; Thompson R.: Decision support systems and models for aiding irrigation and nutrient management of vegetable crops. *Agricultural Water Management*, Volume 240, 106209, 2020.
- [Mo21] Moysiadis, V. et al.: Smart Farming in Europe. *Computer Science Review*, Volume 39, 100345, 2021.
- [Sa17] Saidu, A. et al.: Application of ICT in Agriculture: Opportunities and Challenges in Developing Countries. *International Journal of Computer Science and Mathematical Theory*, Volume 3(1), 8-18, 2017.
- [Ve21] Verdouw, C. et al.: Digital twins in smart farming. *Agricultural Systems*, Volume 189, 103046, 2021.

## Assessment of ground conditions in grassland on a mower with artificial intelligence

Christoph Manss<sup>1</sup> , Viktor Martel<sup>2</sup> and Roman Weisgerber<sup>2</sup>


**Abstract:** Process-monitoring for autonomous mowers in agriculture is crucial to establish an online quality assessment. Here, neural networks (NNs) are employed to classify ground conditions, distinguishing between dry, mowed, unplanted, and grass. The data comprises RGB images that are captured by a camera mounted on a mower. These images are then used to train various NNs, with EfficientNet\_V2\_s emerging as the most accurate network and with ResNet18 to be the most efficient network in terms of training duration and accuracy. The study also reveals for this use-case that employing transfer learning enhances the overall network performance. The developed NNs is intended for deployment on mowers, enabling them to adjust their mowing blades, conserve energy, and enhance the quality of mowed grass. Beyond mowing, the NN can be applied in process control and the identification of other plant species or weeds in the agricultural field, contributing to biodiversity assessments and more sustainable farming practices.

**Keywords:** classification, process control, autonomous systems

### 1 Introduction

Autonomously driving mowers are becoming more relevant in agriculture as they lower the demand of humans that are otherwise required for driving the mowers. Thus, the mowers must detect their surroundings and plan a driving pattern depending on the farmland that must be mowed. Consequently, the focus currently lies on path planning, object detection, and obstacle avoidance [Da20; Ko18]. Yet, the quality of the grass before and after mowing is currently not considered for automation. However, depending on the grass quality (dry, wet, or many unwanted plants) the arrangement of the mowing device can be changed, or the mowing blades can be stopped to save energy during the process. This is particularly useful if the grassland consists of several dry spots such that mowing is not reasonable as well as when the mower drives over already mowed grass. Additionally, this enables the mower to inject quality assessment into its workflow for

---

<sup>1</sup> DFKI Niedersachsen, Marine Perception, Marie-Curie-Str. 1, 26129 Oldenburg, christoph.manss@dfki.de,   
<https://orcid.org/0000-0003-4851-2622>


<sup>2</sup> Maschinenfabrik Bernard Krone GmbH & Co. KG, Heinrich-Krone-Straße 10, 48480 Spelle,  
Viktor.Martel@krone.de, Roman.Weisgerber@krone.de

**Förderhinweis:** Das DFKI Niedersachsen (DFKI NI) wird gefördert im Niedersächsischen Vorab durch das Niedersächsische Ministerium für Wissenschaft und Kultur und die VolkswagenStiftung (FKZ: ZN3683). Die Arbeit entstand im Projekt Agri-Gaia, das durch das Bundesministerium für Wirtschaft und Klimaschutz gefördert wird (FKZ: 01MK21004A).

automatized mowing. Currently, remote sensing is utilized to assess the quality of the grassland [DRD21; Mo21]. For example, in [Mo21], the authors reviewed the current research on above-ground biomass (AGB) of grasslands estimation through remote sensing and machine learning. The authors concluded that remote sensing hits a plateau regarding the accuracy of AGB estimation, and that the proximity of the sensor system to the ground is most influential for the accuracy. On the detection of mowing events with remote sensing, the authors in [DRD21] also identified similar limitations. In another study [Zu20], the authors detected the grass length at the mower to control the motor blades in the mower by using a random forest algorithm that considers seven different features of a built-in 9-axis inertia measurement unit. Yet, for bigger mowing devices this approach can be too sensitive to noise.

Therefore, in this paper, RGB images that have been collected with a camera on top of the cabin of a mower are used to detect ground conditions of the grassland in front of the mower. The considered conditions are dry, mowed, unplanted, and grass. The data was collected during different seasons and over two years to ensure that both relatively dry and wet weather conditions appear in the data. For the classification of these ground conditions, neural networks (NNs) are trained and evaluated. We used networks readily available in Pytorch and optimized the augmentations with the help of SMAC [Li22]. To understand the classification results, methods of explainable AI are used to further understand the classification results.

## 2 Dataset

The dataset<sup>3</sup> was detected with a camera that was mounted on the top of a mower. The height of the camera was about 4m above ground, and the camera was facing forward with an angle of 45°. In , the view of the camera is displayed. As the mower uses three blade rows, the recorded image is split into three equally large sub-images, which address one of the mowing blades; the left image corresponds to the left mowing blade, etc. As the same neural network will be used for all sub-images, a dataset is created that comprises only the sub-images. The classes are addressed by sorting the images into folders with the name of the corresponding class (dry, mowed, unplanted, and grass). At the end, 10.213 sub-images for grass, 670 sub-images for dry, 4.195 sub-images for mowed, and 198 sub-images for unplanted have been collected. Fig. 1 displays examples of the classes. The classes dry and unplanted are underrepresented in the dataset, because no mowing has been done on very dry fields and likewise no mowing has been done on unplanted fields.

---

<sup>3</sup> The dataset has been published on Zenodo.org under the title „forefield\_grassland“. DOI: 10.5281/zenodo.10371371




Fig. 2: View of the RGB camera from the top of the mower. The black boxes indicate the regions within the image, which are cropped and passed to the neural network



Fig. 1: Example images of all classes in the dataset from left to right: dry, mowed, unplanted, and grass

Yet, these categories can be observed and are therefore part of the dataset. So far, the classes are superficial and are currently only intended to test the system and its performance, but the number of classes can also be extended in the future.

### 3 Development of the Artificial Intelligence

To make the implementation of NNs easily reproduceable and available, we focused on using NNs that are already implemented in Torchvision (Version 0.14.1). The tested networks are ResNet18, ResNet34, ResNet50 [He16], MobileNet\_V2 [Sa19], MobileNet\_V3\_Small and MobileNet\_V3\_Large [Ho19], and EfficientNet\_V2\_s [TL21]. All networks are trained from scratch and with the provided weights in Torchvision, which are based on ImageNet [Ru15]. The input images are resized to squared images with a pixel size of 256 pixel and are also casted to float values with a range from 0.0 to 1.0. To optimize the augmentation of the data during the training of the networks, the optimizer SMACV3 [Li22] was employed with the search space: brightness, contrast, hue, and saturation. As a result, the brightness and the hue are uniformly varied within a range of 0.2, and the contrast and saturation are uniformly varied within a range of 0.1.

All networks are trained on a Nvidia V100-DGX with 32GB RAM. Each network was trained for 50 epochs, with the Adam optimizer, a batch size of 64, and a learning rate of 0.0001. For training, the data was split into 80% for training and 20% for validation.

## 4 Results

The results are presented in Tab. 1, where all entries are sorted according to the F1-Score in descending order. The F1-Score can be seen as the harmonic mean of the precision and recall scores. The F1-Score can also account for the class imbalance of the dataset. From Tab. 1 it can be concluded that using transfer learning increases the performance of the network on a different classification task. Here, the gain is about 1-2 % in precision and recall.

In terms of the performance with respect to the F1-Score, the EfficientNet\_V2\_s is the best neural network. However, it is not the best regarding the duration it took to train the network. The duration for training is connected to the computational complexity of a neural network, and a low computational complexity often contradicts a good accuracy, as a smaller neural network is less able to learn complex features in the data. Thus, in the last column, we divided the F1-Score by the duration for training to get a quantification for performance vs complexity. Then, a high number indicates an efficient network. Accordingly, a good choice of a fast network with relatively low computational complexity would be the ResNet18 or the MobileNet\_v3\_Small with pretrained weights.

| Model              | Pretrained | Duration [h:mm] | Precision | Recall | F1-Score | F1-Score/duration |
|--------------------|------------|-----------------|-----------|--------|----------|-------------------|
| EfficientNet_V2_s  | yes        | 2:20            | 0,9913    | 0,9912 | 0,9912   | 10,2              |
| MobileNet_V3_large | yes        | 00:49           | 0,9908    | 0,9908 | 0,9908   | 29,1              |
| ResNet34           | yes        | 00:50           | 0,9908    | 0,9908 | 0,9908   | 28,5              |
| MobileNet_v2       | yes        | 00:47           | 0,9886    | 0,9885 | 0,9885   | 30,3              |
| MobileNet_V3_small | yes        | 00:40           | 0,9882    | 0,9882 | 0,9882   | 35,6              |
| ResNet18           | yes        | 00:31           | 0,9879    | 0,9879 | 0,9879   | 45,9              |
| ResNet50           | yes        | 01:03           | 0,9874    | 0,9869 | 0,9870   | 22,6              |
| ResNet18           | no         | 00:31           | 0,9785    | 0,9761 | 0,9768   | 45,4              |
| MobileNet_V3_large | no         | 00:48           | 0,9759    | 0,9755 | 0,9754   | 29,3              |
| MobileNet_V3_small | no         | 00:40           | 0,9739    | 0,9735 | 0,9736   | 35,1              |
| MobileNet_V2       | no         | 00:46           | 0,9708    | 0,9699 | 0,9701   | 30,4              |
| EfficientNet_V2_s  | no         | 02:20           | 0,9696    | 0,9696 | 0,9695   | 10,0              |
| ResNet34           | no         | 00:50           | 0,9682    | 0,9673 | 0,9668   | 27,8              |
| ResNet50           | no         | 01:30           | 0,9625    | 0,9614 | 0,9608   | 15,4              |

Tab. 1: Training results of all trained networks. The training results are sorted according to the F1-Score in descending order




Fig. 3: Saliency map for all classes created with GradCam++ for a misclassified example. Here, the true class of this example is *dry*, but the network classified it as *mowed*, with prediction accuracies of 0.39% and 0.996%, respectively. Thus, the saliency map yields stronger features for *mowed* instead for the other classes

|           |       |     |       |           |
|-----------|-------|-----|-------|-----------|
| grass     | 2025  | 1   | 0     | 0         |
| dry       | 0     | 149 | 3     | 0         |
| mowed     | 1     | 2   | 837   | 0         |
| unplanted | 0     | 0   | 0     | 38        |
|           | grass | dry | mowed | unplanted |

Fig. 4: Confusion matrix of the validation set

Explainability methods provide further insights on the detections of the NNs. Here, we used GradCam++ [Ch18]<sup>4</sup>, but other methodologies are also possible such as [He23]. GradCam++ analyses the second order gradients in the neural network to estimate a saliency map for the input image. The saliency map highlights regions on the input image that are most influential on the class. An example is shown in Fig. 3, where the network detects *mowed* although the true label is *dry*. Through GradCam++ we can see that the classes are falsely classified in border region, i.e., an image where two classes are possible or where

images have similar features. Here the dry area has also a low grass height and can therefore be seen as mowed. Another reason for false classification is that the classes *dry* and *unplanted* appear similar to the network. However, a misclassification happens rarely as can be seen in Figure 4. It would, however, be helpful to diversify the data more.

## 5 Conclusion and Outlook

This paper showed preliminary results on training a classification network to assess the quality of the grassland while mowing. With the gathered data, the network is able to achieve a high F1-Score and only few false classifications. We were able to achieve this by using an optimization framework on the augmentation and transfer learning. With the explainability method GradCam++, we identified that false classifications result from two possible classes in the image. Yet, the impact of such false classifications on the application has to be investigated.

In the future, this network will be deployed on the mower. Once the network can coarsely classify the grassland, the network should be improved for a more detailed assessment of

<sup>4</sup> [https://github.com/vickyliin/gradcam\\_plus\\_plus\\_pytorch](https://github.com/vickyliin/gradcam_plus_plus_pytorch), accessed 14.12.2023


the grassland, e.g. through image segmentation [MGR23]. It is envisioned that the detection results can be used to adjust the mowing blades, reduce the energy consumption, and increase the quality of the mowed grass. Also, we would like to increase the size of the dataset and to increase the number of classes for a more detailed detection. Moreover, this network can be applied for automatized process control, and to detect other plants and weeds within the images like [Sm19] to determine the biodiversity on the field.

### Bibliography

- [Ch18] Chattopadhyay, A., et al.: Grad-CAM++: Improved Visual Explanations for Deep Convolutional Networks. In: 2018 IEEE Winter Conference on Applications of Computer Vision (WACV). pp. 839–847, 2018.
- [Da20] Daniyan, I., et al.: Development and Performance Evaluation of a Robot for Lawn Mowing. *Procedia Manufacturing*. 49, 42–48, 2020.
- [DRD21] De Vroey, M., Radoux, J., Defourny, P.: Grassland Mowing Detection Using Sentinel-1 Time Series: Potential and Limitations. *Remote Sensing*. 13, 3, 348, 2021.
- [He16] He, K., et al.: Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
- [He23] Hedström, A., et al.: Quantus: An Explainable AI Toolkit for Responsible Evaluation of Neural Network Explanations and Beyond. *JMLR*. 24, 34, 1–11, 2023.
- [Ho19] Howard, A., et al.: Searching for mobilenetv3. *Proceedings of the IEEE/CVF international conference on computer vision*. 2019.
- [Ko18] Korthals, T., et al.: Multi-Modal Detection and Mapping of Static and Dynamic Obstacles in Agriculture for Process Evaluation. *Frontiers in Robotics and AI*. 5, 2018.
- [Li22] Lindauer, M., et al.: SMAC3: A Versatile Bayesian Optimization Package for Hyperparameter Optimization. *Journal of Machine Learning Research*. *J. Mach. Learn. Res.*, 23, 1–9, 2022.
- [MGR23] Manss, C., Guenther, I., Rahe, F.: Cropline and Weed Detection in Corn Using Weak Supervision. In: Bramer, M. and Stahl, F. (eds.) *Artificial Intelligence XL*. pp. 377–390 Springer Nature Switzerland, Cham, 2023.
- [Mo21] Morais, T.G., et al.: The use of machine learning methods to estimate aboveground biomass of grasslands: A review. *Ecological Indicators*. 130, 108081, 2021.
- [Ru15] Russakovsky, O., et al.: ImageNet Large Scale Visual Recognition Challenge, <http://arxiv.org/abs/1409.0575>, 2015.
- [Sa19] Sandler, M., et al.: Mobilenetv2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018.
- [TL21] Tan, M., Le, Q.: Efficientnetv2: Smaller models and faster training. *International conference on machine learning*. PMLR, 2021.
- [Sm19] Smith, L.N., et al.: Weed classification in grasslands using convolutional neural networks. In: *Applications of Machine Learning*. pp. 334–344 SPIE, 2019.
- [Zu20] Zushida, K., et al.: Estimation of Lawn Grass Lengths based on Random Forest Algorithm for Robotic Lawn Mower. In: 2020 59th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE). pp. 1628–1633, 2020.



## Combining a crop growth model with satellite images to get better insight in wheat growth

Emir Memic <sup>1</sup>, Jonas Frössl<sup>2</sup> and Simone Graeff-Hönninger<sup>1</sup>

**Abstract:** The overall goal of better crop management that is expected to contribute to food security relies on the idea of being able to predict end-of-season yield early in the growing season and adapt crop management strategies (e.g. fertilization) to the expected seasonality trend (weather forecasts). The goal of this study was to investigate the potential of combining crop growth models with satellite image-based information for prediction of in-season plant development. Satellite image-based leaf area index (LAI) estimates were compared to crop model simulations at two locations: Heidfeldhof and Eckartsweier, both University of Hohenheim research stations. Crop model simulated LAI was compared to vegetation index (VI) based LAI for the Heidfeldhof location resulting in RMSE 0.78 and 0.312 nRMSE based on 24 measurements. For the Eckartsweier location, VI-based LAI had 1.4 RMSE and 0.573 nRMSE based on 8 measurements.


**Keywords:** crop model, DSSAT CERES-Wheat, satellite image-based LAI

### 1 Introduction

The impact of seasonality (weather-related) on biological processes of plants with respect to management practices results in complexity that can be disentangled only with additional mechanisms such as crop growth models (decision support), remote- and near-sensing technology (monitoring systems) etc. The Decision Support System for Agrotechnology Transfer – Crop Environment Resource Synthesis (DSSAT-CERES) Wheat crop growth model simulates plant development and in-season biomass accumulation with respect to specific soil conditions (soil texture, soil water holding capacity etc.), weather conditions (daily min/max temperature, solar radiation, precipitation etc.), plant genetics (cultivar specific biomass partitioning among various plant organs) and management practices (planting and harvesting date, fertilizer type and amount etc.) [Ho19]. The underlying mechanism in the model is based on a radiation use efficiency approach, while plant phenological development takes temperature and daylength into account. Genetic coefficients of CERES-Wheat for cultivar RGT-Reform were estimated including the data collected within the DiWenkla project (*diwenkla.uni-hohenheim.de*, unpublished yet). In the last few decades, various remote- and near-sensing

---

<sup>1</sup> Agronomy/University of Hohenheim, 340a, Fruwirthstr. 23, 70599 Stuttgart, emir.memic@

uni-hohenheim.de,  <https://orcid.org/0000-0002-0184-5481>; simone.graeff@uni-hohenheim.de

<sup>2</sup> Fertilization and soil matter dynamics/University of Hohenheim, 340i, Fruwirthstr. 20, 70599 Stuttgart, jonas.froessler@uni-hohenheim.de

technologies were used to non-destructively monitor plant growth during vegetative plant development on site-specific level. In this study, the potential of satellite image for estimating in-season leaf area index (LAI) was evaluated with free of charge Sentinel-2 images, with pixel scales of approximately 10 x 10 m ([www.sentinel-hub.com](http://www.sentinel-hub.com)). The correlation between satellite image-based vegetation index (VI) and measured in-season LAI was investigated based on normalised difference vegetation index (NDVI) and enhanced vegetation index (EVI). Main objective of the current study was the conversion of VI to LAI, to investigate the potential of evaluating CERES-Wheat LAI simulations with satellite images-based LAI estimates, resulting in more accurate crop model yield estimates.

## 2 Materials and Methods

### 2.1 Fields and Experiment Descriptions

Two different locations in Baden-Württemberg (Germany): Heidfeldhof (Lat:48.711, Lng:9.196) and Eckartsweier (Lat:48.519, Lng:7.870) were used for analysis. On these two locations, the same winter wheat cultivar RGT-Reform was planted. The experimental design was the same at both locations. Among other things, the impact of urea N-fertilizer on LAI, tops (total above-ground dry biomass, including leaf, stem, and grain) and grain yield (dry matter) in winter wheat was investigated. The soil type at Heidfeldhof was characterized as haplic luvisol and as gleyic luvisol at Eckartsweier. Winter wheat was planted in October 2022 with an inter-row distance of 12.5 cm (330 at Heidfeldhof and 350 kernels per m<sup>2</sup> at Eckartsweier) and harvested in July 2023 at both locations. The amount of applied urea fertilizer was based on common agricultural practice with applications: 1) at tillering, 2) at stem elongation and 3) at anthesis. The total amount of nitrogen applied at Heidfeldhof was 210 (70+70+70) and 230 (90+70+70) kg ha<sup>-1</sup> at Eckartsweier. The urea treatment consisted of a large circle area in the field with 40 m diameter. LAI was measured at different growth stages non-destructively with LAI 2000 (LiCor, Lincoln, NE, USA). Destructive sample cuts of above-ground biomass were collected within the circle area during growing season with the sample cut size being 25 x 25 cm. Four cuts within circle area at each sampling date were conducted and averaged during the evaluation process. Data was collected in cooperation with NH<sub>3</sub>-Min project ([nh3min.de/partner/universitaet-hohenheim](http://nh3min.de/partner/universitaet-hohenheim)).

### 2.2 Satellite Image-based LAI

The NDVI and EVI satellite image-based analysis was conducted with the dataset Sentinel-2 L2A in the online EO-Browser (Sentinel-Hub) [Si23] platform. Shape files (polygons) of the experimental plots were exported as KML format in QGIS and uploaded into EO-Browser for targeting specific pixels of interest. The satellite image based NDVI

(Eq. 1) information was used as a form of remote-sensing vegetation monitoring system (for estimating LAI) where “healthy” (higher chlorophyll) biomass areas result in higher reflectance rate in the near infra-red (B08) and high absorption in red (B04) [Si23].

$$NDVI = (B08-B04)/(B08+B04) \tag{1}$$

The EVI (Eq. 2) was used for further analysis because blue (B02) can be used for correcting NDVI as it takes into account soil background signals and atmosphere (Custom visualisation, EO Browser [Si23]).

$$EVI = 2.5 \times (B08-B04) / ((B08+6.0 \times B04-7.5 \times B02) + 1.0) \tag{2}$$

LAI was first calculated from NDVI and EVI with exponential function-based correlation equation [Sa01; An21] taken from literature by replacing VI with NDVI and EVI values in Equation 3.

$$LAI = 0.57 \times \exp(2.33 \times VI) \tag{3}$$

In addition, LAI was calculated from NDVI and EVI index with modified exponential function-based correlation equation by replacing VI with NDVI and EVI in Eq. 4. Equation 4 was a result of fitting of available data collected within this study.

$$LAI = 0.25 \times \exp(3.6 \times VI) \tag{4}$$

### 3 Results

#### 3.1 Satellite Image-based LAI estimates

The time-series trends of estimated LAI based on NDVI ( $LAI_{NDVI}$ ) and EVI ( $LAI_{EVI}$ ) with Equations 3 and 4 are shown in Figure 1 for Heidfeldhof (a) and Eckartsweier (b).




Fig. 1: The time-series trends of estimated LAI based on the NDVI and EVI with Equations 3 and 4 for Heidfeldhof (a) and Eckartsweier (b)

Based on the measurements of LAI with three ground truth measurements at Heidfeldhof and four ground truth measurements at Eckartsweier, EVI based LAI estimation with Equation 4 delivered satisfactory results. The  $LAI_{NDVI}$  over-estimated LAI early in the winter wheat vegetative period (March-April) and  $LAI_{EVI}$  under-estimated LAI later in winter wheat vegetative period (May-July), when compared to the measurements.

### 3.2 Crop Model Simulations

In Figure 2, CERES-Wheat simulations for Heidfeldhof (a) and Eckartsweier (b) with LAI (a and b figure, x-axis), tops (total above-ground biomass dry matter) and grain weight dry matter  $kg\ ha^{-1}$  (a and b figure, y-axis) of investigated area are shown graphically for purpose of comparing visually with LAI estimated based on EVI (Eq. 4).

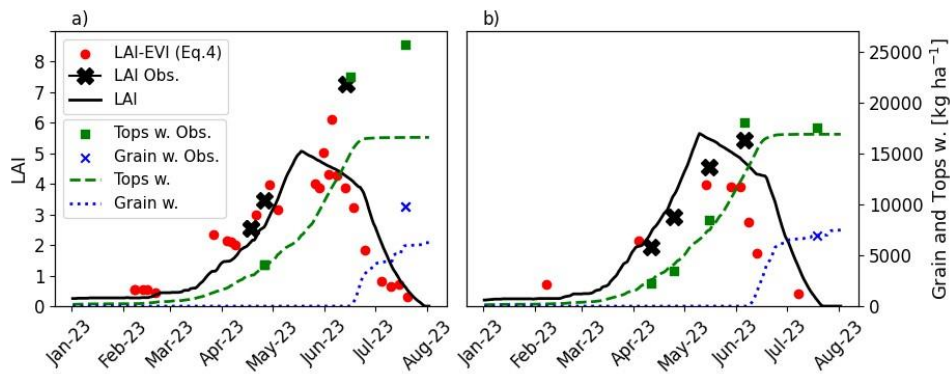


Fig. 2: Simulation outputs of CERES-Wheat for Heidfeldhof entire circle area 2023 (a), Eckartsweier 2023 entire circle area (b) with LAI (a and b figure, x-axis), tops and grain weight (a and b figure, y-axis) with corresponding observations and  $LAI_{EVI}$  (Eq. 4)

Despite a minor underestimation of  $LAI_{EVI}$  (Eq.4) in June when compared to crop model simulated LAI, the trend was captured well and could be used in future for evaluation of crop model LAI. For Heidfeldhof, crop model underperformed when simulating all three parameters, including LAI (RMSE 1.85 and 0.416 nRMSE), tops weight with RMSE 6846  $kg\ ha^{-1}$  and 0.393 nRMSE and grain weight with RMSE 3850  $kg\ ha^{-1}$  and 0.39 nRMSE, based on three observations each (Tab. 1). For Eckartsweier other than tops weight with RMSE 2313  $kg\ ha^{-1}$  and 0.223 nRMSE, CERES-Wheat performed very well based on four LAI, five tops and one grain weight observation (Tab. 1). Simulated LAI was directly compared to  $LAI_{EVI}$  (Eq.4) estimates ( $n=24$ ) at the Heidfeldhof location, and a relatively good and comparable fit was found with RMSE 0.78 and 0.312 nRMSE. Simulated LAI at Eckartsweier underperformed when compared to  $LAI_{EVI}$  (Eq.4) due to underestimation of  $LAI_{EVI}$  later in the vegetative period with RMSE 1.4 and nRMSE 0.573 ( $n=8$ ) (Tab. 1).

| Variables                       | Heidfeldhof |              |           | Eckartsweier |              |          |
|---------------------------------|-------------|--------------|-----------|--------------|--------------|----------|
|                                 | RMSE        | n-RMSE       | #O.       | RMSE         | n-RMSE       | #O.      |
| LAI Obs.                        | 1.85        | 0.416        | 3         | 0.73         | 0.197        | 4        |
| <b>LAI<sub>EVI</sub> (Eq.4)</b> | <b>0.78</b> | <b>0.312</b> | <b>24</b> | <b>1.4</b>   | <b>0.573</b> | <b>8</b> |
| Tops w.                         | 6846        | 0.393        | 3         | 2313         | 0.223        | 5        |
| Grain w.                        | 3850        | 0.39         | 1         | 19           | 0.003        | 1        |

Tab. 1: RMSE and nRMSE statistics of crop model simulated and measured with corresponding number of measurements for Heidfeldhof and Eckartsweier. #O – numbers of observations, RMSE - kg ha<sup>-1</sup>

#### 4 Discussion

The crop growth model evaluation on two locations was not entirely satisfactory due to underestimations at Heidfeldhof location. Underestimation of biomass might be due to uncertainties in soil profile-related crop model parametrization and requires further analysis of soil parameters. More detailed information about soil-layer-based bulk density and organic matter might improve the results. Overall, the results indicated potential in relying on satellite image-based data for evaluation of crop model LAI estimates. Estimating above-ground biomass (crop model tops or grain weight) based on image-based information seems to be challenging [Zi21] and requires further analysis. Various cultivars have different leaf to stem ratio and harvest index resulting in different vegetation canopy structure (different reflectance properties). If canopy structure and timing of specific phenological stages are not considered, data interpretation may result in wrong conclusions. Various studies such as [Ha04] and [Xi16] also indicated problems caused by index saturation related to plant biomass densities. As it can be seen in Figure 2 and availability of satellite images (with no cloud coverage) explanatory power of the satellite image-based information can be eroded very quickly with missing measurements if representative time-series trends cannot be constructed and thus result in misleading conclusions and results. One of the biggest weaknesses of this short study were availability of one season at two locations, and destructive sample size and frequency. The reason for less frequent destructive sample cuts was a practical constraint of using the same plots for destructive sampling and image analysis.

#### 5 Conclusion

Results of the study indicate a certain potential of using satellite image-based data for evaluation of crop growth model LAI simulations. Crop growth models have great potential to be used as decision support tool if yield predictions are timely and trustworthy. Yield prediction accuracy of crop growth models has always been conditioned by destructively collected evaluation data. This study indicated that non-destructively collected crop model evaluation data can be attained from free of charge satellite images.

However, one should be careful when using VI interpretations of plant related physiology that are not based on any form of agronomic knowledge (plant physiology).

**Acknowledgements:** The project DiWenkLa (Digital Value Chains for a Sustainable Small-Scale Agriculture) is supported by funds from the Federal Ministry of Food and Agriculture (BMEL) based on a decision of the Parliament of the Federal Republic of Germany. The Federal Office for Agriculture and Food (BLE) coordinates support for digitalisation in agriculture as a funding organization; grant number 28DE106A18 is gratefully acknowledged. DiWenkLa is also supported by the Ministry for Food, Rural Areas, and Consumer Protection Baden-Württemberg.

#### Bibliography

- [An21] Andalibi, L. et al.: Leaf area index variations in ecoregions of ardabil province, iran, *Remote Sens.*, vol. 13, no. 15, 2021, doi: 10.3390/rs13152879.
- [Ha04] Haboudane, D. et al.: Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture, *Remote Sens. Environ.*, vol. 90, no. 3, pp. 337–352, 2004, doi: 10.1016/j.rse.2003.12.013.
- [Ho19] Hoogenboom, G. et al.: The DSSAT crop modeling ecosystem, in *Advances in crop modelling for a sustainable agriculture*, 1st ed., K. J. Boote, Ed. Burleigh Dodds Science Publishing, pp. 173–216, 2019.
- [Sa01] Saito, K. et al.: Estimates of lai for forest management in okutama, in *Asian Conference on Remote Sensing*, no. November, pp. 5–9, 2001. [Online]. Available: <https://crisp.nus.edu.sg/~acrs2001/pdf/155SAITO.PDF>
- [Si23] Sinergise Ltd., EO Browser - Modified Copernicus Sentinel data, last accessed: Sept. 2023. <https://apps.sentinel-hub.com/eo-browser/>
- [Xi16] Xie, Q. et al.: Estimating Winter Wheat Leaf Area Index from Ground and Hyperspectral Observations Using Vegetation Indices, *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 9, no. 2, pp. 771–780, 2016, doi: 10.1109/JSTARS.2015.2489718.
- [Zi21] Ziliani, M. G. et al.: Early season prediction of within-field crop yield variability by assimilating CubeSat data into a crop model, *Agric. For. Meteorol.*, vol. 313, no. November 2021, 2022, doi: 10.1016/j.agrformet.2021.108736.

## Assessing the contribution of digital technologies to agroecological principles in the European context

Alma Moroder<sup>1</sup>, Sonoko Bellingrath-Kimura<sup>1</sup>, Karl Reimand<sup>2</sup>, Jochen Kantelhardt<sup>2</sup> and Andreas Meyer-Aurich<sup>3</sup>

**Abstract:** The aim of our research is to find out how the alignment/misalignment of digital technologies with agroecological principles can be assessed, in order to allow for a holistic evaluation of digital technologies in the future. To address this research question, we looked at agroecology as the “10 elements of agroecology” defined by the FAO, which encompass environmental, socio-economic, cultural and political principles. We developed a set of indicators representing these elements of agroecology. The indicator development was based on an exploratory and a systematic literature review, as well as a short survey, followed by a series of qualitative interviews with both agroecology and digitalisation experts. First results indicate that our indicator-based approach, although non-exhaustive, allows for a wide number of digital technologies to be assessed under the lens of their contribution to agroecology.

**Keywords:** Agroecology, 10 elements of agroecology, FAO, digitalisation, digital technology, digital tool

### 1 Introduction

Compliance of food systems with agroecological principles is not only lacking on a global scale but also on a European level [Fa18]. European agriculture is characterized by a particularly intensive use of resources and inputs and by rapidly decreasing levels of biodiversity and ecosystem services. Digital innovations in the agricultural sector are considered to be able to tackle some of these issues [Ba17]. However, it is not yet clear how digital technologies in Europe contribute to agroecological principles. Thus, the goal of our research is to find out how digital technologies in the European context are perceived to align/misalign with the concept of agroecology in general and the agroecological principles in particular. Agroecology is a broad concept that encompasses a wide range of environmental, socio-economic, cultural and political principles [We20]. The development of indicators for agroecology aims at representing the concept of

---

<sup>1</sup> Leibniz-Zentrum für Agrarlandschaftsforschung e.V. (ZALF), Programmbereich 2: Landnutzung und Governance, Eberswalder Str. 84, 15374 Müncheberg; alma-maria.moroder@zalf.de

<sup>2</sup> Universität für Bodenkultur (BOKU), Institut für Agrar- und Forstökonomie (AFO), Feistmantelstraße 4, 1180 Wien

<sup>3</sup> Leibniz-Institut für Agrartechnik und Bioökonomie (ATB), Ökonomik der Agrartechnik, Max-Eyth-Allee 100, 14469 Potsdam

agroecology as a whole, which is why the entirety of agroecological principles needs to be taken into account and represented through the indicators. Since these principles go far beyond efficiency, which tends to be the primary goal of most technologies in agriculture [Ba17], a holistic evaluation of digital technologies is made possible. Importantly, the concept of agroecology is also relevant at different levels, ranging from farm-level activities to the society. While there are several understandings of agroecology, the Food and Agriculture Organization (FAO) of the United Nations (UN) has developed a widely accepted definition for agroecology, stating that it is “an integrated approach that simultaneously applies ecological and social concepts and principles to the design and management of food and agricultural systems” [Fa18; Ba20]. The FAO has developed a set of 10 elements that represent agroecology: diversity, resilience, co-creation and sharing of knowledge, efficiency, recycling, synergies, culture and food traditions, human and social values, responsible governance and circular and solidarity economy. Thus, according to this understanding of agroecology, complying with agroecological principles means ensuring that several aspects within the human, social and ecological dimension are taken into consideration within an agricultural system.

We want to identify a set of indicators for agroecology, based on the understanding of agroecology as proposed by the FAO [Fa18], and to adjust them with regard to the assessment of digital tools and technologies. The indicators were developed based on a literature review and feedback from all project members within the EU-Horizon project D4AgEcol and are followed by a series of structured qualitative interviews with digitalisation and agroecology experts, which are expected to add their insights as to the validity and applicability of the proposed indicators. They are also expected to share their general knowledge and estimation on the current and future interplay between digitalisation and agroecology. First results of these interviews will be presented in the form of a poster at the conference.

## 2 Method

The indicator development was based on an extensive literature review. First, literature from pre-existing knowledge within the project (e.g. [Bi20a], [Bi20b], [Hi22], [TH20], [Me19], [CO12], [We20] and others) was gathered and assessed. Subsequently, an exploratory literature review was carried out, for which literature directly related to the FAO’s 10 elements of agroecology [Fa18; Fa19; Hi19] was analysed. Hereby, publications and publicly available documents from existing coordination and support actions on agroecology (AE4EU, ALL-Ready) were specifically scanned for indicators for agroecology. Next, a systematic literature research was carried out. For that, Web of Science was used as the primary search engine. 16 publications were found, 6 of which were kept for the development of the indicators after a review (the rest were excluded because they did not include any information related to the assessment of agroecology and did not provide a good basis for the formulation of indicators). All publications were thoroughly analysed, after which we gathered relevant indicators for agroecology through



an iterative process, estimating their quality and suitability for our purposes, especially taking into account their validity in the context of digital technologies. The analysed literature rarely included digitalisation-specific indicators for agroecology. Some of the identified indicators thus had to be adjusted in order to allow for an assessment under the lens of digital technologies. Furthermore, a small number of indicators was developed based on discussions among ZALF and BOKU and are not directly based on the literature review. After this process, a final list of 62 indicators representing all 10 elements of agroecology was compiled. This list was then sent out to all project members (in an online-survey format using LimeSurvey) in order to collect their feedback. They were asked to indicate 3 indicators per element which they thought would be best suited for describing the respective element of agroecology, thus reducing the final number of indicators to 30. (Tab. 1). The literature review and the survey are being complemented by a series of qualitative interviews with both agroecology and digitalisation experts. These experts were selected based on the systematic indication of 4 contacts from each of the project partnering institutes/universities. This, as well as the explicit request for non-academic experts, was aiming at ensuring a balanced selection of experts both with an academic and a non-academic background and a broad selection across different European nationalities. The interviews consist of general questions on the connection between digitalisation and agroecology in Europe as well as of specific questions connected to the assessability of a possible contribution of digital technologies to agroecological principles overall, as well as through indicators and through our proposed indicators in particular.

### 3 Results and Discussion

Our research resulted in 30 indicators reflecting some of the main aspects of agroecology (Tab. 1). However, the indicators do not constitute an exhaustive representation of agroecology in its entirety but offer a depiction of agroecology under the lens of digitalisation. They constitute the basis upon which digital technologies can be assessed. One challenge that presented itself in the indicator development process was to adjust or newly define indicators that would allow for such an assessment. Our indicators needed to prioritise aspects of agroecology that are not always the focus of other existing indicator sets regarding the FAO's 10 elements of agroecology, including those contained in the Tool for Agroecology Performance Evaluation [Fa19]. Most of the literature was therefore not directly useful when developing general indicators for agroecology, which were not exclusively related to digital technologies or digitalisation in general. Two notable exceptions are the publications by [Hi22] and [TH20], which were useful in defining indicators connected to technologies, i.e. "technology-specific indicators" – indicators that are directly connected to technologies.

It should be noted that our list of indicators does not represent agroecology in its entirety but a selection of certain central aspects of agroecology. The broadness of our concept of agroecology makes it difficult for it to be condensed in a list of 30 indicators without leaving out a number of crucial aspects. Many more indicators would be necessary to draw

a comprehensive picture of the concept (e.g. soil health, soil compaction), and even then some aspects might be left out since knowledge systems on agroecology, which inform such indicator development processes, are highly individual and context-specific. Other important aspects, like the reduction of greenhouse gas emissions were not taken into account. This is also due to the fact that the environmental aspects are not explicitly addressed with the formulation of the 10 elements of agroecology. This can be seen as a shortcoming of the concept of agroecology. Thus, to capture the holistic impact of digital tools and technologies on agroecology and the environment, it might be necessary to consider further indicators.

The interviews with digitalisation and agroecology experts are still ongoing, and the first results will be included in the poster presentation. In these interviews, we put our understanding of agroecology to a test by asking the experts about their own understanding of it. So far, the interviews have shown that not only does the definition of agroecology differ vary largely between digitalisation experts on one side and agroecology experts on the other, but also within the agroecology expert group. The role of digitalisation for a pathway towards agroecology is seen as crucial by some and as negligible by others. For example, sowing and mechanical weeding robots might contribute to efficiency, since they help reduce the input of resources (e.g. pesticides), while they might only have a negligible impact on recycling. Smart technologies in milk production might contribute to human and social values since they help improve working conditions on the farm, and cloud applications for nature conservation might strengthen the relations between producers and consumers when used as communication tools, thus contributing to co-creation and sharing of knowledge. Digital grazing systems such as virtual fencing technology might increase the protection from livestock grazing for certain species as well as improve landscape connectivity through the absence of physical barriers, thus contributing to diversity. Most interviewees agree that digital technologies are an integral part of current agriculture in Europe and thus can potentially be used to achieve certain agroecological goals, if desired. In fact, some experts state that no digital technology is inherently agroecological but that its agroecological impact depends solely on how the technology is used. Some experts consider current definitions of agroecology (and among others the one by the FAO) to be too broad, in general, but especially when observed from a digital technology point of view. However, when asked about whether indicator systems such as ours are suited for the evaluation of the agroecological contribution of digital technologies, most experts agree. Furthermore, some state that many of the presented indicators will be difficult to quantify or measure. We expect these interviews to help us look critically at our developed indicators and at indicator systems for agroecology in general, and to give us insights into the role of digital technologies for agroecology.

Our study is timely insofar as we look at how the ongoing digitalisation in agriculture aligns/misaligns with agroecology as a whole and whether an indicator-based approach is suitable for such an assessment. We find that although our indicators are non-exhaustive, they allow for a systematic assessment of digital technologies and their contribution to certain crucial aspects of agroecology. Their framing under the lens of digitalisation and

their adaptation to the assessment of digital tools makes them tailored to our specific research question. However, it will allow for the assessment of a wide range of digital technologies within agriculture and is thus replicable.

| Element                              | Indicator  |
|--------------------------------------|--|
| DIVERSITY                            | Habitat and landscape diversity  |
|                                      | Crop, tree and livestock diversity on the farm                                     |
|                                      | Diversity of activities, products and services                                     |
| CO-CREATION AND SHARING OF KNOWLEDGE | Access to data collected by the technology   |
|                                      | Connections among farmers or between farmers and other stakeholders                |
|                                      | Participation of farmers (or other end-users) in the development of the technology |
| SYNERGIES                            | Compatibility with other digital and non-digital technologies                      |
|                                      | Compatibility with polyculture fields or non-crop plants                           |
|                                      | Habitat and landscape connectivity   |
| EFFICIENCY                           | Farm profitability   |
|                                      | Pesticide use  |
|                                      | Fertiliser use   |
| RECYCLING                            | Reusability and reparability of technology   |
|                                      | Water saving or recycling  |
|                                      | Reduction or recycling of waste  |
| RESILIENCE                           | Protection against extreme weather events  |
|                                      | Protection of farmers against income fluctuations                                  |
|                                      | Protection against pest and disease attacks  |
| HUMAN AND SOCIAL VALUES              | Working conditions and wages   |
|                                      | Young people's empowerment and involvement in agriculture                          |
|                                      | Data ownership   |
| CULTURE AND FOOD TRADITIONS          | Compatibility with local varieties and breeds                                      |
|                                      | Preservation of farmers' knowledge, skills and identity                            |
|                                      | Integration of local culture into the technology                                   |
| RESPONSIBLE GOVERNANCE               | Infrastructure readiness   |
|                                      | Sufficiency of risk assessment related to the use of technology                    |
|                                      | Supporting of policymaking and regulation by data provision                        |

Tab. 1: Indicators of agroecology for digitalisation (per element of agroecology [Fa18])

## Bibliography

- [Ba17] Balafoutis, A. et al.: Precision Agriculture Technologies Positively Contributing to GHG Emissions Mitigation, Farm Productivity and Economics. *Sustainability* 9, 1339, 2017.
- [Ba20] Barrios, E. et al: The 10 Elements of Agroecology: enabling transitions towards sustainable agriculture and food systems through visual narratives. *Ecosystems and People* 16, 230-247, 2020.
- [Bi20a] Biovision: ACT - Agroecology Criteria Tool. Agroecology Info Pool – an initiative by Biovision. <https://www.agroecology-pool.org/methodology/>, 2020.
- [Bi20b] Biovision: F-ACT - Farm-Level Agroecology Criteria Tool. Agroecology Info Pool – an initiative by Biovision. <https://www.agroecology-pool.org/methodology/>, 2020.
- [CO12] Cabell, J.F., Oelofse, M.: An Indicator Framework for Assessing Agroecosystem Resilience. *Ecology and Society* 17 (1), 18, 2012.
- [Fa18] FAO, 2018.: The 10 elements of agroecology: guiding the transition to sustainable food and agricultural systems. <http://www.fao.org/3/i9037en/i9037en.pdf>, 2018.
- [Fa19] FAO: TAPE Tool for Agroecology Performance Evaluation 2019 – Process of development and guidelines for application. Test version. Rome, 2019. <https://www.fao.org/3/ca7407en/ca7407en.pdf>
- [Gö23] Gödel, B. et al.: Definitions and a set of inclusion criteria for agroecology living labs, pertinent research infrastructures and their synergies. Zenodo. <https://doi.org/10.5281/zenodo.8146852>, 2023.
- [Hi22] Hilbeck, A. et al.: Aligning Digitalization with Agroecological Principles to Support a Transformation Agenda. ECDF Working Paper Series 003, Berlin, 2022. <https://www.tandfonline.com/doi/full/10.1080/21683565.2018.1432329>
- [HI19] HLPE: Agroecological and other innovative approaches for sustainable agriculture and food systems that enhance food security and nutrition. A report by the High Level Panel of Experts on Food Security and Nutrition of the Committee on World Food Security, Rome, 2019. <http://www.fao.org/cfs/cfs-hlpe/en/>
- [Me19] Meuwissen, M. P. M. et al.: A framework to assess the resilience of farming systems. *Agricultural Systems* 176, 102656, 2019.
- [TH20] Tisselli, E., Hilbeck, A.: Agroecological principles applied to ICT. In (eds. Ajena et al.): *Agroecology & Digitalisation. Traps and opportunities to transform the food system*, 2020.
- [We20] Wezel, A. et al.: Agroecological principles and elements and their implications for transitioning to sustainable food systems. A review. *Agronomy for Sustainable Development* 40, 40, 2020.

## Ausbildungsorganisatorische Perspektiven auf die Wissensvermittlung zur Digitalisierung im dualen System

### Ergebnisse einer qualitativen Befragung von Ausbildungsbetrieben

Michael Paulus <sup>1</sup> und Clara Körner<sup>1</sup>

**Abstract:** Neben neuen technischen Möglichkeiten ergeben sich aus der Digitalisierung des Agrarsektors neue Ansprüche an Kompetenz- und Lernbedürfnisse für die landwirtschaftliche Berufsbildung. Die Wissensvermittlung kann dabei als ausbildungsorganisatorische Herausforderung für betriebliche, schulische und überbetriebliche Ausbildungsstätten im dualen System angesehen werden. Vor diesem Hintergrund wurden 20 Leitfadeninterviews mit Ausbildungsbetrieben aus dem Regierungsbezirk Stuttgart durchgeführt, um betriebliche Perspektiven auf die Wissensvermittlung im dualen System und den Bedarf an Lernkooperationen im Kontext der Digitalisierung besser zu verstehen. Es wird festgestellt, dass die Wissensvermittlung mehrheitlich als Gemeinschaftsaufgabe aller Wissensakteure wahrgenommen wird, jedoch findet bisher wenig Vernetzung zwischen Ausbildungsbetrieben und weiteren Bildungsakteuren im dualen System statt. Um die Wissensvermittlung zur Digitalisierung zu stärken, braucht es zukünftig eine stärkere ausbildungsorganisatorische Abstimmung, um einen ausreichenden Wissenszugang zur Digitalisierung zu ermöglichen.

**Keywords:** Digitalisierung, Ausbildung, Leitfadeninterviews, Wissensvermittlung

## 1 Einleitung

Die Empirie zu digitalen Technologien in der Landwirtschaft zeigt seit vielen Jahren eindeutige Differenzen in der Verbreitung von digitalen Technologien auf. Selbst innerhalb ähnlich strukturierter Regionen können differenzierte Verbreitungsmuster für unterschiedliche Technologien in Deutschland beobachtet werden [GG2023]. Dabei hat die Diffusionsforschung zur Digitalisierung im Laufe der letzten Jahrzehnte eine ganze Bandbreite von Verbreitungs- und Nutzungsbarrieren für Precision- und Digital-Farming-Technologien identifiziert [Sh21]. Unter anderem legen Forschungsarbeiten nahe, dass sich der Austausch und Transfer von Wissen und Informationen positiv auf die Technologieverbreitung auswirken [Ma22; To18]. Kritische Stimmen befürchten jedoch, dass die wissensbezogenen Risiken der zunehmenden digitalen Technisierung bisher nur unzureichende Beachtung finden und empfehlen in diesem Zusammenhang, dass diesen

---

<sup>1</sup> Universität Hohenheim, Kommunikation und Beratung in ländlichen Räumen, Schloss Hohenheim 1, 70599

Stuttgart, m.paulus@uni-hohenheim.de,  <https://orcid.org/0000-0002-3409-6798>,  
claramarian.koerner@uni-hohenheim.de

Risiken mit bildungspolitischen Maßnahmen in Aus- und Weiterbildung entgegengewirkt wird [KMS21].

Kernelement der landwirtschaftlichen Erstqualifizierung in Deutschland ist die Lernkooperation zwischen betrieblichen und berufsschulischen Ausbildungsstätten sowie überbetrieblichen Bildungsträgern im Rahmen des dualen Systems. [ESB19] erläutern, dass die Auswirkungen der Digitalisierung auf die Berufsbildung auf einer individuellen (z. B. Lernvoraussetzungen), normativen (z. B. Bildungsziele), didaktischen (z. B. digitale Lehrmittel), ordnungspolitischen (z. B. Lehrpläne) und ausbildungsorganisatorischen (z. B. Lernkooperation) Ebene zu gestalten sind. Schwerpunkt der bisherigen Forschung stellt vornehmlich die Betrachtung der inhaltlich-normativen und didaktisch-methodischen Ebene dar [Be17; Ki02]. Dagegen liegen nur wenige Untersuchungen zur Beleuchtung der ausbildungsorganisatorischen und lernkooperativen Gestaltung der Agrarbildung im Kontext der Digitalisierung vor [Sc19]. Vor diesem Hintergrund eruiert die vorliegende Arbeit die Bedeutung von Lernkooperation im Kontext der Digitalisierung ausgehend von den Ergebnissen einer qualitativen Befragung von 20 landwirtschaftlichen Ausbildungsbetrieben aus dem Regierungsbezirk Stuttgart basierend auf der folgenden Forschungsfrage: *Wie stellt sich die Kooperationen von Lernorten im dualen System im Hinblick auf die Wissensvermittlung zur Digitalisierung aus Sicht von Ausbildungsbetrieben dar?*

## 2 Material und Methoden

Zur Beantwortung der Forschungsfrage wird auf einen qualitativen Ansatz zurückgegriffen. Die Verwendung von teilstrukturierten Interviews erlaubt es, dass subjektive Erfahrungen entlang vordefinierter Themen erfragt werden, gleichzeitig aber eine gewisse Offenheit und Flexibilität herrscht, um durch Nachfragen Teilaspekte gezielt zu vertiefen [GL10]. Der verwendete Leitfaden besteht überwiegend aus offenen Fragen. Inhaltlich wurden die Teilnehmenden zunächst gebeten, (1) den eignen Betrieb und (2) Erfahrungen mit der betrieblichen Ausbildung darzulegen. Im Anschluss daran wurde spezifischer nachgefragt, wie sich (3) die betriebliche Wissensvermittlung zur Digitalisierung darstellt und (4) welche Erfahrungen und Ansichten zur Lernkooperation im Rahmen des dualen Systems zur Digitalisierung vorherrschen.

Zunächst wurden drei Interviews mit zwei staatlichen Versuchsbetrieben und einem privaten Ausbildungsbetrieb im Ausbildungsberuf Landwirt durchgeführt, um die Angemessenheit des Leitfadens zu überprüfen. Weitere Interviewteilnehmer wurden mittels der Ausbildungsdatenbank anhand vorab festgelegter Merkmale ausgewählt und kontaktiert. Insgesamt wurden 20 Vorort- oder Telefoninterviews im Frühjahr 2023 mit Ausbildungsbetrieben aus dem Regierungsbezirk Stuttgart durchgeführt.

Nach gegebener Zustimmung wurden die Interviews jeweils aufgezeichnet. Zur weiteren Auswertung wurden die Interviews verschriftlicht und in Anlehnung an das

inhaltsanalytische Verfahren strukturierend ausgewertet [KR22]. Dazu wurden alle Interviews durchgearbeitet und inhaltstragende Textfragmente mit Bezug zum Thema Lernkooperation und Wissensvermittlung zur Digitalisierung extrahiert und den Themenfeldern (1) Beispiele für bekannte Angebote im dualen System (2) Austausch mit anderen Akteuren und (3) Wahrnehmungen zu den Verantwortlichkeiten bei der Wissensvermittlung zugeordnet.

### **3 Ergebnisse**

#### **3.1 Beschreibung der teilnehmenden Ausbildungsbetriebe**

Alle befragten Betriebe liegen im Regierungsbezirk Stuttgart, wobei aus den zwölf Landkreisen mindestens immer ein Betrieb befragt wurde. Im Schnitt bewirtschaften die Betriebe eine Fläche von 142 ha. Die Mehrheit der Betriebe wird vollständig konventionell bewirtschaftet (n=16). Mit ausschließlich Meister- (n=12), Techniker- (n=3) oder Hochschulabschlüssen (n=5) verfügt die Gruppe der Interviewten über einen hohen landwirtschaftlichen Bildungsgrad. In der Außenwirtschaft betreiben die Betriebe vor allem Ackerbau (n=20) und Futterbau (n=18). In der Innenwirtschaft stellen die Milchvieh- und Rinderhaltung (n=14), Schweinehaltung (n=5) und Legehennenhaltung (n=3) die wichtigsten Produktionszweige dar.

#### **3.2 Beispiele für Angebote im dualen System**

Der Mehrheit der befragten Ausbilder fällt es schwer, konkrete Beispiele zu benennen, inwiefern unabhängig vom eigenen Betrieb den Auszubildenden bereits Wissen zu digitalen Technologien vermittelt worden ist. Es wird vermutet, dass Vorkenntnisse vorliegen, wenn diese bereits im elterlichen Betrieb (B2) oder Praktikumsbetrieb (B5) vermittelt wurden. Bezogen auf Berufsschulen und überbetriebliche Ausbildungsstätten ist weitestgehend unbekannt, inwiefern und zu welchen Technologien Wissen vermittelt wird. Als Beispiele für digitale Technologien werden Herdenmanagementsysteme (B17), GPS-Technologien und Lenksysteme (B7), Ackerschlagkarteien (B8) und Melkroboter (B13) genannt. Mit Blick auf die inhaltliche Breite der Ausbildung ist zu vermuten, dass der geringe Wissensstand über die Wissensvermittlung zur Digitalisierung an anderen Ausbildungsstätten auch darauf zurückzuführen ist, dass insgesamt ein begrenzter Informationsaustausch zwischen Ausbildungspraxis und weiteren Ausbildungsstätten bzw. Auszubildenden als Mittelsmann stattfindet. B17 führt beispielsweise aus: „Ich bin jetzt auch nicht derjenige, wo da viel nachfragt, aber sie [Anmerkung: Auszubildende] erzählen auch nicht viel von der Schule“. Des Weiteren gehen einzelne Ausbilder davon aus, dass selbst wenn Wissen zu digitalen Technologien vermittelt wird, der Umfang eher gering ist: „In meinen Augen könnte man da noch ein bisschen mehr machen, gerade in der Berufsschule.“ (B11).

### 3.3 Austausch mit anderen Akteuren zur Digitalisierung

Bevorzugt findet ein Austausch zur Digitalisierung mit anderen Landwirten statt. Vereinzelt wird von einer Konsultation von anderen Ausbildern berichtet. Nahezu kein Austausch zur Digitalisierung erfolgt mit Lehrkräften, was teilweise aber auch gar nicht gewünscht wird. Als Grund dafür wird angeführt, dass dafür nur wenig Zeit zur Verfügung steht, die Lehrkräfte als unzureichend informiert wahrgenommen werden oder grundsätzlich kaum Angebote bestehen, um den direkten Austausch mit den Lehrkräften zu pflegen. Ein Ausbilder (B18) fasst zusammen, dass er selbst mit der Berufsschule kaum Kontakt hat und bezweifelt des Weiteren, „ob das wirklich einen Vorteil bringen würde für die Ausbildung.“

### 3.4 Verantwortlichkeiten bei der Wissensvermittlung

Die Mehrheit der Ausbilder (n=11) gibt an, dass die Hauptverantwortung zur Wissensvermittlung im dualen System nicht bei einem einzelnen Akteur liegt. Entsprechend der Kooperation der Lernorte im dualen System wird die Rolle der Ausbildungspraxis und Berufsschulen hervorgehoben.

Den Ausbildungsbetrieben kommt dabei gerade bei der praxisnahen Wissensvermittlung eine tragende Rolle aus Sicht der Ausbilder zu. Ein Ausbilder (B2) führt exemplarisch zur betrieblichen Wissensvermittlung aus: „Da wo die Technik da ist, also auf dem Ausbildungsbetrieb. [...] Diese Sachen muss man 1, 2, 3, 4-mal gemacht haben.“ Als wesentlicher Hemmschuh der Wissensvermittlung wird die betriebliche Begrenzung auf die vorhandenen Technologien angesehen.

Bezogen auf die Berufsschulen führen einige Ausbilder an, dass hier ein Grundverständnis zu digitalen Technologien vermittelt werden sollte. Dadurch würde auch sichergestellt werden, dass alle Auszubildenden gleichermaßen Grundwissen zur Digitalisierung erlangen (B1). Als hemmend wird der begrenzte Wissensstand der Lehrkräfte, die begrenzten Lehrzeiten und die zur Verfügung stehende technische Ausstattung der Schulen wahrgenommen.

Überbetriebliche Angebote werden als Ergänzung zur Ausbildung in Berufsschule und -praxis angesehen. Vereinzelt sprechen sich jedoch Ausbilder für die Etablierung von Ausbildungslehrgängen zur Digitalisierung und eines zentralen Kompetenzzentrums aus. Ein Ausbilder (B7) merkt jedoch kritisch an, dass gerade bei überbetrieblichen Lehrgängen in den Wintermonaten ohne direkten Praxisbezug der Lerneffekt gering sei, da der Anwendungsbezug fehlen würde.



## 4 Diskussion und Ausblick

Die vorliegende Arbeit beleuchtet ausbildungsbetriebliche Perspektiven auf die Wissensvermittlung zur Digitalisierung im dualen System. Es wird aufgezeigt, dass die Wissensvermittlung als eine Gemeinschaftsaufgabe der unterschiedlichen Lernorte angesehen wird. Es bestehen für praktische, berufsschulische und überbetriebliche Ausbildungsstätten unterschiedliche Hemmnisse bei der Wissensvermittlung. Gerade für Berufsschulen und überbetriebliche Bildungsstätten heißt das, dass die technischen und personellen Voraussetzungen dafür geschaffen werden müssen [Sc19]. Im Unterschied zur bisherigen Forschung verdeutlicht die Arbeit am Beispiel der Digitalisierung, dass bisher nur eine begrenzte Vernetzung unter Ausbildungsakteuren zu neuen komplexen Themen in der Agrarbildung besteht. Um den Wissensanforderungen der Digitalisierung gerecht zu werden, sollte hierzu eine engere Kooperation zwischen den landwirtschaftlichen Bildungsstätten gefördert werden. Dazu scheint es auch empfehlenswert, besser abzustimmen, welches Wissen zur Digitalisierung [Be17] am besten wo vermittelt werden kann. Dadurch könnte der Wissenszugang zu neuen technologischen Verfahren und Anwendungen für angehende Landwirte vereinfacht werden.

**Förderhinweis:** Die Förderung des Vorhabens DiWenkLa (Digitale Wertschöpfungsketten für eine nachhaltige kleinstrukturierte Landwirtschaft) erfolgt aus Mitteln des Bundesministeriums für Ernährung und Landwirtschaft. Das Vorhaben wird ebenfalls durch das Ministerium für Ernährung, Ländlichen Raum und Verbraucherschutz Baden-Württemberg unterstützt. Die Projektträgerschaft erfolgt über die Bundesanstalt für Landwirtschaft und Ernährung im Rahmen des Programms zur Innovationsförderung unter dem Förderkennzeichen 28DE106A18. Das Vorhaben wird ebenfalls durch das Ministerium für Ernährung, Ländlichen Raum und Verbraucherschutz Baden-Württemberg unterstützt.

### Literaturverzeichnis

- [Be17] Beinert, M.: Fachliche, methodische und persönlich-soziale Anforderungen an landwirtschaftliche Arbeitskräfte vor dem Hintergrund der zunehmenden Technisierung und Digitalisierung in der Landwirtschaft. In: Edmund-Rehwinkel-Stiftung der Landwirtschaftlichen Rentenbank (Hg.): Arbeitsmarkt, Ausbildung, Migration: Perspektiven für die Landwirtschaft (33), S. 7–41, 2017.
- [ESB19] Euler, D.; Severing, E.; Bertelsmann Stiftung: Berufsbildung für eine digitale Arbeitswelt, 2019.
- [GG23] Gabriel, A.; Gandorfer, M.: Adoption of digital technologies in agriculture – an inventory in a European small-scale farming region. In: Precision Agric 24 (1), S. 68–91, 2023.
- [GL10] Gläser, J.; Laudel, G.: Experteninterviews und qualitative Inhaltsanalyse als Instrumente rekonstruierender Untersuchungen. 4. Auflage. Wiesbaden: VS Verlag (Lehrbuch), 2010.

- [Ki02] Kitchen, N. R et al.: Educational Needs of Precision Agriculture. In: Precision Agric 3 (4), S. 341–351, 2002.
- [KMS21] Kehl, C.; Meyer, R.; Steiger, S.: Digitalisierung der Landwirtschaft: gesellschaftliche Voraussetzungen, Rahmenbedingungen und Effekte. Teil II des Endberichts zum TA-Projekt (Arbeitsbericht, Nr. 194), 2021.
- [KR22] Kuckartz, U.; Rädiker, S.: Qualitative Inhaltsanalyse. Methoden, Praxis, Computerunterstützung: Grundlagentexte Methoden. 5. Auflage. Weinheim, Basel: Beltz Juventa (Grundlagentexte Methoden), 2022.
- [Ma22] Masi, M. et al.: The long way to innovation adoption: insights from precision agriculture. In: Agric Econ 10 (1), 2022.
- [Sc19] Schott, F. et al.: Digitalisierung in Landwirtschaft und Gartenbau. Herausforderungen, Chancen und Empfehlungen für eine zeitgemäße Berufsausbildung in Sachsen, [www.arbeitundleben.eu/projekte/detail/digi-agrar-81/](http://www.arbeitundleben.eu/projekte/detail/digi-agrar-81/), Stand 11.07.2019.
- [Sh21] Shang, L. et al.: Adoption and diffusion of digital farming technologies - integrating farm-level evidence and system interaction. In: Agricultural Systems 190, S. 103074. 2021.
- [To18] Toma, L. et al.: Impact of information transfer on farmers' uptake of innovative crop technologies: a structural equation model applied to survey data. In: J Technol Transf 43 (4), S. 864–881, 2018.

## Entwicklung eines digitalen Zertifikatsystems zur Dokumentation landwirtschaftlicher Klima- und Umweltschutzmaßnahmen am Beispiel der Kartoffel-Wertschöpfungskette

Marie Sophie Peters<sup>1</sup>, Torben Rahn<sup>1</sup>, Steffi Fock<sup>1</sup>, Yves Reckleben<sup>2</sup> und Holger Schulze<sup>2</sup>

**Abstract:** Die Herausforderungen in der Landwirtschaft sind zahlreich und fordernd. Neben dem Klimawandel und den damit einhergehenden Extremwetterereignissen steigen die Anforderungen an die Landwirte, Prozessqualitäten nachzuweisen, stetig (z. B. die Einhaltung von Umweltschutzmaßnahmen). Dabei steigt die Komplexität und Vielschichtigkeit mit jeder Stufe der Wertschöpfungskette. Digitale bzw. automatisierte Zertifikatsysteme haben das Potenzial, die Transparenz entlang der Wertschöpfungskette zu erhöhen und gleichzeitig den administrativen Dokumentationsaufwand der Stakeholder in der Wertschöpfungskette zu verringern. Im Rahmen der Studie wurden Experteninterviews entlang einer ausgewählten Wertschöpfungskette (Kartoffel) durchgeführt, um Herausforderungen der Digitalisierung sowohl im Bereich des Anbaus und der Produktion als auch in der Vermarktung zu analysieren. Darüber hinaus wurden die Potenziale einer automatisierten Erfassung einer Klima- und Umweltschutzmaßnahme am Beispiel des CO<sub>2</sub>-Fußabdruckes analysiert. Dazu wurden systematisch CO<sub>2</sub>-Berechnungs-Tools miteinander verglichen und automatisierte Erfassungsmöglichkeiten im landwirtschaftlichen Bereich aufgezeigt und durchleuchtet, um eine mögliche Grundlage für ein neues Zertifizierungssystem zu schaffen.

**Keywords:** Digitalisierung, Kartoffeln, automatische Datenerfassung, CO<sub>2</sub>-Zertifikate, CO<sub>2</sub>-Äquivalenzen

### 1 Einleitung

Die moderne Landwirtschaft steht vor komplexen Herausforderungen durch den Klimawandel und gesellschaftliche Erwartungen [BM19]. Die Digitalisierung bietet vielversprechende Lösungen, erfordert jedoch eine umfassende Vernetzung der Anwendungen. Diese Studie konzentriert sich auf die Entwicklung eines digitalen Zertifizierungssystems für die Kartoffel-Wertschöpfungskette, um Klima- und Umweltmaßnahmen zu dokumentieren. Mit Hilfe von qualitativen Experteninterviews mit Landwirten und Akteuren in der Kartoffel-Wertschöpfungskette werden Herausforderungen der Digitalisierung sowohl im Bereich des Kartoffelanbaus als auch in der Verarbeitung identifiziert. Zusätzlich werden Potenziale einer automatisierten Erfassung von Klima- und Umweltmaßnahmen am Beispiel des CO<sub>2</sub>-Fußabdruckes

---

<sup>1</sup> Forschungs- und Entwicklungszentrum Fachhochschule Kiel GmbH, Schwentinststraße 24, 24149 Kiel; marie.s.peters@fh-kiel.de, torben.rahn@fh-kiel.de, steffi.fock@fh-kiel.de

<sup>2</sup> Fachhochschule Kiel, Sokratesplatz 1, 24149 Kiel; holger.schulze@fh-kiel.de, yves.reckleben@fh-kiel.de

analysiert. Dazu werden bestehende CO<sub>2</sub>-Berechnungs-Tools miteinander verglichen und automatisierte Erfassungsmöglichkeiten im landwirtschaftlichen Bereich aufgezeigt und durchleuchtet. Die Ergebnisse sollen nicht nur Einblicke in Stakeholder-Bedürfnisse bieten, sondern auch die Grundlage für ein effizientes digitales Zertifizierungssystem schaffen, das zur CO<sub>2</sub>-Reduzierung beiträgt und die Klimaneutralität in der Landwirtschaft fördert.

## **2 Potenziale der Digitalisierung zur automatischen Erstellung von Zertifikaten**

Zertifikate spielen eine entscheidende Rolle in der Gewährleistung von Produktstandards für den Verkauf auf dem Zielmarkt. Gegenwärtig im Fokus stehen CO<sub>2</sub>-Zertifikate, die durch nachhaltige Praktiken auf landwirtschaftlichen Betrieben generiert werden können. Zertifizierungssysteme sind unerlässlich, um produzierte Waren in den Verkehr zu bringen, sei es durch die Einhaltung ökologischer Grundsätze oder anderer spezifischer Standards wie das EU-Biosiegel [Sa23].

Die Herausforderungen in Bezug auf Zertifikate liegen in der Vergleichbarkeit und Vertrauenswürdigkeit, da Maßnahmen noch weitgehend manuell dokumentiert werden. Die aktuelle Digitalisierung im Agrarsektor ist trotz voranschreitender Entwicklungen noch nicht ausreichend. Es fehlen anwenderfreundliche, digitale Lösungen und die notwendigen politischen Rahmenbedingungen [Me23].

Verschiedene Studien haben sich in den letzten Jahren den allgemeinen Herausforderungen in der Landwirtschaft und deren Verknüpfung mit der Digitalisierung gewidmet [Re20; RKR20; SG18]. Diese Studien analysieren nicht nur die wahrgenommenen Vor- und Nachteile der verstärkten Nutzung digitaler Alternativen, sondern auch das Akzeptanzverhalten (Bereitschaft, eine Technologie/Innovation zu akzeptieren) der Landwirte. Obwohl die Digitalisierung potenziell eine erhöhte Produktionseffizienz, Entlastung von physischen Arbeitsbelastungen und eine umweltschonende Produktion ermöglicht, stehen diverse Hindernisse im Vordergrund. Finanzielle Aspekte, Anschaffungskosten, Wirtschaftlichkeit digitaler Technologien, Netzabdeckungsdefizite und Datensicherheitsbedenken werden von Landwirten als bedeutende Hürden wahrgenommen. Dennoch zeigt sich eine grundsätzlich positive Einstellung der Landwirte gegenüber digitalen Technologien, die in den letzten Jahren sogar eine positive Entwicklung erfahren hat.

## **3 Material und Methode**

Diese Forschungsarbeit widmet sich einerseits den Herausforderungen in der Kartoffelproduktion und -vermarktung, die mit Hilfe qualitativer Experteninterviews mit Landwirten und Unternehmensvertretern identifiziert werden sollen. Andererseits wird

das Potenzial ausgewählter CO<sub>2</sub>-Berechnungs-Tools im Hinblick auf diese Herausforderungen analysiert, mit dem Ziel, eine Grundlage für die Entwicklung eines neuen CO<sub>2</sub>-Berechnungs-Tools zu schaffen. Die Interviews, durchgeführt von August bis Oktober 2023, bieten einen guten ersten Einblick in betriebliche Aspekte, Herausforderungen, Entwicklungspotenziale und die Akzeptanz digitaler Technologien. Die Landwirte aus Schleswig-Holstein und Niedersachsen (Ø Betriebsgröße: 412 ha; Ø prozentualer Anbau von Kartoffeln zur Gesamtbetriebsgröße: 26 %) ermöglichen eine Analyse des Status quo in der Kartoffelproduktion.

Die Interviews wurden anhand eines Leitfadens strukturiert, um einen schrittweisen Ansatz von allgemeinen zu spezifischen Themen zu gewährleisten. Durch die Verwendung offener und ungestützter Fragen wurde ein Verständnis für die Herausforderungen und Potenziale geschaffen. Die Codierung und Analyse der gesammelten Daten erfolgte mit der Software MaxQDA, wobei der methodische Ansatz auf einer eingehenden Literaturanalyse basierte [MA15].

Parallel dazu erfolgte die Analyse ausgewählter CO<sub>2</sub>-Berechnungs-Tools im Zeitraum von September bis Oktober 2023. Vier identifizierte Tools wurden hinsichtlich Anwendungsland, Anzahl berücksichtigter Kriterien und Eingabeoptionen systematisch untersucht. Die daraus gewonnenen Erkenntnisse bieten eine Grundlage für den Vergleich mit realen Produktionsdaten, die in einer umfassenden Datenbank im Rahmen von Kooperationen mit Projekten und der Firma Exatrek gesammelt wurden.

## **4 Vorläufige Ergebnisse**

### **4.1 Ergebnisse der qualitativen Befragung der Landwirte und Unternehmensvertreter**

Die Studie präsentiert vorläufige Ergebnisse aus ersten Gesprächen mit Vertretern entlang der Kartoffel-Wertschöpfungskette. Es wird deutlich, dass CO<sub>2</sub>-Zertifikate künftig eine zentrale Rolle in der Vermarktung von Kartoffeln und ihren Produkten spielen können. Die derzeitigen Mechanismen zur CO<sub>2</sub>-Erfassung in der Kartoffelproduktion erweisen sich als unzureichend, wodurch die Dringlichkeit einer datenbasierten Herangehensweise betont wird. Unternehmen streben eine umfassende Datengrundlage an, um CO<sub>2</sub>-Äquivalente präzise zu ermitteln und den steigenden Anforderungen an eine klimaneutrale Produktion gerecht zu werden. Die Rückmeldung der Befragten hebt zudem die wachsende Bedeutung des Klimawandels, insbesondere im Hinblick auf den Wasserbedarf für die Kartoffelproduktion, hervor und plädiert für die Einführung von Wasser-Effizienz-Zertifikaten. Transparenz bei Pflanzenschutz- und Düngemaßnahmen wird als entscheidend erachtet, um regulatorischen Anforderungen und öffentlichen Bedenken gerecht zu werden.

Die Gespräche mit landwirtschaftlichen Betriebsleitern offenbaren vielfältige Herausforderungen für die Kartoffelproduktion, darunter Klimawandel, Pflanzenschutzregelungen und Marktpreisschwankungen. Dennoch betrachten die Befragten den Anbau von Kartoffeln weiterhin als vielversprechend für die Zukunft. In Bezug auf die Datenerfassung setzen 60 % der Landwirte auf teilweise automatische Erfassung, vorrangig für Arbeitsschritte wie Dünge- und Pflanzenschutzmaßnahmen. Die Übertragung dieser Daten an kompatible Ackerschlagkarteien wird angestrebt, wobei Bedenken hinsichtlich der Transparenz und der Kontrollen existieren. Trotz infrastruktureller Herausforderungen überwiegen die wahrgenommenen Vorteile der automatisierten Datenerfassung. Die automatisierte Datenerfassung für das zukünftige effiziente Management landwirtschaftlicher Betriebe, wird entgegen bestehenden Herausforderungen unabdingbar in der Landwirtschaft werden.

## 4.2 CO<sub>2</sub>-Berechnungs-Tools im Vergleich

Im Verlauf der Studie wurde ein Vergleich von vier CO<sub>2</sub>-Berechnungs-Tools in der Landwirtschaft (Agrocleantech, Hunter, CoolFarmTool und das Tool der Bayerischen Landesanstalt für Landwirtschaft) durchgeführt. Zusätzlich wurde das „Exatrek“-System der Exa Computing GmbH als Beispiel für eine telemetriebasierte Datenaufzeichnung herangezogen und auf die Anwendbarkeit von CO<sub>2</sub>-Berechnungen geprüft. Ziel dieses Vergleiches war es, die unterschiedlichen Herangehensweisen, Genauigkeiten und Herausforderungen bei der Bestimmung des CO<sub>2</sub>-Fußabdrucks in landwirtschaftlichen Betrieben zu analysieren.

Die ersten vier Systeme erfordern eine rein manuelle Dateneingabe, wobei erhebliche Unterschiede im Umfang und in der Art der einzugebenden Daten bestehen. Insbesondere fallen Agrocleantech und CoolFarmTool durch eine geringere Anzahl berücksichtigter Indikatoren für die Berechnung auf, während das Tool von Hunter und der Bayerischen Landesanstalt für Landwirtschaft zusätzlich ackerbauliche Maßnahmen und den Betriebsmitteleinsatz einbeziehen. Diese Vielfalt in den Herangehensweisen führt zu Schwankungen in der Quantität der zur Berechnung herangezogenen Parameter und somit ebenfalls in der Qualität des berechneten CO<sub>2</sub>-Fußabdruckes.

Im Gegensatz zu diesen manuellen Verfahren sticht das Exatrek-System hervor, das eine digitale Datenerfassung während der ausgeführten Arbeit auf dem Schlepper ermöglicht. Eine Vielzahl an Parametern, die in den vorab betrachteten CO<sub>2</sub>-Berechnungs-Tools zur Berechnung des CO<sub>2</sub>-Fußabdruckes herangezogen werden, können automatisch durch eine Telemetrieinheit erfasst werden. Mit Hilfe der gesammelten Daten ist es möglich, faktenbasiert den CO<sub>2</sub>-Ausstoß zu berechnen und auszugeben.

Die manuelle Eingabe von Daten in den jeweiligen betrachteten Tools zeigt Schwierigkeiten auf, da nicht eindeutig erkennbar ist, welche Informationen explizit gemeint sind. Diese Unklarheiten können zu Fehlern führen, die die Genauigkeit der CO<sub>2</sub>-Berechnungen beeinträchtigen. Zudem erfordert die manuelle Dateneingabe einen hohen

Zeitaufwand, während bei Exatrek der Zeitaufwand durch die automatische Datenerfassung erheblich reduziert wird. Es ist erkennbar, dass es verschiedene Ansätze zur Berechnung des CO<sub>2</sub>-Fußabdruckes gibt. Dennoch wird aus der Vielzahl der unterschiedlichen vorhandenen Tools deutlich, dass die Bedeutung der Berechnung und damit der Standardisierung des CO<sub>2</sub>-Fußabdruckes zunimmt und somit auch die Automatisierung dieses Prozesses unabdingbar wird, da die Datenqualität einen entscheidenden Stellenwert zur Identifizierung des individuellen CO<sub>2</sub>-Fußabdruckes hat. Auch die Benutzerfreundlichkeit des Tools ist für eine fehlerfreie Berechnung essenziell.

## 5 Diskussion und Schlussfolgerung

Die vorliegende Studie bietet eine erste Beurteilung der Fragestellung, ob und wie ein digitales Zertifizierungssystem entlang der Wertschöpfungskette Kartoffeln zukünftig aussehen kann. Aufgrund der geringen Anzahl an Experten werden die gewonnenen Erkenntnisse nicht als repräsentativ angesehen, dennoch gibt es aufschlussreiche Anhaltspunkte für weiterführende Befragungen zu dieser Thematik. Die Ergebnisse aus den qualitativen Interviews mit den Landwirten zeigen deutlich auf, dass die Landwirtschaft derzeit vor viele Herausforderungen gestellt wird, die durch den Einsatz von digitalen Hilfsmitteln sachgerecht gelöst und dokumentiert werden können. Die aus der Literatur gewonnene Erkenntnis, dass das Akzeptanzverhalten von Landwirten gegenüber der Digitalisierung tendenziell zukünftig steigen wird, konnte in dieser Untersuchung bestätigt werden. Viele Landwirte sehen die Digitalisierung in Zukunft als essenzielles Tool, um ein gutes Management durchzuführen. Eine digitale und automatisierte Datenerhebung zur Erfassung des CO<sub>2</sub>-Fußabdrucks kann sowohl die Arbeitsintensität als auch die Genauigkeit der Auswertung verbessern. Ebenso zeigt die Umfrage, dass ein solches Vorgehen von den Landwirten als positiv empfunden wird. Durch die Vielzahl an erheblichen Indikatoren sind die einzelnen Tools untereinander kaum zu vergleichen. Dies benötigt eine genauere Betrachtung.

Aus dem Vergleich der verschiedenen Berechnungs-Tools für einen CO<sub>2</sub>-Fußabdruck ist deutlich erkennbar, dass zur Berechnung verschiedene Indikatoren herangezogen werden. Es wird somit ersichtlich, dass es kein standardisiertes Verfahren zur Berechnung eines CO<sub>2</sub>-Fußabdruckes gibt und diese nicht miteinander vergleichbar sind. Zukünftig wäre eine Standardisierung des Verfahrens sinnvoll. Dennoch ist unverkennbar, dass mit dem Einsatz eines Telemetriesystems eine automatische Erfassung möglich wäre, die die wahrgenommenen Vorteile aus dem vorherigen Kapitel positiv beeinflussen. Nicht nur für die Landwirtschaft bietet die Automatisierung der Datenerfassung einen Vorteil. Diese Daten könnten mit wenig Aufwand an weitere Schnittstellen, wie Beratungsringe, Kammern oder private Berater weitergeleitet werden und ermöglichen eine schnellere Datenauswertung sowie weitere Zeitersparnis. Die Folgen einer möglichen Datentransparenz über verschiedene Instanzen hinweg sollten in weiteren Studien untersucht werden.

Abschließend zeigen die Ergebnisse, dass zukünftig die Digitalisierung einen signifikanten Stellenwert in der Landwirtschaft hinsichtlich Management und Planung sowie Durchführung von Produktionsschritten einnehmen wird. Dabei ist eine Entwicklung eines automatischen Erfassungssystems, welches kompatibel mit der Ackerschlagkartei sowie verpflichtenden Meldesystemen ist, unverzichtbar. Zudem könnten möglicherweise diese Daten mit Hilfe der untersuchten Blockchain-Telemetrie automatisch erfasst und zu Zertifikaten, die automatisch anhand von vorab definierten Indikatoren erstellt werden, umgewandelt und anschließend in der Wertschöpfungskette weitergeleitet werden.

#### Literaturverzeichnis

- [BM19] Bundesministerium für Ernährung und Landwirtschaft: Diskussionspapier Ackerbaustrategie 2035 Perspektiven für einen produktiven und vielfältigen Pflanzenbau. [https://www.bmel.de/SharedDocs/Downloads/DE/Broschueren/Ackerbaustrategie.pdf?\\_\\_blob=publicationFile&v=15](https://www.bmel.de/SharedDocs/Downloads/DE/Broschueren/Ackerbaustrategie.pdf?__blob=publicationFile&v=15): Stand 18.10.2023.
- [Ma15] Mayring, P.: Qualitative Inhaltsanalyse. Grundlagen und Techniken, 12, Beltz Verlagsgruppe, Weinheim, 2015.
- [Me23] von Meyer-Höfer, M. et al.: Klimaschonende Landwirtschaft angehen – Dialog zwischen Verbrauchern und Landwirten fördern, <https://www.thuenen.de>: Stand 27.10.2023.
- [Re20] Reissig, L.: Wahrnehmung der Digitalisierung in der Landwirtschaft durch Betriebsleiter von Betriebsgemeinschaften in der Schweiz. <https://dl.gi.de/server/api/core/bitstreams/6c4437e7-4da0-44a8-ba29-a226d994d765/content>: Stand 28.10.2023.
- [RKR20] Rohleder, B.; Krüskens, B.; Reinhardt, H.: Digitalisierung in der Landwirtschaft 2020. [https://www.bitkom.org/sites/main/files/2022-01/27.04.20\\_digitalisierung-in-der-landwirtschaft-2020.pdf](https://www.bitkom.org/sites/main/files/2022-01/27.04.20_digitalisierung-in-der-landwirtschaft-2020.pdf): Stand: 20.10.2023.
- [SG18] Schleicher, S.; Gandorfer, M.: Digitalisierung in der Landwirtschaft: Eine Analyse der Akzeptanzhemmnisse. [https://www.lfl.bayern.de/mam/cms07/ilt/dateien/digitalisierung\\_in\\_der\\_landwirtschaft-eine\\_analyse\\_der\\_akzeptanzhemmnisse.pdfS23](https://www.lfl.bayern.de/mam/cms07/ilt/dateien/digitalisierung_in_der_landwirtschaft-eine_analyse_der_akzeptanzhemmnisse.pdfS23)] Société Générale de Surveillance: Audits und Zertifizierung, <https://www.sgs.com>: Stand 26.10.2023.
- [Sa23] Saurer, J.: Bausteine eines Rechtsrahmens für CO<sub>2</sub>-Entnahmemechanismen im EU-Recht, <https://doi.org/>: Stand 26.10.2023.



## Verbindung von Wissenschaft und Praxis: WiLaDi

### Ein Instrument zur Beurteilung der Wirtschaftlichkeit landwirtschaftlicher Digitalisierung

Sara Anna Pfaff<sup>1</sup> und Johannes Munz<sup>1</sup>

**Abstract:** Mittlerweile stehen zahlreiche digitale Technologien in der Landwirtschaft zur Verfügung, welche positive Effekte auf die ökologische, ökonomische und soziale Nachhaltigkeit versprechen. Allerdings ist die aktive Nutzung digitaler Technologien z. T. verhalten, was sich vor allem mit finanziellen Barrieren begründen lässt. Aktuell gibt es nur bedingt Möglichkeiten für Landwirte, herstellerunabhängige Informationen und Entscheidungsunterstützungen zu nutzen. Daher wurde im Rahmen des DiWenkLa-Projektes in den Jahren 2021 und 2022 das ökonomisch basierte Online-Tool „WiLaDi“ (Wirtschaftlichkeitsrechner Landwirtschaft Digital) entwickelt. WiLaDi basiert auf einem ökonomischen Modell orientiert an der Leistungs-Kostenrechnung und berücksichtigt insgesamt 27 Technologievariationen im Ackerbau. Das Tool ermöglicht es Landwirten, die Kosten und Nutzen je Technologie betriebsindividuell zu errechnen sowie weiteres technologiespezifisches Informationsmaterial einzusehen. Zukünftig soll WiLaDi nicht nur auf der einzelbetrieblichen Ebene, sondern auch in Kooperation mit Bildungs- und Beratungsakteuren nutzbar sein.

**Keywords:** Digitalisierung, Entscheidungsunterstützung, Economies of Scale, Precision Agriculture

## 1 Einleitung

Oftmals versprechen digitale Technologien in der Landwirtschaft positive Effekte auf die ökologische, ökonomische und soziale Nachhaltigkeit. Demnach ist das politische, aber auch das gesamtgesellschaftliche Interesse an dieser Thematik ebenfalls hoch. Dennoch ist die Nutzung digitaler Technologien v. a. in kleinstrukturierten Agrarregionen (z. B. Bayern, Baden-Württemberg) zurückhaltender [GG22; Pf22] als in großstrukturierten Regionen Deutschlands. Gemäß bisherigen Studien hemmen vor allem die fehlende Übersichtlichkeit über die verfügbaren Technologien sowie die Ungewissheit über die einzelbetriebliche Profitabilität digitaler Technologien [Ko21; GG22]. Bisher sind die Möglichkeiten für Landwirt:innen, sich herstellerunabhängige Informationen einzuholen und Entscheidungsunterstützungen zu nutzen, begrenzt [Ci20; Sh21].

---

<sup>1</sup> Hochschule für Wirtschaft und Umwelt Nürtingen-Geislingen, Institut für Angewandte Agrarforschung (IAAF), Neckarsteige 6-10, 72622 Nürtingen, sara.pfaff@hfwu.de, johannes.munz@hfwu.de

Bisher wurden vereinzelt Tools entwickelt, welche den ökonomischen Nutzen einzelner Technologiebereiche im Ackerbau anhand von Ertrags- und Flächendaten errechnen, um Landwirt:innen in der Entscheidungsfindung zu unterstützen [Me21]. Allerdings berücksichtigen diese Tools nicht das Zusammenspiel agrarstruktureller Charakteristiken wie z. B. die durchschnittliche Größe der Schläge sowie den bisherigen Mechanisierungsgrad und Maschinenpark eines Betriebes. Zudem sind bisherige Tools oftmals rein wissenschaftlich aufgebaut, sodass die Anwenderfreundlichkeit für die landwirtschaftliche Praxis u. U. zurückbleibt. Eine vollumfängliche Betrachtung der potenziell verfügbaren Technologien sowie eine ganzheitliche Sicht auf den Betrieb ist unerlässlich, um Betriebsleitenden eine realistische Entscheidungsunterstützung anbieten zu können. Darüber hinaus fehlt es an Tools, die gleichzeitig zur Berechnung der Leistung und Kosten praxisrelevante, technologiespezifische und wissenschaftlich basierte Informationen zur Verfügung stellen. Tatsächlich würde dies aber den Entscheidungsprozess der Landwirte maßgeblich unterstützen.

## 2 Material und Methoden

Im Rahmen des DiWenkLa-Projektes in Baden-Württemberg wurde das ökonomisch basierte Online-Tool „WiLaDi“ (Wirtschaftlichkeitsrechner Landwirtschaft Digital) im Jahr 2021 und 2022 entwickelt. Der Wirtschaftlichkeitsrechner ist über den Link <https://wiladi.netscrappers.com/> öffentlich zugänglich. Das Tool stützt sich auf ein ökonomisches Modell basierend auf der Leistungs-Kostenrechnung bei dem die technologiebedingten Veränderungen bis zur Stufe der Direkt- und Arbeitserledigungskostenfreien Leistung (DAKfL) berechnet werden. Eine Zusammenfassung der Methodik wird in Abbildung 1 dargestellt. Die Berechnung gliedert sich in (1) die Profitabilitätsgrenzen sowie (2) den Vergleich der betrieblichen Situation mit und ohne Investition in die jeweilige Technologie:

- (1) **Profitabilitätsgrenzen:**  $\Delta \text{DAKfL} \geq 0$  oder  $\text{DAKfL}_{\text{Digitale Technologie}} \geq \text{DAKfL}_{\text{Status quo}}$
- (2) **Vergleich der Technologien:**  $\Delta \text{DAKfL} = \text{DAKfL}_{\text{Digitale Technologie}} - \text{DAKfL}_{\text{Status quo}}$

Zur Erstellung der Datenbanken für die digitalen Technologien wurde eine umfassende Literaturrecherche durchgeführt. Ferner wurden für die ökonomische Modellierung öffentlich zugängliche Daten des Kuratoriums für Technik und Bauwesen in der Landwirtschaft (KTBL) verwendet. Im Rahmen des Berechnungsmodells werden insgesamt 27 Technologievariationen in neun Technologiegruppen im Ackerbau berücksichtigt: (1) GPS-Lenkssysteme, (2) Hacktechnik, (3) Section Control, (4) Teilflächenspezifische(r) Bodenbearbeitung / (5) Aussaat / (6) Kalkung / (7) Min. N-Düngung / (8) Pflanzenschutz / (9) organische Düngung (siehe Tab. 1).

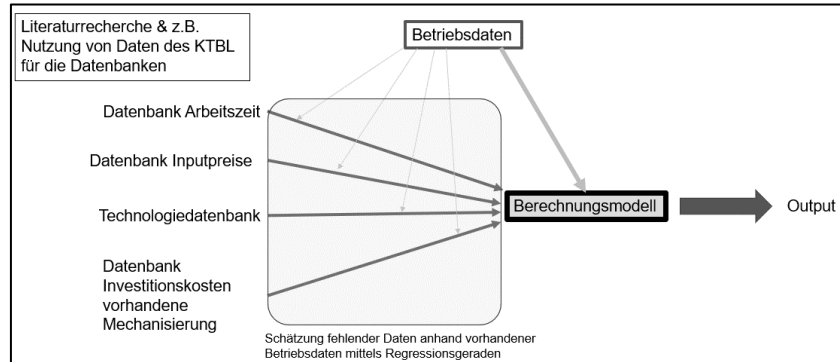


Abb. 1: Zusammenfassung der Methodik von WiLaDi

| Technologiebereich                        | Technologieart   |
|---|--|
| GPS-Lenksysteme                           | Lenkhilfen   Lenkassistenten   Lenkautomat Traktor 1 (Haupttraktor, schwere Arbeiten)   Lenkautomat Traktor 2 (Pflegetraktor)   Lenkautomat T1-2 |
| Hacktechnik                               | GPS-gesteuert   Kamera-gesteuert   Sensor-gesteuert   Sensor+GPS   |
| Section Control                           | Drill-Saat   Einzelkorn-Saat   N-Düngung   Pflanzenschutz  |
| Teilflächenspezifische Bodenbearbeitung   | Offline Lenkassistent   Offline Lenkautomat   Online   Online Lenkautomat  |
| Teilflächenspezifische Aussaat            | Drillsaat   Einzelkornsaat   |
| Teilflächenspezifische Kalkung            |  |
| Teilflächenspezifische Min. N-Düngung     | Offline Lenkassistent   Offline Lenkautomat   Online (Lenksystem nicht erforderlich)   Online mit Kartenüberlagerung                             |
| Teilflächenspezifischer Pflanzenschutz    | Offline   Online   |
| Teilflächenspezifische organische Düngung |  |

Tab. 1: Berücksichtigte Technologiebereiche in WiLaDi

Begleitend wurden die Ergebnisse der Literaturrecherche dazu verwendet, Informationsmaterial für Nutzer:innen von WiLaDi für die folgenden Themenbereiche zu erarbeiten: Gründe für Digitalisierung im Ackerbau, Vorgehensweise zur Investition in digitale Technologien, Definition der teilflächenspezifischen Bewirtschaftung und Umsetzung sowie spezifische Informationen je Technologievariation.

### 3 Ergebnisse

WiLaDi stellt eine Onlineanwendung dar, welche (konventionellen) Landwirt:innen eine herstellerunabhängige und betriebsspezifische Einschätzung der ökonomischen Vorteilhaftigkeit digitaler Technologien im Ackerbau ermöglicht. Nutzer:innen geben die benötigten betriebsindividuellen Daten ein und erhalten eine entsprechende Berechnung der zusätzlichen Kosten und Nutzen je Technologievariation, die genauere Funktionsweise wird mithilfe von Abbildungen 2 und 3 näher dargestellt.




Abb. 2: Funktionsweise von WiLaDi aus Nutzersicht

Zunächst starten Nutzer:innen die Anwendung, indem Angaben zur Anzahl der Schläge, die Art der angebauten Kultur mit Flächenanteil, Ertrag pro Hektar sowie Preis pro Tonne in den Wirtschaftlichkeitsrechner eingepflegt werden. Das System schlägt automatisch Preise vor, diese können aber bei Bedarf angepasst werden. Im zweiten Schritt erfolgt dann die Angabe der genutzten Dienstleistungen. Anschließend wird im letzten Schritt die Mechanisierung intensiver beleuchtet. Nutzer:innen können für den Haupt- und Pflgetraktor jeweils die Leistung (in kW) angeben. Zusätzlich kann die Verfügbarkeit von verschiedenen Anbaugeräten kenntlich gemacht werden.

Für die Berechnung benötigte zusätzliche Daten (wie z. B. Betriebsmittelaufwände, benötigte Arbeitszeiten je Arbeitsgang) werden im Hintergrund über Regressionsgeraden ergänzt und sind auf die betrieblichen Gegebenheiten angepasst. Hierzu müssen Nutzer:innen folglich keine Angaben tätigen.

Bevor die eigentliche Berechnung der Rentabilität initiiert werden kann, können Nutzer:innen spezifisch auswählen, welche Technologie in die Berechnung miteinbezogen werden soll. Dies verhindert, dass die Berechnungsergebnisse zu komplex sind, da sich diese somit auf den aus Nutzersicht präferierten Technologiebereich fokussiert.

Im Anschluss erhält der Nutzende die visualisierte Berechnung der zusätzlichen Kosten und Nutzen bei Anschaffung der zuvor ausgewählten Technologie (siehe Abb. 3).



Abb. 3: Beispielhafter Ergebnisüberblick von WiLaDi für die Technologiegruppe „Lenksysteme“ aus Nutzersicht

Durch die detaillierte Berücksichtigung der vorhandenen Mechanisierung auf den Betrieben wird ermöglicht, dass Investitionsentscheidungen passend zum Maschinenpark und dessen Leistungsvermögen getätigt werden können. Zusätzlich zum ersten Ergebnisüberblick können detailliertere Ergebnisse (siehe Abb. 3, „Details“) zur durchschnittlichen (jährlichen) Veränderungen der Leistung, den Direktkosten, variablen und fixen Arbeiterledigungskosten eingesehen werden. Die Berechnungsergebnisse in WiLaDi sind nicht absolut, sondern vielmehr erste faktenbasierte und neutrale Einschätzungen, um die Entscheidungsfindung aus Nutzersicht unterstützen zu können. Ferner wird über das Online-Tool Informationsmaterial zu den jeweiligen Technologien und weiterführenden Thematiken zur Verfügung gestellt. Je Technologievariation sind Erklärungen zur Funktionsweise, Umsetzung in der Praxis, Anschaffungskosten und Besonderheiten einsehbar.

#### 4 Fazit und Ausblick

WiLaDi stellt ein herstellernertrales und wissenschaftsbasiertes Tool dar, welches es Landwirt:innen ermöglicht, die finanziellen Folgen (Kosten und Nutzen) verschiedener digitaler Technologien im Ackerbau für den eigenen Betrieb abschätzen zu können. Dies ist insbesondere für Betriebe in kleinstrukturierten Agrarregionen relevant, generell ist das Tool aber skalenneutral nutzbar. Im Jahr 2023 wurden mithilfe einer quantitativen Befragung Nutzertests mit Landwirt:innen, aber auch anderen Stakeholder:innen im Agrarumfeld durchgeführt, um das Tool explizit weiterzuentwickeln. Momentan werden qualitative Interviews gemäß der Think-Aloud-Methode zur Untersuchung der Benutzerfreundlichkeit von WiLaDi mit Landwirt:innen durchgeführt, um die Entwicklung des Tools final abzuschließen.

Zukünftig ist die Nutzung des Wirtschaftlichkeitsrechners sowohl auf einzelbetrieblicher Ebene als auch in Kooperation mit Bildungs- und Beratungsakteuren möglich. Diesbezüglich sind weitere Forschungs- und Vernetzungsaktivitäten mit der Praxis geplant.

**Förderhinweis:** Die Förderung des Vorhabens DiWenkLa (Digitale Wertschöpfungsketten für eine nachhaltige kleinstrukturierte Landwirtschaft) erfolgt aus Mitteln des Bundesministeriums für Ernährung und Landwirtschaft. Das Vorhaben wird ebenfalls durch das Ministerium für Ernährung, Ländlichen Raum und Verbraucherschutz Baden-Württemberg unterstützt. Die Projektträgerschaft erfolgt über die Bundesanstalt für Landwirtschaft und Ernährung im Rahmen des Programms zur Innovationsförderung unter dem Förderkennzeichen 28DE106B18. Das Vorhaben wird ebenfalls durch das Ministerium für Ernährung, Ländlichen Raum und Verbraucherschutz Baden-Württemberg unterstützt.

#### Literaturverzeichnis

- [Ci20] Cisternas, Isabel et al.: Systematic literature review of implementations of precision agriculture. In: *Computers and Electronics in Agriculture* 176, S. 105626, 2020. DOI: 10.1016/j.compag.2020.105626.
- [GG22] Gabriel, Andreas; Gandorfer, Markus: Adoption of digital technologies in agriculture – an inventory in a European small-scale farming region. In: *Precision Agric.* DOI: 10.1007/s11119-022-09931-1, 2022.
- [Ko21] Kolady, Deepthi E. et al.: Determinants of adoption and adoption intensity of precision agriculture technologies: evidence from South Dakota. In: *Precision Agric* 22 (3), S. 689–710, 2021. DOI: 10.1007/s11119-020-09750-2.
- [Me21] Medici, M. et al.: A web-tool for calculating the economic performance of precision agriculture technology. In: *Computers and Electronics in Agriculture* 181, S. 105930, 2021. DOI: 10.1016/j.compag.2020.105930.
- [Pf22] Pfaff, S. et al.: Nutzung digitaler Technologien in der kleinstrukturierten Landwirtschaft Baden-Württembergs. DiWenkLa Ergebnisbericht - Band 1. Hg. v. DiWenkLa. Hochschule für Wirtschaft und Umwelt Nürtingen (HfWU); Universität Hohenheim (UHOH), 2022. Online verfügbar unter [https://diwenkla.uni-hohenheim.de/ergebnisbericht\\_befragung\\_baden-wuerttemberg](https://diwenkla.uni-hohenheim.de/ergebnisbericht_befragung_baden-wuerttemberg), zuletzt geprüft am 04.10.2023
- [Sh21] Shang, Linmei et al.: Adoption and diffusion of digital farming technologies - integrating farm-level evidence and system interaction. In: *Agricultural Systems* 190, S. 103074, 2021. DOI: 10.1016/j.agsy.2021.103074.

## Vergleich zwischen luft- und bodengeführten Laser- Scannern zur Bestimmung der Laubwandhöhe im Weinbau

Björn Poss<sup>1</sup>, Nikos Tsoulas<sup>1</sup>, Andreas Heiß<sup>1</sup> und Dimitrios S. Paraforos<sup>1</sup>

**Abstract:** Die Methode zur Ermittlung der Dosierung von Pflanzenschutzmitteln im Weinbau basiert nach aktueller guter fachlicher Praxis auf dem Laubwandflächenmodell. Eine der für diese Berechnung benötigten Größen ist die Laubwandhöhe. Diese kann im Bestand jedoch sehr variabel sein, was bei manueller Messung an nur einigen wenigen Stellen zu einer ungenauen Aufwandmengkalkulation führt. Ziel dieser Arbeit war es daher, neue Verfahren zur genaueren Bestimmung der Laubwandhöhe im Bestand zu untersuchen. Mithilfe von Laser-Scannern, die sowohl vom Boden aus während Überfahrten als auch mit Drohnen aus der Luft Daten aufnehmen, soll der Bestand analysiert und die Laubwandhöhe ermittelt werden. Dazu wurden die Sensorsysteme validiert und beide Verfahren miteinander verglichen.

**Keywords:** Laser-Scanner, Weinbau, Laubwandhöhe, UAV, LiDAR

### 1 Einleitung

Der Pflanzenschutz spielt im Weinbau nach wie vor eine entscheidende Rolle und befindet sich im ständigen Wandel. Dazu gehören neben den rechtlichen Rahmenbedingungen auch der Schutz des Klimas und der Umwelt. Ein wichtiger Bestandteil dabei ist die Einsparung und bedarfsorientierte Ausbringung von Pflanzenschutzmitteln. Durch die in der EU angestrebte Vereinheitlichung der Dosiermodelle werden in Zukunft Mengenangaben auf die tatsächlich zu behandelnde Fläche bezogen. Das daraus in Deutschland entstandene neue Dosiermodell, auch Laubwandflächenmodell genannt, bezieht sich somit auf die effektiv zu behandelnde Laubwandfläche inklusive des Entwicklungsstadiums der Reben [LW23]. Trotz der dadurch entstehenden präziseren Dosierung bleibt das Problem der Inhomogenität der Laubwandhöhe im Bestand, welche zur neuen Dosiermengenberechnung benötigt wird. Fehlende Stöcke und Lücken in der Laubwand werden nicht berücksichtigt und können zu einer Fehldosierung führen. Durch die Nutzung von Laser Scannern lassen sich solche Höhenunterschiede im Bestand detektieren [Ar12] und anschließend in Form von bspw. Applikationskarten zur variablen Ausbringung adressieren.

Die Analyse von Pflanzen mithilfe von Laser-Scannern wurde bereits vielfach untersucht. Sowohl bodenbasierte, d.h. von Fahrzeugen getragene [Ts19; Sa22], als auch luftbasierte,

---

<sup>1</sup> Hochschule Geisenheim University, Von-Lade-Straße 1, 65366 Geisenheim, Korrespondenz:  
Bjoern.Poss@hs-gm.de

d.h. von Unmanned Aerial Vehicles (UAV) getragene, Sensor-Systeme [Hü22] können hierbei zur Datenerfassung verwendet werden. Ebenso sind eine Vielzahl anderer Verfahren zur Bestimmung von Laubwandgeometrien im Weinbau, wie etwa die Nutzung von multispektralen Sensoren oder auch photogrammetrischer Aufnahmen, vielversprechend [Pa22].

Das übergeordnete Ziel dieser Arbeit bestand darin, eine Methodik zur Bestimmung von Laubwandparametern mithilfe von Light-Detection-and-Ranging (LiDAR)-Systemen aus der Luft und vom Boden zu entwickeln. Die spezifischen Ziele dieser Studie waren darauf ausgerichtet, die Messunsicherheit dieser LiDAR-Systeme durch die Analyse einer rechteckigen Platte mit bekannten Abmessungen im Feld zu testen. Die Auswertung der Punktwolken einer Laubwand erfolgte in drei Dimensionen und fokussierte sich insbesondere auf die Anwendung in Weinbergen.

## 2 Material und Methoden

### 2.1 Datenerfassung

Zur bodengeführten Datenerfassung wurde ein Sensorrahmen, ausgestattet mit drei Sensoren, an den Frontanbau eines Schmalspurschleppers montiert. Ein LiDAR (Puck Lite VLP-16, Velodyne, San José, CA, USA) lieferte hierbei die 3D-Punktwolke. Ein RTK-GNSS Receiver (R10, Trimble, Sunnyvale CA, USA) sorgte für die Positionsbestimmung in WGS84-Koordinaten, während die Lage der Punktwolke im Raum zusätzlich zu den anderen beiden Sensoren mit einer Inertial Measurement Unit (IMU) gemessen wurde (VN-100, VectorNav, Dallas, TX, USA). Die Traktorgeschwindigkeit lag bei  $0,5 \text{ km h}^{-1}$  und der senkrecht zum Rahmen befestigte LiDAR war in Richtung der vertikalen Laubwand bzw. der Validierungsplatte ausgerichtet. Für die Sensordatenfusion und Rekonstruktion der Punktwolke wurde die Software Matlab R2023a (MathWorks, Natick, MA, USA) verwendet.

Die Aufnahmen aus der Luft erfolgten mit einem UAV (Matrice 300 RTK, DJI, Shenzhen, China) und einem darauf montierten LiDAR (Zemuse L1, DJI, Shenzhen, China) mit integrierter IMU und GNSS-RTK. Die Flughöhe lag bei 12 m und die Fluggeschwindigkeit bei  $1,5 \text{ m s}^{-1}$ . Der LiDAR war in einem Winkel von  $40^\circ$  schräg zur horizontalen Achse des UAV montiert. Die Aufnahmen wurden von allen vier Perspektiven bzw. Himmelsrichtungen im konstanten Winkel gemacht. Mithilfe der Software DJI Terra (DJI, Shenzhen, China) wurde im Anschluss die Punktwolke rekonstruiert.

Die Datenerfassung der hier vorgestellten Aufnahmen wurde für beide Varianten am 10. August 2023 bei voller Laubwand durchgeführt. Nach der Rekonstruktion der Punktwolke wurde die Laubwand manuell segmentiert, wobei nicht zwischen den



Messpunkten des Rebholzes in der Laubwand und denen des Laubs zur Höhenberechnung unterschieden wurde.

## 2.2 Sensorvalidierung

Zur Ermittlung der Messunsicherheit unter realistischen Szenarien wurde eine rechteckige Platte (1 x 2 m) genutzt, welche eine reale Laubwand repräsentiert (**Fehler! Verweisquelle konnte nicht gefunden werden.**). Die schachbrettartig angeordneten schwarzen und weißen Kacheln (25 x 25 cm,  $n = 36$ ) dienen dabei für Reflexionskalibrierungen der Sensoren, welche jedoch nicht in die vorliegenden Untersuchungen einfließen. Die Platte wurde von beiden Systemen in den Distanzen und Geschwindigkeiten gescannt, welche auch bei den Messungen im Weinberg gegeben waren. Ebenso entspricht das Koordinatensystem dem der realen Messung im Weinberg.




Abb. 1: Validierungsplatte inkl. der maximalen Höhe und Breite der Spalten bzw. Reihen

Jede Reihe (R) und Spalte (C) der Platte wurde anhand der Abmessungen der Kacheln unterteilt. Alle R und C wurden in eine bestimmte Anzahl von Intervallen (Boden:  $n = 371$  und  $179$ , Luft:  $n = 157$  und  $435$ ) unterteilt, in denen der Abstand zwischen dem minimalen und maximalen Punkt berechnet wurde. Die Intervallgröße wurde mithilfe einer separaten Fehlerberechnung für jede Zeile und Spalte festgelegt. Für die daraus resultierenden

Zeilen- und Spaltenlängen, respektive die Höhen und Breiten der Platte, wurde anschließend eine Fehlerberechnung durchgeführt. Hierbei wurde der Mittelwert (M), das Maximum (Max), das Minimum (Min), die Standardabweichung (SD), der Standardfehler (SEM), der Bias (MBE) und die Wurzel der prozentual ausgedrückten mittleren Fehlerquadratsumme (RMSE) berechnet.

### 3 Ergebnisse und Diskussion

#### 3.1 Sensorvalidierung

Die Ergebnisse zeigen, dass die Standardabweichungen bezogen auf die Breite zwischen boden- und luftbasierten Daten mit ca. 0,025 m nahezu gleich sind, wohingegen der Standardfehler von 0,0013 m und respektive 0,002 m einen deutlich größeren Unterschied aufweist (Tab. 1). Ähnliche Verhältnisse sind auch bei der Höhenberechnung ersichtlich. Ein weiterer Unterschied zwischen den Ergebnissen von Höhe und Breite ist der Bias. Dieser weist luftbasiert mit -0,0308 m bzw. bodenbasiert -0,0377 m in der Höhenkalkulation eine um drei- bis viermal so hohe Abweichung auf als in der Breite (-0,0119 m bzw. -0,011 m). Auch der RMSE zeigt ebenso einen klaren Unterschied zwischen Höhe (max. 5,68 %) und Breite (max. 3,12 %) auf. In Bezug auf die beiden Aufnahmevarianten zeigt sich weiterhin, dass in SD, SEM, MBE und RMSE die Fehler bei der Höhenberechnung bodenbasiert größer sind als luftbasiert. Bei der Breite hingegen ist es genau umgekehrt.

|        |       | $X_M$<br>[m] | $X_{max}$<br>[m] | $X_{min}$<br>[m] | SD<br>[m] | SEM<br>[m] | MBE<br>[m] | RMSE<br>[%] |
|--------|-------|--------------|------------------|------------------|-----------|------------|------------|-------------|
| Höhe   | Boden | 2,04         | 2,14             | 1,60             | 0,0395    | 0,003      | -0,0377    | 5,68        |
|        | Luft  | 2,03         | 2,12             | 1,75             | 0,0372    | 0,0018     | -0,0308    | 5,10        |
| Breite | Boden | 1,01         | 1,09             | 0,51             | 0,025     | 0,0013     | -0,011     | 2,93        |
|        | Luft  | 1,01         | 1,17             | 0,85             | 0,0252    | 0,002      | -0,0119    | 3,12        |

Tab. 1: Ergebnisse von Höhe und Breite der Validierungsplatte aus boden- (Höhe  $n = 716$  und Breite  $n = 2968$ ) und luftgeführter (Höhe  $n = 1740$  und Breite  $n = 1256$ ) Datenerfassung, Mittelwert ( $X_M$ ), Maximum ( $X_{max}$ ), Minimum ( $X_{min}$ ), Standardabweichung (SD), Standardfehler (SEM), Bias (MBE), Wurzel der mittleren Fehlerquadratsumme (RMSE)

#### 3.2 Vergleich Laubwandgeometrie

Vergleicht man die Punktwolken, wird ein Unterschied in Bezug auf die Struktur ersichtlich (Abb. 2). Das bodengestützte System liefert eine größere Anzahl von Punkten ( $n = 559106$ ) mit höherer Auflösung, während die luftgestützte Punktwolke eine geringere Anzahl von Punkten ( $n = 69897$ ) mit stärkerem Rauschen aufweist. Dies lässt sich auf die

Entfernung und schräge Ausrichtung des auf der Drohne befindlichen LiDARs zurückführen. Zusätzlich handelt es sich in beiden Varianten um verschiedene Sensorsysteme mit unterschiedlichen Distanzen zur Laubwand, wodurch eine Abweichung in der Intensität zu erkennen ist.

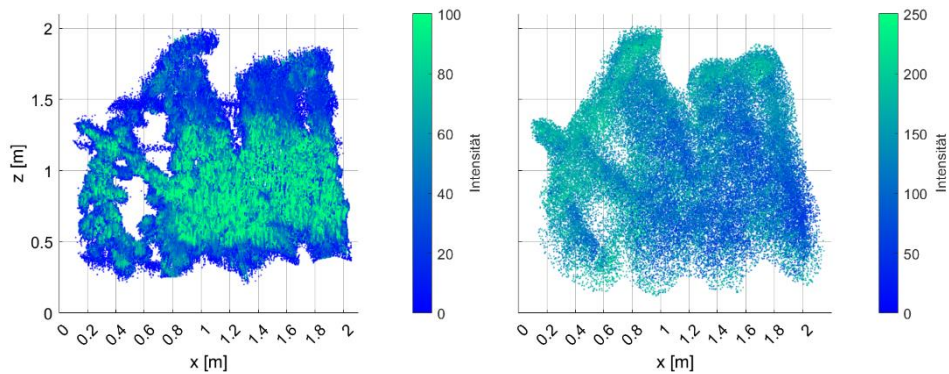


Abb. 2: Rekonstruktion von Punktwolken einer Laubwand von boden- (links) und luftgeführtem (rechts) LiDAR




Abb. 3: Berechnete Distanzen zwischen minimalem und maximalem Punkt der boden- und luftbasierten Laubwandaufnahmen in z-Richtung (links) und in y-Richtung (rechts) durch Aufteilung der Laubwand in 5-cm-Bänder in x- bzw. z-Richtung

Betrachtet man die im linken Graph in Abb. 3 dargestellten Distanzen zwischen den minimalen und maximalen Punkten in z-Richtung mit dem Umriss der in Abb. 2 gezeigten Punktwolken lässt sich eine klare Übereinstimmung feststellen. Im Bereich von  $x = 0,8$  m bis  $x = 1$  m ist in z-Richtung ein Peak in beiden Graphen zu erkennen. Ebenso zeigt der linke Graph in Abb. 3 einen ähnlichen Verlauf der Laubwandhöhe zwischen beiden Varianten. Die Laubwandtiefen bzw. die Distanzen zwischen minimalem und maximalem Punkt in y-Richtung weisen im Vergleich zwischen boden- und luftbasierter Variante klare

Unterschiede auf (Abb. 3 rechts). Bei  $z = 1$  m lässt sich in der Bodenvariante ein größerer Peak erkennen.

#### 4 Schlussfolgerung und Ausblick

Die in dieser Arbeit vorgestellten Verfahren zur Bestimmung der Laubwandhöhe in Weinbergen mit Laser-Scannern sind vielversprechend. Die Sensorvalidierung mit einer Validierungsplatte zeigt eine Standardabweichung in Höhe und Breite von nur wenigen cm, sowohl in der luftbasierten, als auch in der bodenbasierten Variante. Mit beiden Systemen lassen sich daher geometrische Eigenschaften einer Laubwand ermitteln. Bezogen auf den Anwendungsbereich wären damit beide Varianten zur Berechnung einer Dosiermengeneempfehlung für Pflanzenschutzmittel geeignet. Hierzu ist jedoch noch eine Validierung der Systeme bezogen auf die tatsächliche Laubwandhöhe und -tiefe erforderlich und in weiteren Feldversuchen geplant.

**Förderhinweis:** Die Förderung des Vorhabens erfolgt aus Mitteln des Bundesministeriums für Ernährung und Landwirtschaft (BMEL) aufgrund eines Beschlusses des deutschen Bundestages. Die Projektträgerschaft erfolgt über die Bundesanstalt für Landwirtschaft und Ernährung (BLE) im Rahmen der Förderung der Digitalisierung in der Landwirtschaft mit dem Förderkennzeichen 28DE105A22.

#### Literaturverzeichnis

- [Ar12] Arnó, J. et.al.: Leaf area index estimation in vineyards using a ground-based LiDAR scanner. *Precision Agriculture*, 14(3), 290–306, 2012.
- [Hü22] Hütt, C. et.al.: UAV LiDAR Metrics for Monitoring Crop Height, Biomass and Nitrogen Uptake: A Case Study on a Winter Wheat Field Trial. *PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 91, 65–76, 2022.
- [LW23] LWG, Bayerische Landesanstalt für Weinbau und Gartenbau: Das Laubwandflächen-Modell - die neue Bezugsgröße für die Dosierung von Pflanzenschutzmitteln, [https://www.lwg.bayern.de/weinbau/rebe\\_weinberg/326545/index.php](https://www.lwg.bayern.de/weinbau/rebe_weinberg/326545/index.php), Stand: 03.11.2023.
- [Pa22] Pagliai, A. et.al.: Comparison of Aerial and Ground 3D Point Clouds for Canopy Size Assessment in Precision Viticulture. *Remote Sensing*, 14(5), 1145, 2022.
- [Sa22] Saha, K. K. et.al.: Estimation of Vegetative Growth in Strawberry Plants Using Mobile LiDAR Laser Scanner. *Horticulturae*, 8(2), 90, 2022.
- [Ts19] Tsoulas, N. et.al.: Estimating Canopy Parameters Based on the Stem Position in Apple Trees Using a 2D LiDAR. *Agronomy*, 9(11), 740, 2019.

## Dreidimensionale Bodenfeuchtemodellierung auf Schlagebene

### Ansätze für die Erstellung hochaufgelöster Bodenfeuchtekarten mit AMBAV

Sandra Post<sup>1</sup>, Ingmar Schröter<sup>1</sup>, Eric Bönecke<sup>2</sup>, Jörg Rühlmann<sup>2</sup>, Falk Böttcher<sup>3</sup>, Denise Assmann<sup>3</sup> und Eckart Kramer<sup>1</sup>

**Abstract:** Für die Erstellung von hochaufgelösten dreidimensionalen Bodenfeuchtemodellen wurden auf drei Ackerflächen in Mittel- und Ostbrandenburg an jeweils zehn Punkten AMBAV-Modelle in 10-cm-Schichten bis zu einer Tiefe von 150 cm erstellt, die über den mittleren Korngrößendurchmesser schlagspezifisch regionalisiert wurden. In den oberen und mittleren Bodenschichten lag der RMSE bei überwiegend unter 10 Vol.-%, in den unteren Schichten beträgt er durchschnittlich zwischen 10 und 19 Vol.-%. Die Validierung des regionalisierten Modells brachte in den oberen 10 cm einen RMSE von 7,2 Vol.-% hervor.

**Keywords:** Bodenfeuchte, Prozessmodellierung, Bodensensorik, Bodenparametermodellierung, Präzisionslandwirtschaft, AMBAV

## 1 Problemstellung und Zielsetzung

Mit wesentlichem Einfluss auf den Ertrag spielt die Kenntnis der Bodenfeuchte eine entscheidende Rolle für die Verbesserung der Ertragsprognosen sowie der Abschätzung des Bewässerungsbedarfs und kann zudem für die optimierte Düngerausbringung verwendet werden. Aufgrund der hohen zeitlichen und räumlichen Dynamik der Bodenfeuchte steht der Aufwand einer regelmäßigen Beprobung jedoch nicht im Verhältnis zum Nutzen. Alternativ bietet sich eine teilflächenspezifische Bodenfeuchtemodellierung mit dem Agrarmeteorologischen Modell zur Berechnung der aktuellen Verdunstung (AMBAV) [FL07] vom Deutschen Wetterdienst (DWD) an. Es wurde für die Bodenfeuchtemodellierung unter verschiedenen Kulturen mit einer Auflösung von 1x1 km entwickelt. Ziel dieser Studie ist die Erprobung eines Ansatzes zur Erstellung hochaufgelöster 3D-Bodenfeuchtekarten auf Grundlage des AMBAV.

---

<sup>1</sup> Hochschule für nachhaltige Entwicklung Eberswalde, Schicklerstraße 5, 16225 Eberswalde, sandra.post@hnee.de, ingmar.schroeter@hnee.de, eckart.kramer@hnee.de

<sup>2</sup> Leibniz-Institut für Gemüse- und Zierpflanzenbau Großbeeren e.V., Theodor-Echtermeyer-Weg 1, 14979 Großbeeren, boenecke@igzev.de, ruehlmann@igzev.de

<sup>3</sup> Deutscher Wetterdienst, Abteilung Agrarmeteorologie, Kärnerstraße 68, 04288 Leipzig, falk.boettcher@dwd.de, denise.assmann@dwd.de

## 2 Material und Methoden

Der Schlag „Wertheim1“ (51 ha) befindet sich in Mittelbrandenburg in einer ganzjährig grundwasserbeeinflussten Flussaue bei Trebbin und besteht vorrangig aus Sanden mit humoser Auflage. Die Schläge „1211“ (29 ha) und „1601“ (21 ha) liegen im Osten Brandenburgs in Booßen bei Frankfurt/O. auf einer grundwasserfernen Grundmoräne mit äußerst heterogenen Korngrößenverteilungen, die von reinen Sanden bis zu reinem Ton reichen. Keiner der drei Schläge wurde im Versuchszeitraum bewässert. Auf jedem Schlag wurden zehn Messstellen eingerichtet, an denen die Bodenfeuchte in 10-cm-Schichten bis zu einer Tiefe von 150 cm gemessen und mit dem AMBAV modelliert wird. Die Messpunkte wurden mittels scheinbarem elektrischen Widerstand und Gammaaktivität auf Datengrundlage des Geophilus-Sensorsystems [LR13] sowie aus einem NDVI-Komposit unter Verwendung der Fuzzy c-Means-Clusteranalyse festgelegt.

Das AMBAV basiert auf der Penman-Monteith-Gleichung zur Berechnung der potenziellen aktuellen Evapotranspiration und wird kulturspezifisch angepasst. Es berücksichtigt verschiedene kulturspezifische Parameter wie Höhen- und Wurzelwachstum sowie phänologische Phasen. Meteorologische Daten stammen je nach Verfügbarkeit von nahegelegenen eigenen oder DWD-Wetterstationen. Bodenspezifische Informationen, wie Bodenart (nach DIN ISO 11277:2002-08), Humusgehalt (nach DIN EN 15936:2012-11) und Trockenrohddichte, wurden bis zu einer Tiefe von 150 cm berücksichtigt. Die Trockenrohddichte wurde mittels Pedotransferfunktion [RK09] abgeleitet. Im Modell wurden für den grundwassernahen Schlag die Inputparameter Grundwasserflurabstand und Matrixpotenzial angepasst.

Die Modelle wurden mit einem Vorlauf von vier Jahren unter einer angenommenen Bodenfeuchtesättigung gestartet. Die Validierung der Modellierungsergebnisse erfolgte mit Daten von Bodenfeuchtesensoren unter Verwendung von RMSE, Nash-Sutcliffe Modelleffizienz-Koeffizienten (NSE) und  $R^2$ . In den oberen 30 cm wurden bis September/Oktober 2023 Digital True TDR-310N-Sensoren der Marke Acclima (Meridian, USA) verwendet. Die Messungen erfolgten in 10-cm-Schichten. Aufgrund technischer Probleme wurden die TDR-Sensoren gegen PR2/4-Profilsonden der Marke Delta T (Cambridge, UK) ausgetauscht. Für die Messtiefen von 40 bis 70, 90 und 130 cm kam eine PR2/6-Profilsonde der Marke Delta T (Cambridge, UK) zum Einsatz. Gemessen wurde, soweit es die meteorologischen Voraussetzungen zuließen, wöchentlich ab November 2022. Aufgrund technischer Probleme konnte die Messreihe nicht vollständig erhoben werden, so dass an einzelnen Punkten in den oberen 30 cm nur eine geringere Anzahl Messdaten vorhanden ist. Die Messungen der Sensoren wurden mittels Stechzylinderproben validiert.

Die punktuell modellierte Bodenfeuchte wurde unter Anwendung einer linearen Regression mit dem mittleren Korngrößendurchmesser (mean particle diameter – MPD) [SC91] als unabhängige Variable auf Schlagebene regionalisiert. Als Datengrundlage für die Berechnung des MPD diente die Korngrößenverteilung, welche mittels kalibrierter Daten des Geophilus-Sensorsystems flächendeckend bis in eine Tiefe von 150 cm mit

einer räumlichen Auflösung von 2x2 m modelliert wurde. Die hierfür verwendeten elektrischen Widerstände wurden mittels Inversion von den scheinbaren elektrischen Widerständen abgeleitet, so dass diese ebenfalls in 10-cm-Schichten und somit als 3D-Layer-Modell vorlagen.

Die Validierung des daraus abgeleiteten 3D-Bodenfeuchtemodells erfolgte in vorerst 0-10 cm Tiefe durch zehn zufällig verteilte TDR-Messungen. Im weiteren Projektverlauf werden die Modelle im Tiefenprofil zusätzlich validiert.

### 3 Ergebnisse und Diskussion

Die durchschnittlichen Abweichungen der Bodenfeuchtemessungen mittels Sensoren betragen für die TDR-Geräte 5 % und für die Profilsonden 7 %. In Tabelle 1 sind die Modellierungsergebnisse für die AMBAV-Punktmodellierungen exemplarisch für drei Tiefen dargestellt. Es ist eine tendenzielle Zunahme des RMSE mit zunehmender Tiefe erkennbar. Der NSE sowie das  $R^2$  nehmen mit zunehmender Tiefe ab. Signifikante Unterschiede zwischen grundwasserbeeinflussten und grundwasserfernen Schlägen lassen sich hieraus nicht ableiten. Es ist zu beachten, dass sich die durchschnittlichen Abweichungen der Bodenfeuchtesensormessungen sowohl positiv als auch negativ auf die Validierungsergebnisse auswirken können. Die Korrekturen der Messwerte wurden an dieser Stelle noch nicht vorgenommen.

| Schlag    | Tiefe [cm] | RMSE <sub>mean</sub><br>[Vol.-%] | NSE <sub>mean</sub> | R <sup>2</sup> <sub>mean</sub> |
|-----------|------------|----------------------------------|---------------------|--------------------------------|
| Wertheim1 | 0-10       | 7,37                             | -2,97               | 0,54                           |
|           | 60-70      | 7,73                             | -28,07 (2xNA)       | 0,55 (7xNA)                    |
|           | 120-130    | 10,01                            | NA                  | 0,49 (8xNA)                    |
| 1211      | 0-10       | 9,02                             | -2,30               | 0,70                           |
|           | 60-70      | 11,84                            | -49,51              | 0,51                           |
|           | 120-130    | 18,94                            | -38,59              | 0,22 (1xNA)                    |
| 1601      | 0-10       | 8,99                             | -7,64               | 0,16                           |
|           | 60-70      | 8,93                             | -24,61              | 0,38                           |
|           | 120-130    | 15,30                            | -33,89              | 0,31                           |

Tab. 1: Mittlere Güten der AMBAV-Punktmodellierungen exemplarisch für die Tiefen 0-10, 60-70 und 120 bis 130 cm; NAs aufgrund zu geringer Varianzen der modellierten Werte

Die tendenzielle Abnahme der Modellgüte mit zunehmender Tiefe ist auch in Abbildung 1 zu erkennen. Hier sind die AMBAV-Modellierungen, sowie die Referenzmessungen als Zeitreihe beispielhaft für den Punkt 122 des Schlags „1601“ dargestellt. Die Unterschätzung in den tieferen Schichten lässt sich nicht ohne weiteres auf andere Punkte übertragen. Zwar sind die Abweichungen quantitativ ähnlich, die Richtung der Abweichung lässt auf anderen Punkten und Schlägen jedoch keine Tendenzen erkennen. Eine Ursache hierfür könnte in nur ungenau berechneten Lagerungsdichten liegen. Die hierfür verwendete Pedotransferfunktion bezieht ausschließlich den Humusgehalt ein. Die Anwendung einer erweiterten Funktion mit Einbeziehung der Texturdaten soll zukünftig erprobt werden. Die Abbildung verdeutlicht außerdem die überwiegende Überschätzung der AMBAV-Modelle in den oberen und mittleren Bodenschichten, die auch an anderen Standorten festgestellt werden kann.




Abb. 1: Modellerte und gemessene Bodenfeuchtwerte für drei Tiefen an Punkt 122 auf Schlag „1601“, links: als Zeitreihe je Bodenschicht, rechts: als 1:1-Plot

Abbildung 2a) zeigt das regionalisierte Bodenfeuchtemodell des Schlags „1601“ für die validierten Bodenschichten mit den gemessenen TDR-Bodenfeuchtwerten vom 16.10.2023. Auch hier sowie in Abb. 2b) ist die tendenzielle Abnahme der Modellgüte mit zunehmender Tiefe erkennbar. Auffällig ist bei zunehmender Tiefe auch die zunehmende Varianz der gemessenen Werte bei gleichzeitiger abnehmender Varianz der modellierten Werte. Die geringe Varianz der modellierten Werte in den tieferen Bodenschichten führt teilweise dazu, dass der NSE sowie das R<sup>2</sup> an einigen Punkten nicht berechnet werden können (s. Tab. 1). Diese Tendenzen sowie die überwiegend auftretende Überschätzung



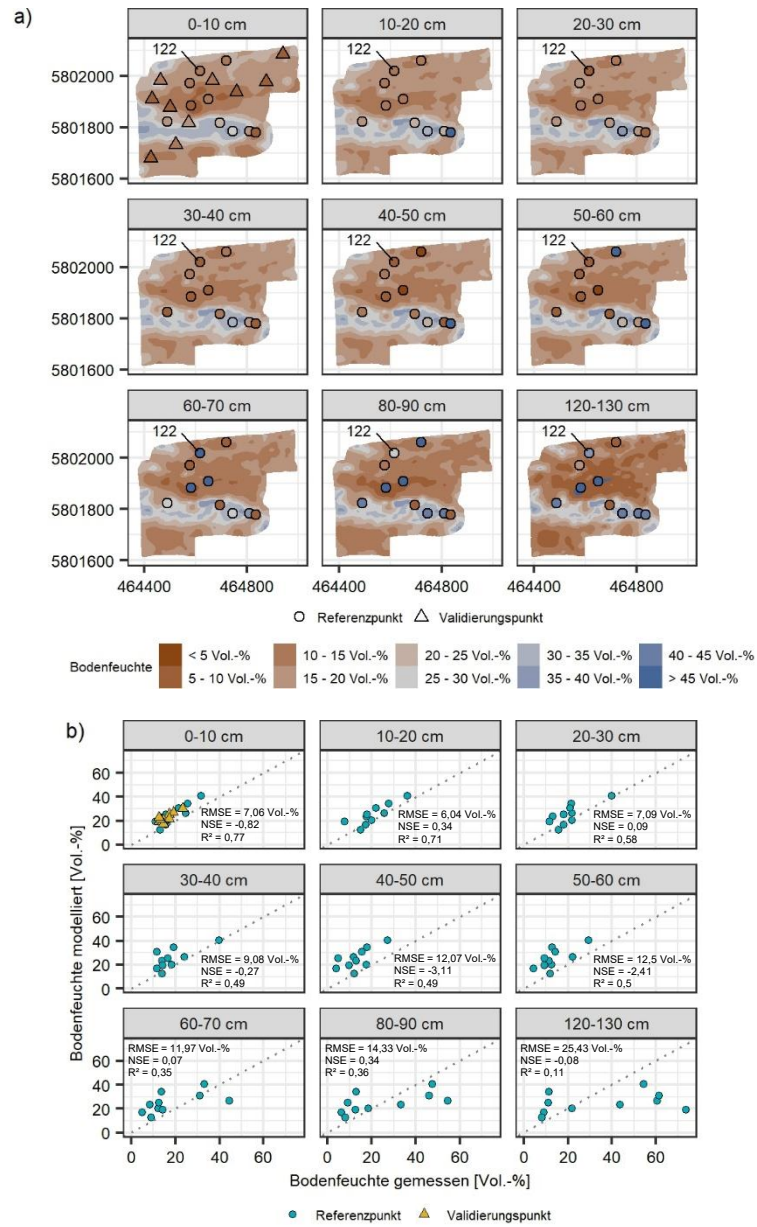


Abb. 2: Validierungsergebnisse des flächenhaften dreidimensionalen Bodenfeuchtemodells für Schlag „1601“, a) hochaufgelöste Bodenfeuchtekarten vom 16.10.2023 für die validierten Tiefenschichten, b) als 1:1-Plot

der AMBAV-Modelle in den oberen und mittleren Schichten konnten auch auf den übrigen Schlägen festgestellt werden. Die Validierung der Bodenfeuchtekarte in den oberen 10 cm abseits der Referenzpunkte zeigt mit einem RMSE von 7,2 Vol.-% ähnliche Abweichungen wie an den Referenzpunkten mit 6,9 Vol.-%, so dass die Verifizierung der angewendeten Regionalisierungsmethode als erfolgreich gewertet werden kann.

Bei dem hier vorgestellten Ansatz handelt es sich um Zwischenergebnisse für drei Schläge. Im weiteren Projektverlauf ist die Evaluierung der Methodik auf fünf weiteren Standorten in Brandenburg geplant. Da das AMBAV für einen kleineren Maßstab entwickelt wurde, finden laterale Fließprozesse in den Berechnungen keine Berücksichtigung.

#### 4 Schlussfolgerungen und Ausblick

Die Validierungsergebnisse der Bodenfeuchtemodelle lassen insbesondere in den oberen und mittleren Bodenschichten mit RMSE-Werten von durchschnittlich unter 10 Vol.-% eine Eignung des AMBAV für die Bodenfeuchtemodellierung auf Schlagebene erkennen. Abweichungen können zukünftig ggf. durch die optimierte Berechnung der Lagerungsdichte, der Einbeziehung des Reliefs sowie einer Verschiebung der Ergebnisse in Reaktion auf die Überschätzungen verringert werden. Die Validierung der Bodenfeuchtekarten in den oberen 10 cm lässt eine erfolgreiche Regionalisierung mittels MPD vermuten. Weitere Validierungen stehen an dieser Stelle noch aus. Nach weiterer Optimierung der hier vorgestellten Methodik und der Einbeziehung einer mittelfristigen Wetterprognose können die Ergebnisse durch eine zeitliche Anpassung der Düngerausbringung das präzise Düngemanagement optimieren. Auch für die Einteilung der Schläge in einheitlich bewirtschaftete Teilflächen und die Anpassung der Bewässerung lassen sich die Bodenfeuchtemodelle nutzen.

#### Literaturverzeichnis

- [FL07] Friesland, H.; Löpmeier, F.J.: The performance of the model AMBAV for evapotranspiration and soil moisture on Müncheberg data. In (Kersebaum, K.C.; Hecker, J.M.; Mirschel, W.; Wegehenkel, M., Hrsg.): Modelling water and nutrient dynamics in soil-crop systems. Springer, Dordrecht, 2007.
- [LR13] Lück, E.; Rühlmann, J.: Resistivity mapping with GEOPHILUS ELECTRICUS—information about lateral and vertical soil heterogeneity. *Geoderma* 199, 2013.
- [RK09] Rühlmann, J.; Körschens, M.: Calculating the Effect of Soil Organic Matter Concentration on Soil Bulk Density. *Soil Science Society of America Journal* 73, 2009.
- [SC91] Shiozawa, S.; Campbell, G.S.: On The Calculation of Mean Particle Diameter and Standard Deviation from Sand, Silt, and Clay Fractions. *Soil Science* 152, 1991.

## Weed detection with YOLOv8-seg in UAV-imagery

### Network architecture and the detection of small weed plants

Maren Pukrop <sup>1</sup>, Simon Pukrop <sup>2</sup> and Thomas Jarmer <sup>1</sup>



**Abstract:** Accurate site-specific weed management depends on precise weed localization. In 2023, the YOLOv8 architecture was introduced, providing an accessible instance segmentation tool available in five scaled versions, each with an increasing number of trainable parameters. This study focuses on weed mapping on high-resolution UAV imagery, emphasizing the detection of small weed plants. The research investigates the detection of *Cirsium arvense* and other weed species in maize. To aid this research, RGB UAV imagery was obtained on three different dates ranging from May to June 2022. The detection of weeds was performed on five different YOLOv8 models. During validation, it was demonstrated that the models' accuracy in detecting weeds with many small plants is comparable, indicating no need for a larger model. Recall is low for small objects measuring only a few cm<sup>2</sup> across all five models tested but increases as object size increases.


**Keywords:** weed mapping, deep learning, UAV-data, instance segmentation

## 1 Introduction

As part of its farm-to-fork strategy, the European Union aims to halve pesticide usage in its member states by 2030 [EU20]. In this context, the deployment of concepts such as site-specific weed management (SSWM) is critical. Successful SSWM necessitates effective detection and identification of various weed species, especially smaller plants during the early growth stages, such as the two-leaf or four-leaf stage. In addition, further pesticide savings can be made with species-specific weed detection and management. Weed detection is usually carried out by proximal sensing using ground-based sensor systems, e.g., robots or sensor platforms mounted on a tractor, or by remote sensing using camera systems mounted on a UAV. Ground sampling distance (GSD) is of great importance for weed detection, which is challenging due to high class imbalance, occlusion and overlap with other plants, and high variability within and between species [Ha21]. Therefore, UAV imagery must be acquired at low altitudes and by cameras with

---

<sup>1</sup> Osnabrück University, Institute of Computer Science, Remote Sensing Group, Wachsbleiche 27,  
49090 Osnabrück, maren.pukrop@uni-osnabrueck.de,  <https://orcid.org/0000-0002-0711-732X>,  
thomas.jarmer@uni-osnabrueck.de,  <https://orcid.org/0000-0002-4652-1640>

<sup>2</sup> German Research Center for Artificial Intelligence, Hamburger Straße 24, 49084 Osnabrück,  
simon.pukrop@dfki.de,  <https://orcid.org/0000-0002-4473-5215>

high spatial resolution [Co22]. Starting from reflectance-based methods for weed detection in large areas, computer vision approaches are now widely used [Ha21]. These approaches can be roughly divided into four groups: image classification, object detection, semantic segmentation, and instance segmentation. Currently, there are two main approaches to object detection and instance segmentation. The first uses two-stage algorithms that attempt to isolate regions of interest (RoIs) and then use classification methods to identify the object within each RoI. Notable models include R-CNN (Region Based Convolutional Neural Network) and Mask R-CNN. The more recent approach is to use single-stage object detectors. They extract and classify objects in an image with a single forward pass through a deep neural network. Early YOLO (You Only Look Once) models traded off some accuracy for a significant improvement in inference speed, with the first YOLO achieving a speed two orders of magnitude faster than Fast RCNN. Several researchers have created new iterations of the YOLO concept. For a comprehensive discourse on both approaches and various YOLO models, please refer to [DAT23] and [TC23]. Ultralytics' YOLOv8 [JCQ23] was released in 2023. It surpasses earlier versions in terms of accuracy on small objects, overall performance, and inbuilt support for instance segmentation. YOLOv8 offers five model sizes called nano, small, medium, large, and extra-large (n, s, m, l, x), ranging from 3.4 million to 71.8 million parameters. Generally, the larger models are more accurate but slower. With respect to the challenges of species-specific weed detection in UAV imagery, we want to explore the capabilities of the different YOLOv8 segmentation models for the detection of small weed plants using the example of the detection of *Cirsium arvense* and other weed species in maize.

## 2 Material and Methods

The study area and the UAV imagery used in this study have already been described in [PH23]. Here, a subset of three datasets from flights on May 5, 2022, May 18, 2022 and June 2, 2022 is used. Between May 18, 2022 and June 2, 2022 chemical weed regulation was done, so at June 2, 2022 only a small amount of weed plants, except for the resistant *Cirsium arvense*, are visible. The UAV images were acquired using a DJI Matrice 210 with a MicaSense Altum mounted. A GSD of 3.5 mm was achieved by flying at an altitude of 10 m. Fixed field targets were used as ground control points and located using differential GPS. The imagery was stitched into orthomosaics and radiometrically calibrated using Agisoft Metashape (version 1.7.2). For this analysis, only the RGB information of the orthomosaics was used. Samples were taken from three spatially independent areas: one area for training of size 50.7 m<sup>2</sup> (T), one area for validation during training of size 9.1 m<sup>2</sup> (V) and one area for subsequent validation of size 24.4 m<sup>2</sup> (SV). Polygon-based labels were manually annotated for three classes: "Maize" as crop, *Cirsium arvense* ("Cirsium") as target weed species and "other weed" species (including plants of *Chenopodium album*, *Stellaria media*, and various monocotyledonous plants). Samples were taken with a size of 128 px and a stride of 64 px for T and V. An overview of the instances per class in T, V and SV data can be found in Table 1, and examples of annotated data from all three dates in Figure 1.

| Number of instances |    | Total | 0-1 | 1-2 | 2-3 | 3-4 | 4-5 | 5-10 | 10-15 | 15-25 | 25-50 | >50 |
|---------------------|----|-------|-----|-----|-----|-----|-----|------|-------|-------|-------|-----|
| maize               | T  | 1225  | 1   | 5   | 5   | 13  | 25  | 302  | 68    | 37    | 302   | 467 |
|                     | V  | 203   | 0   | 0   | 0   | 1   | 4   | 61   | 9     | 15    | 57    | 56  |
|                     | SV | 566   | 1   | 4   | 5   | 12  | 18  | 138  | 23    | 36    | 138   | 191 |
| cirsium             | T  | 1225  | 28  | 36  | 32  | 30  | 30  | 108  | 129   | 199   | 292   | 341 |
|                     | V  | 322   | 0   | 1   | 1   | 2   | 2   | 15   | 30    | 51    | 81    | 139 |
|                     | SV | 422   | 2   | 6   | 6   | 6   | 5   | 23   | 30    | 75    | 130   | 139 |
| Other weed          | T  | 1611  | 233 | 468 | 276 | 169 | 93  | 232  | 75    | 47    | 16    | 2   |
|                     | V  | 846   | 139 | 216 | 136 | 69  | 50  | 120  | 56    | 49    | 6     | 5   |
|                     | SV | 863   | 112 | 233 | 115 | 75  | 60  | 174  | 65    | 31    | 31    | 6   |

Tab. 1: Overview of instances per class in training (T), validation (V) and subsequent validation (SV) data, split by different size groups (in cm<sup>2</sup>)




Fig. 1: Snippets of orthomosaics and labels for the three dates

| Model parameter | Default | Adjusted |
|-----------------|---------|----------|
| flipud          | 0.0     | 0.5      |
| scale           | 0.5     | 0        |
| mosaic          | 1.0     | 0.5      |
| maskratio       | 4       | 1        |
| lrf             | 0.01    | 0.001    |
| imgsize         | 640     | 256      |

Tab. 2: Default and adjusted model parameters

YOLOv8 provides various hyperparameters for both training and data augmentation [JCQ23]. The default parameters for data augmentation are tuned for object detection in standard perspective images. Therefore, we adjusted some hyperparameters for our usage in top-down perspective UAV imagery (Tab. 2). For training, we used 1000 epochs combined with an early stopping with a patience of 50 epochs. For measuring the performance during training, the build-in performance metrics  $mAP50_{box}$  and  $loss_{box}$  were used.  $mAP50_{box}$  is a measure for the model's performance,  $loss_{box}$  describes the model's error [JCQ23]. For validation, the classification of SV was performed with different offsets and overlapping tilings, and only plants in the centre of the central quarter of a tile were retained. As validation metrics, a normalized confusion matrix for pixel accuracy (PA) was calculated based on the rasterized classification result as well as the validation data to make the classification results comparable to segmentation-based weed detection. Furthermore, the average precision at an IoU-threshold of 0.5 (AP) of the bounding boxes was calculated for each class and in total. This measure is most used for object detection tasks [Ha21]. Finally, the recall (proportion of correct classified plants out of all plants) was calculated for each class for different size groups of the objects (0-1, 1-2, 2-3, 3-4, 4-5, 5-10, 10-15, 15-25, 25-50 and larger than 50 cm<sup>2</sup>).

### 3 Results

Due to the early stopping parameter, the five models stopped at different epochs: n at 112, s at 90, m at 106, l at 80 and x at 63. In Figure 2  $mAP50_{box}$  and  $loss_{box}$  during the training process are presented. While there are no significant differences in  $mAP50_{box}$  during training of the five models, the  $loss_{box}$  is slightly lower at earlier epochs, the larger the model gets. In the subsequent validation, the models achieved following mean AP on the validation dataset: n: 0.65, s: 0.64, m: 0.64, l: 0.65 and x: 0.62. The mean PAs (*mean PAs without background*) are n: 0.97 (0.68), s: 0.97 (0.62), m: 0.96 (0.62), l: 0.96 (0.62), x: 0.97 (0.67). By looking at the achieved mean APs as well as the mean PAs of the confusion matrices of the five models, no trend in accuracy regarding the model complexity is visible. The models achieved an AP for “maize” ranging from 0.90 to 0.91, “cirsium” from 0.81 to 0.86 and “other weeds” from 0.35 to 0.39. For the PAs (Fig. 3), “maize” ranges from 0.75 to 0.79, “cirsium” from 0.67 to 0.79 and “other weed” from 0.39 to 0.51. It is noticeable that in all models a large proportion (around 0.3) of “other weed” are not detected and classified as background. Confusion with “maize” is very low (below 0.01), confusion with “cirsium” is higher (0.11-0.19). By looking at the recall of the different classes grouped by size (Fig. 4), it is noticeable that especially the very small objects are rarely detected. For “maize” and “cirsium”, *recall* rises with increasing object size. For “other weed”, recall reaches a maximum at an object size of 4-10 cm<sup>2</sup> and then shrinks again. Large “other weed” polygons (area > 50 cm<sup>2</sup>) are only detected by models s and l.




Fig. 2:  $mAP50_{box}$  and  $loss_{box}$  metrics during the training for the models until early stopping




Fig. 3: Normalized confusion matrices for the five different models based on the rasterized classification result




Fig. 4: Recall for objects of the classes “maize”, “cirsium” and “other weed”, both in total and split in the different size groups

## 4 Discussion and Outlook

The presented models achieved both mean APs and mean PAs (without background) between 0.62 and 0.65. The mean and class-wise accuracies indicate the ability of the presented model to correctly classify the different species to a certain extent. Misclassifications for all plant species are mostly made with the background, especially for small plants. As can be seen in Figure 4, the recall value generally increases for larger plant sizes. The mean accuracies of the presented models are lower than results of state-of-the-art studies in both semantic and instance segmentation for weed and crop classification, which range between 0.71 and 0.97 depending on weed species, crop type and model [Ha21; Xu23]. For a species-specific instance segmentation of multiple crop and weed species in high-resolution ground data, [Ch20] achieved a mean AP of 0.49, and an AP of 0.85 for maize and 0.15-0.73 for the target weed species. The APs presented in this paper are comparable or slightly better than in [Ch20], although the UAV imagery has a wider GSD. The evaluation reveals that all five presented models yield nearly identical outcomes in terms of AP, PA and the recall for the different size groups. The larger models seem to necessitate fewer, but slower, epochs to reduce loss. For the recognition of weeds, particularly when dealing with a high amount of small weed plants, it is not necessary to opt for a large model with many trainable parameters. The number of training samples for the three classes “maize”, “cirsium” and “other weed” are roughly equal. But the intra-class variability of size differs between the classes (Tab. 1). Caused by data from three dates, there are three maxima in the polygon size of the “maize” class. The number of samples per size group of the “cirsium” class is rising with increasing polygon size. The size of “other weed” plants has two maxima, one at a size of 1-2 cm<sup>2</sup>, and the other at a size of 5-10 cm<sup>2</sup>. The missing third maxima is caused by the controlled weed plants in the dataset from June 2, 2022. The variability in polygon size necessitates multitemporal data collection with a high temporal resolution to generate a dense training set. Although tiny objects are well represented in the training data, they are rarely detected by the models. It is probable that the low detection rate of small “other weed” plants hinders the overall training process, including for larger objects and other classes. Due to the limited amount of larger “other weed” plants in both the training and the independent validation datasets, these plants are mistakenly classified as “cirsium”. By using a collection of examples of weed plants in later stages of growth (such as in an unregulated field), it should be possible

to avoid these misclassifications. For future use of YOLOv8 for weed classification in UAV imagery for species- and site-specific weed management, the model should be adapted to the detection of small plants of different species. Approaches from other research areas within the field of object detection [Zh23] could also be transferred to the area of weed detection to deal with plants in early growth stages.

**Acknowledgements:** This work is supported by the Federal Ministry for the Environment, Nature Conservation, Nuclear Safety and Consumer Protection (BMUV) within the CognitiveWeeding project (grant number: 67KI21001B). A special thanks goes to Lukas Grund and Katalin Schleuter for manually digitalizing plant polygons.

#### Bibliography

- [Co22] Coleman, G. R. et al.: Weed detection to weed recognition: reviewing 50 years of research to identify constraints and opportunities for large-scale cropping systems. *Weed Technology*, 1-50, 2022.
- [Ch20] Champ, J. et al.: Instance segmentation for the fine detection of crop and weed plants by precision agricultural robots. *Applications in Plant Sciences* 8(7): e11373. 2020.
- [DAT23] Diwan, T.; Anirudh, G.; Temburne, J. V.: Object detection using YOLO: Challenges, architectural successors, datasets and applications. *multimedia Tools and Applications*, 82(6), P. 9243-9275, 2023.
- [EU20] The European Commission: Communication from the Commission to the European Parliament, the Council, the European economic and social committee and the Committee of the regions, A Farm to Fork Strategy for a fair, healthy and environmentally-friendly food system, 2020.
- [Ha21] Hasan, A. M. et al.: A survey of deep learning techniques for weed detection from images. *Computers and Electronics in Agriculture* 184/, P. 106067, 2021.
- [JCQ23] Jocher, G.; Chaurasia, A.; Qiu, J.: Ultralytics YOLOv8. <https://github.com/ultralytics/ultralytics>, 2023.
- [PH23] Pöttker, M. et al.: Kartierung des Bedeckungsgrads von *Cirsium arvense* im Mais (*Zea mays* L.) mithilfe Neuronaler Netze in UAV-Daten. In: Referate der 43. GIL-Jahrestagung, 2023.
- [TC23] Terven, J.; Cordova-Esparza, D.: A comprehensive review of YOLO: From YOLOv1 and beyond. *arXiv* 2023. *arXiv preprint arXiv:2304.0050*, 2023.
- [Xu23] Xu, B. et al.: Instance segmentation method for weed detection using UAV imagery in soybean fields. *Computers and Electronics in Agriculture*, 221, 107994, 2023.
- [Zh23] Zhai, X. et al.: YOLO-Drone: An Optimized YOLOv8 Network for Tiny UAV Object Detection. *Electronics*, 12(17), 3664, 2023.



## Development of an index to estimate potential risk of slug damage

Giovanni Antonio Puliga <sup>1</sup>, Jobst Gödeke<sup>2</sup>, Dieter von Hörsten<sup>1</sup> and Jens Karl Wegener<sup>1</sup>

**Abstract:** Terrestrial slugs are important pests for many agricultural and horticultural crops. Current control strategies are mostly based on preventive approaches and their success is strongly influenced by timing of application and knowledge of the pests' behaviour. This paper presents an approach to estimate spatial and temporal activity of slugs in the field. For this, an index is developed considering different factors that influence the activity of slugs. The index is then used to generate a map, where areas of the field with higher potential risk of slug damage are identified. This map can be used for smart agriculture applications such as the control of these pests through an autonomously operating field robot.

**Keywords:** crop protection, field slugs, slug index, precision farming

### 1 Introduction

Terrestrial slugs (Mollusca: Gastropoda) represent important pests in many agricultural and horticultural crops. In temperate climates of Europe, the most common species are the field grey slug *Deroceras reticulatum* and the Spanish slug *Arion vulgaris*, but also other species can cause crop damage. Damage from slugs can lead to significance loss to a wide range of crops, and it is mainly caused by feeding. Furthermore, indirect damages such as rests of bodies, faeces or slime can lead to deterioration of the product's quality and make several high value vegetables such as lettuce unmarketable [Go79].

Achieving a successful and more sustainable pest control following integrated pest management strategies requires a deep understanding of the pest behaviour and its interactions with both biotic and abiotic factors in the agroecosystems. Thus, estimating the temporal and spatial activity of slugs in the field can represent an important tool in order to apply successful pest control methods, while reducing the use of chemical molluscicides.

---

<sup>1</sup> Julius Kühn-Institut, Institut für Anwendungstechnik im Pflanzenschutz, Messeweg 11/12, 38104

Braunschweig, giovanni.puliga@julius-kuehn.de,  <https://orcid.org/0000-0003-3030-2387>, dieter.von-hoersten@julius-kuehn.de, jens-karl.wegener@julius-kuehn.de

<sup>2</sup> Landwirtschaftskammer Niedersachsen, Praxislabor Digitaler Ackerbau, An der Domäne 1, 38154 Königslutter am Elm, jobst.goedeke@lwk-niedersachsen.de

In this study, a model (“Slug Index”) to estimate the presence and activity of slugs in the field and thus the potential risk of slug damage is developed. Three main groups of influencing factors were selected and evaluated: site characteristics (soil texture, topography, field margin, natural enemies), management practices (soil management, crop type), and meteorological factors (temperature, weather conditions). The aim of the slug index is to estimate spatial and temporal patterns of slugs’ activity based on their response to these factors. This information is used to generate a map of the field which gives an overview of the areas with higher risk of slug presence and consequent potential crop damage, which can be used for the application of control measures.

## 2 Methods

### 2.1 Selection of the variables

Forecasting population dynamics and activity of slugs is of primary importance to achieve an efficient pest control, and for that, different modelling approaches have been extensively investigated in the past. Several slug population models have used climatic data to predict activity of slugs [e.g. Yo91]. Furthermore, individual-based models have been developed, involving the simulation of life-history processes and which are therefore species-specific [e.g. Sh01; Ch06]. Both types of models, however, often neglected the importance of other factors that can affect slugs’ activity under field conditions, such as site characteristics and crop management practices.

The aim of the slug index is not to investigate the long-term dynamics of slug population, but to estimate the spatial and temporal patterns of activity of slugs in the field, as basis for the application of a control strategy following the principles of precision farming. In order to develop the index, the biotic and abiotic factors that affect the activity of slugs in agricultural fields need to be assessed. These factors were identified as site characteristics, field management practices and meteorological conditions. Among those, different categories were defined, and the most relevant variables to describe them were chosen.

Local site characteristics such as soil texture, topography, field margins and presence of natural enemies all have the capacity to influence the presence of slugs. Fields with higher clay content and lower sand content are preferred by slugs due to higher water retention properties of the soil. In addition, clay soils offer more shelter and refuges for slugs in the more superficial layers [So92]. It is known that in agricultural fields the spatial distribution of slugs is heterogeneous, forming patches of high population density separated by areas with low population density [Fo17]. It is therefore important, for the application of control measures, to determine the patch location. The local topography of the investigated field may affect those patches, which are more likely to be located in depression zones. In relation to field margins, different types can distinctly affect the occurrence of slugs. In particular, herbaceous and woody semi-natural habitats can offer refuge and shelter for slugs, which can then migrate into arable fields [Fu16]. Natural enemies can also play a

role in regulating slug populations. Carabid beetles, for instance, have been proven to be effective predators of those pests [Bo00]. Therefore, their presence in the field is another important variable that should be considered when estimating slugs' activity. However, this variable cannot be easily quantified under practical conditions, except with specific investigations.

With regard to crop management practices, soil cultivation has a central role in affecting slugs' activity. The risk of slug damage is generally higher under regimes of reduced or no-tillage, compared to fields that are conventionally ploughed. An undisturbed field offers a more favourable environment for slugs, in particular when crop residues are present or cover crops are cultivated [Go79]. Furthermore, certain crops are known to be at particularly high risk of slug attack compared to others [Ho12]. Thus, it is important to assess the potential risk in relation to the cultivated crop as well.

Meteorological factors have an effect on the temporal component of the index. It is well acknowledged that climatic factors such as temperature and precipitation play the most important role in influencing slug activity. As slug bodies consist of 92% water, these animals strive to protect themselves from drying out due to high temperatures and sunlight. Among climatic variables, air temperature, soil surface temperature, wind speed, humidity and soil moisture have all been shown to influence slug activity in the field [Yo91; So92]. Precipitation exerts an important influence on the occurrence of slugs. Not only direct rainfall, but also an increase of humidity by dew creates favourable conditions for slugs. The temperature optimum is between 14 °C and 18 °C, while the activity tends to decrease with increasing temperature, also because this is likely associated with sunny and dry conditions. Especially in summer, in order to avoid the harmful effects of sunlight, slugs retreat to shielded areas or deeper soil layers [Go79]. To simplify the development of the slug index, the readily observed variables of air temperature and weather conditions were used to reflect meteorologically induced changes in slug' activity. The more general variables used for weather conditions differentiate the occurrence of periods with precipitation, hence favourable conditions in terms of humidity, and periods with less favourable conditions for slugs.

Here, evaluating the effects of meteorological conditions, we did not distinguish between different times of the day, assuming that under favourable weather conditions, slugs can be active independently of it. In practice, it is well known that sunlight plays a fundamental role for the activity of slugs, and that they are, with differences between species, more active during dawn, dusk and at night, compared to daytime. Nevertheless, falling temperatures after rainfall in summer could induce daytime activity of slugs.

## 2.2 Evaluation of the variables

In the next step, based on knowledge from literature, weighting scores were assigned to the different variables, representing the potential effect on presence and activity of slugs (1: low, 2: medium, 3: high). As an example, for the category soil texture, scores were

assigned as follows: sand: 1; loam: 2; clay: 3, as it is known that clay soils are preferred by slugs compared to the other two types (Tab. 1).

|                                  | <b>Category</b>    | <b>Variable</b>                              | <b>Score</b> |
|----------------------------------|--------------------|--|--------------|
| Site                             | Soil texture       | Sand   | 1            |
|                                  |                    | Loam   | 2            |
|                                  |                    | Clay   | 3            |
|                                  | Topography         | Plain  | 1            |
|                                  |                    | Elevation                                    | 1            |
|                                  |                    | Depression                                   | 2            |
|                                  | Field margin       | Arable land                                  | 1            |
|                                  |                    | Woodland                                     | 2            |
|                                  |                    | Grassland and fallow land                    | 2            |
|                                  | Natural enemies    | High abundance of natural enemies            | 1            |
| Low abundance of natural enemies |                    | 2  |              |
| Crop management                  | Soil management    | Ploughing                                    | 1            |
|                                  |                    | Mulch sowing and reduced till                | 2            |
|                                  |                    | No till                                      | 3            |
|                                  | Crop type          | Low risk crops                               | 1            |
|                                  |                    | Medium risk crops (e.g. cereals, sugar beet) | 2            |
|                                  |                    | High risk crops (e.g. rape seed, lettuce)    | 3            |
| Meteorological factors           | Temperature        | 0 °C-10 °C                                   | 2            |
|                                  |                    | 10 °C-20 °C                                  | 3            |
|                                  |                    | >20 °C                                       | 1            |
|                                  | Weather conditions | Dry  | 1            |
|                                  |                    | Cloudy                                       | 2            |
|                                  |                    | Wet  | 3            |

Tab. 1: Descriptive summary of categories and variables with their respective scores considered for the development of the slug index

### 3 Results

#### 3.1 Calculation of the index and production of the field map

To apply the index in an agricultural field, a test field was chosen. Using a GIS software, a raster (10x10 meters) was laid over the field. For each single cell, the index was calculated as a mean resulting from the sum of the scores assigned to each variable. A value between 1 and 3 can be obtained, which represents the different levels of potential risk for slug presence (1: low risk, 2: medium risk, 3: high risk). Based on these values, a field map is produced, where each raster cell corresponds to a point with a defined index and colour (Fig.1), varying from green (lower risk) to red (higher risk). To produce the map, the interpolation method Inverse Distance Weighting (IDW) was used.




Fig. 1: Field map generated based on the slug index showing different levels of potential risk for slug presence (green: low risk, orange: medium risk, red: high risk)

### 4 Conclusions

In conclusion, the approach presented here attempts to develop a tool that relates the presence and activity of slugs with different components of the agroecosystem. Considering that slugs can be influenced by a large number of factors, it is important to consider not only climatic conditions, but also site characteristics and crop management practices. The slug index offers possibilities for future precision farming applications. For instance, an alternative to conventional slug control methods may be represented by a robotic solution that controls slugs through mechanical methods, which can benefit from the index [Gö19]. Using the field map generated, the route for the robot navigation can be

calculated, so that it is able to move specifically towards areas with a higher risk of slug damage, checking for their presence and rendering them harmless.

Further development of the model and adjustments of the variables considered and scores assigned are still required. In addition, field observations of slugs are also necessary to validate the index under real agricultural settings.

**Acknowledgements:** This work is funded by the Federal Ministry of Food and Agriculture (BMEL) based on a decision of the Parliament of the Federal Republic of Germany via the Federal Office for Agriculture and Food (BLE).

#### Bibliography

- [Bo00] Bohan, D.A. et al.: Spatial dynamics of predation by carabid beetles on slugs. *Journal of Animal Ecology*, 69, 367-379, 2000.
- [Ch06] Choi, Y.H. et al.: Individual based model of slug population and spatial dynamics. *Ecological Modelling*, 190, 336-350, 2006.
- [Fo17] Forbes, E. et al.: Sustainable management of slugs in commercial fields: Assessing the potential for targeting control measures. In *Aspects of Applied Biology*, 134 (eds. Hull, R., et al.), 89-96, 2017.
- [Fu16] Fusser, M.S. et al.: Effects of landscape composition on carabids and slugs in herbaceous and woody field margins. *Agriculture, Ecosystems & Environment*, 226, 79-87, 2016.
- [Go79] Godan, D.: *Schadschnecken und ihre Bekämpfung*. Verlag Eugen Ulmer, Stuttgart, 1979.
- [Gö19] Gödeke, J. et al.: Entwicklung einer Robotik-Lösung zur Schneckenbekämpfung im Ackerbau. *Gesunde Pflanzen*, 71, 573-578, 2019.
- [Ho12] Howlett, S.A.: Terrestrial slug problems: Classical biological control and beyond. *CAB Reviews*, 7 (51), 2012.
- [Sh01] Shirley, M.D.F. et al.: Simulating the long-term dynamics of slug populations: A process-based modelling approach for pest control. *Journal of Applied Ecology*, 38, 401-411, 2001.
- [So92] South, A.: *Terrestrial slugs: Biology, ecology and control*. Springer-Science + Business Media, B.V., 1992.
- [Yo91] Young, A.G. et al.: Development of a forecast of slug activity: Models to relate slug activity to meteorological conditions. *Crop Protection*, 10 (5), 413-415, 1991.

# Datennutzungsstrategien von Ackerbaubetrieben – Wofür Landwirte ihre Daten nutzen

Hendrik Schwager<sup>1</sup>, Jorrit Kühl<sup>1</sup> und Holger Schulze<sup>1</sup>

**Abstract:** Auf landwirtschaftlichen Betrieben werden immer häufiger digitale Technologien eingesetzt, um unterschiedliche Daten zu erheben. Obwohl die Verarbeitung dieser Daten den Betriebsleitern von Ackerbaubetrieben neue Potenziale eröffnet, ist bisher noch weitestgehend unerforscht, wofür und inwieweit Landwirt\*innen ihre Daten nutzen. Die vorliegende Arbeit hat daher zum Ziel, das Datennutzungsverhalten von Ackerbaubetrieben näher zu untersuchen. Hierzu wurden insgesamt 60 Betriebsleiter\*innen (n=60) von ökologisch und konventionell wirtschaftenden Ackerbaubetrieben qualitativ befragt. Aus der Befragung ging dabei unter anderem hervor, dass die betrieblichen Einflüsse (z. B. Flächenausstattung) einen größeren Einfluss auf die Bereitschaft zur Datennutzung haben als die Einflüsse des Betriebsleiters (z. B. Alter, Bildungsabschluss).

**Keywords:** Digitalisierung, Datenmanagement, Datennutzung, Ackerbaubetriebe

## 1 Einleitung

Die zunehmende Integration digitaler Technologien auf landwirtschaftlichen Betrieben ermöglicht eine immer stärkere Erfassung von Daten [K120]. Mit der Verarbeitung jener Daten gehen dabei unterschiedliche Potenziale einher, die bisher nur wenig erforscht sind. Vor dem Hintergrund der aktuellen Gegebenheiten setzt sich die vorliegende Arbeit daher zum Ziel, das Datennutzungsverhalten von Ackerbaubetrieben näher zu untersuchen. Wesentliches Ziel der Untersuchungen ist es dabei, neue Erkenntnisse über die derzeitigen Einstellungen der Betriebsleiter\*innen von Ackerbaubetrieben zur Nutzung von Daten zu gewinnen. Hierzu wird im Rahmen der Arbeit analysiert, welche Daten auf den Ackerbaubetrieben erfasst und genutzt werden, welche Motivationen mit der Nutzung von Daten verbunden sind und welche Faktoren das Datennutzungsverhalten beeinflussen.

## 2 Stand der Forschung

Um den aktuellen Forschungsstand zum Datenmanagement der Betriebsleiter\*innen von Ackerbaubetrieben näher skizzieren zu können, wurde zunächst eine Literaturanalyse durchgeführt. Im Zuge der Analyse, die im Zeitraum von Juli bis September 2022 abgewickelt wurde, konnten insgesamt 152 internationale Beiträge recherchiert werden, die

---

<sup>1</sup> Fachhochschule Kiel, Fachbereich Agrarwirtschaft, Grüner Kamp 11, 24783 Osterrönfeld, hendrikschwager@gmx.de, jorrit.kuehl@fh-kiel.de, holger.schulze@fh-kiel.de

mit dem Thema „Digitalisierung und Datenmanagement“ in der Landwirtschaft in Verbindung stehen. Die Häufigkeitsverteilung der Veröffentlichungen im Zeitverlauf ließ dabei auf eine stetig wachsende Bedeutung der Thematik schließen. Zentrale Erkenntnis der Literaturanalyse ist es, dass im Rahmen bisheriger Untersuchungen insbesondere zwei Fragestellungen beleuchtet wurden. So wurde einerseits bereits ausführlich untersucht, wodurch die Bereitschaft zur Nutzung digitaler Technologien beeinträchtigt wird [CC19; Pi19] und andererseits bereits umfassend erforscht, welche Wirkungen Landwirt\*innen mit der Nutzung digitaler Technologien in Verbindung bringen [LTT14; MWE18; Za21]. Außerdem ging aus der Literaturanalyse hervor, dass bisher nur wenig Forschung zum Datenmanagement (= alle technischen, konzeptionellen und organisatorischen Maßnahmen, die sich auf die Erhebung, Speicherung und Bereitstellung von Daten beziehen) der Betriebsleiter\*innen landwirtschaftlicher Betriebe durchgeführt wurde [He22; TDM21; Za21].

### 3 Methodik

Aufgrund des aktuell noch geringen Forschungsstandes zum Datenmanagement landwirtschaftlicher Betriebe wurde eine qualitative Umfrage durchgeführt. An der Umfrage, die im Zeitraum von November 2022 bis Februar 2023 abgewickelt wurde, nahmen insgesamt 60 Betriebsleiter\*innen (Ø 42 Jahre) von ökologisch und konventionell wirtschaftenden Ackerbaubetrieben (Ø 330 ha) mit Wohnsitz in Norddeutschland teil. Die Umfrage wurde auf Grundlage eines 27 Fragen umfassenden Interviewleitfadens durchgeführt und unter der Zuhilfenahme von „MAXQDA“ und „Microsoft Excel“ qualitativ nach dem Schema von Mayring [Ma91] ausgewertet.

Nach Abschluss der qualitativen Inhaltsanalyse wurde auf Grundlage der Befragungsergebnisse zudem eine Kategorisierung des Datennutzungsverhaltens aller Interviewteilnehmer\*innen vorgenommen. Für die Kategorisierung wurden alle Aussagen der Interviewteilnehmer\*innen zu einer Auswahlfrage des Interviewleitfadens („Wofür werden die gesammelten Daten genutzt?“) analysiert, sodass anschließend eine Einteilung in die Gruppen „Datenverwalter“, „Datennutzer“ und „Dateninnovatoren“ (siehe Tab. 1) vorgenommen werden konnte. In die Gruppe der „Datenverwalter“ wurden dabei alle Betriebsleiter\*innen eingeordnet, die bisher keine Daten verwerten oder Daten ausschließlich über Precision-Farming-Technologien automatisch verarbeiten lassen. Als „Datennutzer“ wurden wiederum alle Betriebsleiter\*innen charakterisiert, die bereits ein intensiveres Datenmanagement vorzuweisen haben und Daten auch schon „manuell“ (= nicht ausschließlich über technische Systeme), beispielsweise zur Planung oder Unterstützung der Entscheidungsfindung, verwerten. In die Gruppe der „Dateninnovatoren“ wurden wiederum nur Betriebsleiter\*innen aufgenommen, die bereits zusätzliche (entscheidungsrelevante) Informations- und Wissenspotenziale erschließen, indem sie Daten aus unterschiedlichen Systemen (individuell) kombinieren (z. B. für die teilflächenspezifische Bewirtschaftung).



## 4 Ergebnisse

Den Ergebnissen der vorliegenden Studie ist zu entnehmen, dass die Leistungsdaten von Maschinen und Ertragsdaten (im Sinne von Ertragskartierungen) bisher am häufigsten erhoben werden. Jene Daten werden bereits auf etwa einem Drittel der Betriebe erfasst und genießen damit einen höheren Stellenwert als Daten zur Arbeitszeiterfassung (23 %), Satellitendaten (15 %), N-Sensor-Daten (8 %), NIR-Sensor-Daten (7 %), georeferenzierten Bodenproben (3 %) und Wetterdaten (3 %).

Die Verarbeitung von Daten erfolgt bisher vor allem automatisch über Precision-Farming-Technologien wie Spurfahrassistenten oder Section Control. Etwa 80 % der Befragungsteilnehmer gaben an, jene Technologien bereits auf ihrem Betrieb zu nutzen. Die „manuelle“ Verarbeitung von Daten (= Datenverarbeitung, die nicht ausschließlich automatisch über technische Systeme erfolgt), beispielsweise zur Planung, Unterstützung der Entscheidungsfindung oder Kontrolle von betrieblichen Prozessen und Systemen (jeweils 40 %) ist demgegenüber (noch) weniger verbreitet. Ähnliches gilt auch für die Datenverarbeitung zur Rechnungserstellung und für Vergleichszwecke (jeweils 13 %) sowie die Verwertung von Daten zur besseren Kontrolle von Mitarbeitern (8 %).

Vor dem Hintergrund der aufgeführten Ergebnisse wurde zudem analysiert, wodurch die Bereitschaft der Betriebsleiter\*innen zur Nutzung von Daten beeinträchtigt wird. Aus der Analyse, im Zuge derer Intensität und Innovativität der Datennutzung unter Berücksichtigung unterschiedlicher Faktoren untersucht wurden, ging dabei hervor, dass die betrieblichen Einflüsse (z. B. Flächenausstattung) einen deutlich größeren Einfluss auf die Bereitschaft zur Datennutzung haben als die Einflüsse des Betriebsleiters (z. B. Alter, Bildungsstand).

Die Ergebnisse der Kategorisierung verschiedener Datennutzungsstrategien sind in Tabelle 1 zusammengefasst und veranschaulichen, dass nur ein vergleichsweise geringer Anteil (13 %) der Betriebsleiter\*innen Daten im Sinne der in Tabelle 1 dargebotenen Definition „innovativ“ nutzt. Zudem verdeutlichen die Ergebnisse, dass die Betriebsleiter\*innen konventionell wirtschaftender Betriebe Daten „innovativer“ nutzen als Landwirt\*innen in der ökologischen Landwirtschaft.

|                              | Definitionen  | Datenverwalter   | Datennutzer   | Dateninnovatoren |
|------------------------------|---|--|---|------------------|
|                              | Die Datennutzung erfolgt ausschließlich über technische Systeme (z. B. GPS, Section Control). | Die Datennutzung geht über die Verwertung mittels technischer Systeme hinaus. Daten werden z. B. auch für die Planung, zur Unterstützung der Entscheidungsfindung, als Abrechnungsgrundlage oder zur Kontrolle betrieblicher Prozesse genutzt. | Im Zuge der Datennutzung werden sogar zusätzliche Informations- und Wissenspotenziale erschlossen, indem Daten aus unterschiedlichen Systemen (individuell) kombiniert werden (z. B. für die teilflächenspezifische Bewirtschaftung). |                  |
| Anteile                      | alle Betriebe (n=60)  | 24 (40 %)  | 28 (≈ 47 %)   | 8 (≈ 13 %)       |
|                              | konventionelle Betriebe (n=40)  | 16 (40 %)  | 16 (40 %)   | 8 (20 %)         |
|                              | ökologische Betriebe (n=20)   | 12 (60 %)  | 8 (40 %)  | 0 (0 %)          |
| Merkmale des Betriebsleiters | ø Alter (Lebensjahre)   | 45   | 42  | 44               |
|                              | Hochschulabschluss  | 9 (≈ 38 %)   | 9 (≈ 32 %)  | 4 (50 %)         |
| Merkmale des Betriebs        | ø Flächenausstattung (ha)   | 214  | 294   | 801              |
|                              | Tierhaltung   | 15 (≈ 63 %)  | 20 (≈ 71 %)   | 2 (25 %)         |
|                              | Lohnunternehmen   | 1 (≈ 4 %)  | 2 (≈ 7 %)   | 3 (≈ 38 %)       |

Tab. 1: Kategorisierung des Datennutzungsverhaltens (eigene Darstellung)

Aus einer ergänzenden Analyse der charakteristischen Eigenschaften (siehe Tab. 1) ging außerdem hervor, dass die Merkmale des Betriebsleiters (Alter, Bildungsabschluss) einen geringeren Einfluss auf die Art und Intensität sowie Innovativität der Datennutzung haben als die betrieblichen Merkmale (z. B. Flächenausstattung, Tierhaltung). Im Detail ist den Analyseergebnissen zu entnehmen, dass die „Dateninnovatoren“ zumeist Betriebsleiter\*innen von Betrieben ohne Tierhaltung sind, die über eine überdurchschnittlich große Flächenausstattung verfügen. Ersichtlich wurde zudem, dass die Betriebsleiter\*innen ökologisch wirtschaftender Betriebe Daten im Durchschnitt weniger vielfältig nutzen (weniger Verwertungsoptionen) als ihre Berufskollegen\*innen in der konventionellen Landwirtschaft.

Interesse an einer weiteren Intensivierung des Datenmanagements – ausgehend vom aktuellen Status quo – signalisierten etwa 45 % der Befragungsteilnehmer\*innen, während etwa 30 % der Landwirt\*innen eine weitere Intensivierung ablehnten (25 % Enthaltung). Eine ergänzende Analyse offenbarte zudem, dass die „Datenverwalter“ eine Intensivierung des Datenmanagements häufiger ablehnen als die „Dateninnovatoren“, die bereits nach aktuellem Stand ein umfangreicheres Datenmanagement vorzuweisen haben.

Eine höhere Bereitschaft zur Nutzung von Daten könnte nach Auffassung zahlreicher Betriebsleiter\*innen (27 %) zukünftig entstehen, wenn die Bedienbarkeit digitaler Technologien einfacher wird, da ein Einsatz letzterer positiven Einfluss auf das Datenmanagement der Landwirte\*innen haben kann. Außerdem gaben die Betriebsleiter\*innen an, dass sich eine Verbesserung der Kompatibilität digitaler Technologien (25 %), eine Verringerung der Anschaffungskosten für digitale Technologien (20 %), eine Vergrößerung des Mehrwertes der Datennutzung (17 %), eine Verbesserung der Netzinfrastruktur (13 %), eine Vereinfachung der Datenauswertung (13 %), eine Verringerung der Fehleranfälligkeit digitaler Systeme (5 %) sowie eine Verbesserung der Datensicherheit positiv auf die Bereitschaft zur Datennutzung auswirken können (5 %).

Ersichtlich wurde zudem, dass die erfassten Daten bisher fast ausschließlich innerbetrieblich verwertet werden und eine überbetriebliche Weitergabe von Daten fast nur zu Vergleichszwecken (12 %) erfolgt. Außerdem brachten zahlreiche Landwirt\*innen zum Ausdruck, dass eine überbetriebliche Datenweitergabe – z. B. an forschende Institute – nur interessant sein kann, wenn sich infolgedessen ein unmittelbarer Mehrwert für den eigenen Betrieb einstellt und Datenschutzrisiken eingedämmt werden.

## 5 Diskussion und Schlussfolgerungen

Ziel der vorliegenden Arbeit war es, neue Erkenntnisse über das Datennutzungsverhalten der Betriebsleiter\*innen von Ackerbaubetrieben zu gewinnen und eine Kategorisierung unterschiedlicher Datennutzungsstrategien vorzunehmen. Aus der Analyse des Datennutzungsverhaltens ging dabei hervor, dass sich die „manuelle“ Datenverarbeitung (= Datenverarbeitung, die nicht ausschließlich über technische Systeme automatisch erfolgt) bisher weniger etabliert hat als die „automatische“ Datenverarbeitung (= Datenverarbeitung, die ausschließlich über technische Systeme erfolgt). Dies ist vermutlich der Fall, weil mit der „manuellen“ Verarbeitung von Daten ein höherer Mehraufwand einhergeht.

Außerdem ging aus der Umfrage hervor, dass die betrieblichen Merkmale (z. B. Flächenausstattung) einen größeren Einfluss auf die Bereitschaft zur Datennutzung haben als die Merkmale des Betriebsleiters (z. B. Alter, Bildungsabschluss). Dies ist möglicherweise der Fall, weil sich auf Betrieben mit größerer Flächenausstattung mehr digitale Technologien rentabel einsetzen lassen (Skaleneffekt), die zur Erhebung von Daten beitragen können. Vor dem Hintergrund dieser Wirkungszusammenhänge ist somit auch zu mutmaßen, dass das Datennutzungsverhalten der Betriebsleiter\*innen von Ackerbaubetrieben in nicht unwesentlicher Weise durch die monetären Voraussetzungen der Betriebe beeinträchtigt wird.

Die Befragung offenbarte weiterhin, dass die Betriebsleiter\*innen ökologisch wirtschaftender Betriebe Daten im Durchschnitt weniger vielfältig nutzen als ihre Berufskolleg\*innen in der konventionellen Landwirtschaft. Verantwortlich für das Resultat ist dabei vermutlich der geringere Bedarf zur Verwertung von Daten im Kontext der Ausbringung künstlicher Dünger und Pflanzenschutzmittel im ökologischen Sektor. Die Kategorisierung unterschiedlicher Datennutzungsstrategien ließ zudem erkennen, dass die „Datenverwalter“ eine Intensivierung des Datenmanagements häufiger ablehnen als die „Dateninnovatoren“, die bereits nach aktuellem Stand ein umfangreicheres Datenmanagement vorzuweisen haben. Vor dem Hintergrund des Resultats ist somit zu erwarten, dass sich die Betriebsleiter\*innen von Ackerbaubetrieben hinsichtlich der Intensität und Innovativität ihrer Datennutzung zumindest mittelfristig noch stärker voneinander unterscheiden werden.

Da zahlreiche Betriebsleiter\*innen nach aktuellem Stand noch keine „manuelle“ Datennutzung vorzuweisen haben, ist noch Optimierungspotenzial gegeben. Dieses könnte zukünftig ausgeschöpft werden, wenn bessere Voraussetzungen für den Einsatz digitaler Technologien (z. B. geringere Anschaffungskosten, bessere Kompatibilität, bessere Netzinfrastruktur) geschaffen werden. Außerdem erscheint es ratsam, Bildungsangebote auszuweiten, die über die vielfältigen Potenziale der Nutzung von Daten informieren. Dies könnte sich als förderlich erweisen, weil zahlreiche Betriebsleiter\*innen aktuell noch keinen zufriedenstellenden Mehrwert in der Nutzung von Daten erkennen.

#### Literaturverzeichnis

- [CC19] Caffaro, F., Cavallo, E.: The effects of individual variables, farming system characteristics and perceived barriers on actual use of smart farming technologies: evidence from the Piedmont Region, Northwestern Italy. *Agriculture* 9 (5) 111, 2019.
- [He22] Henningsen, J. et al.: Betriebliches Datenmanagement und FMIS. Machbarkeitsstudie für „Betriebliches Datenmanagement und Farm-Management-Information-System (FMIS)“ in sächsischen Landwirtschaftsbetrieben, Schriftenreihe des LfULG, Heft 4, 2022.
- [KI20] Klose, J. et al.: Datenaufbereitung in der Landwirtschaft durch automatisierte semantische Annotation. In: Gandorfer et al. (Hrsg.): *Digitalisierung für Mensch, Umwelt und Tier, Lecture Notes in Informatics (LNI)*, Gesellschaft für Informatik, Bonn: 133-138, 2020.
- [LTT14] Lencsés, E., Takács, I., Takács-György, K.: Farmers' perception of precision farming technology among Hungarian farmers. *Sustainability* 6: 8452-8465, 2014.
- [Ma91] Mayring, P.: Qualitative Inhaltsanalyse. In: Flick et al. (Hrsg.): *Handbuch qualitative Forschung: Grundlagen, Konzepte, Methoden und Anwendungen*: 209-213, 1991.
- [MWE18] Mitchell, S., Weersink, A., Erickson, B.: Adoption of precision agriculture technologies in Ontario crop production. *Canadian Journal of Plant Science* 98 (6): 1384-1388, 2018.
- [Pi19] Pivoto, D. et al.: Factors influencing the adoption of smart farming by Brazilian grain farmers. *International Food and Agribusiness Management Review* 22 (4): 571-588, 2019.
- [TDM21] Thompson, N., DeLay, N., Mintert, J.: Understanding the farm data lifecycle: collection, use, and impact of farm data on U.S. commercial corn and soybean farms. *Precision Agriculture* 22 (6): 1685-1710, 2021.
- [Za21] Zhang, A. et al.: Accelerating precision agriculture to decision agriculture: The needs and drivers for the present and future of digital agriculture in Australia. A cross-industry producer survey for the Rural R&D for profit 'Precision to Decision' (P2D) project. EP175936, CSIRO, Australia, 2021.

## Virtuelles Zäunen und ökologische Wirkungen von Weidewirtschaftung: Prototyp einer App zur Information der Öffentlichkeit

Oliver Schöttker <sup>1</sup>, Astrid Sturm <sup>2</sup> und Frank Wätzold <sup>3</sup>

**Abstract:** Wir präsentieren den Prototyp eines Informationssystems für die interessierte Öffentlichkeit (SMIÖff) zu den Themen nachhaltige Weidewirtschaft, virtuelles Zäunen und deren ökologischen Auswirkungen. Für den Prototyp werden agronomische und ökologische Daten zielgruppengerecht erklärt und aufbereitet sowie in notwendiges Hintergrundwissen eingebettet. Den Nutzern werden die zugrunde liegenden Informationen auf drei unterschiedliche Arten präsentiert: (1) Erläuterung von Hintergrundinformationen unter Verwendung von (2) interaktiven Elementen der Gamification, und (3) Präsentation und Erläuterung von Datenzeitreihen und geolokalisierten Karten. SMIÖff bietet als Web-App ein einfaches und niederschwelliges Informationsangebot, um interessierte Nutzer für die Wichtigkeit einer nachhaltigen und innovativen Nutzung von Grünland zu sensibilisieren, und überbrückt den in der Öffentlichkeit bestehenden „knowledge-gap“. SMIÖff dient damit der einfachen und schnellen Erstellung von Informationsangeboten innerhalb existierender Internetauftritte und kann problemlos um weitere inhaltliche Bausteine erweitert und auf andere Kontexte übertragen werden.


**Keywords:** Informationssystem, Digitalisierung, Software, virtuelles Zäunen, Web-App

### 1 Einleitung

Grünland und Weidewirtschaft sind wichtige Bestandteile landwirtschaftlicher Nutzflächen und Kulturlandschaften [HI22]. Etwa 29 % der landwirtschaftlichen Fläche in Deutschland sind bewirtschaftetes Grünland [BM22], durch welches zudem wichtige Ökosystemdienstleistungen (ÖSL) – u.a. Habitate für gefährdete Arten, Erholungswerte, Nahrungsmittelproduktion – bereitgestellt werden [HI22]. Die Art und Weise, wie Grünland bewirtschaftet wird, hat jedoch großen Einfluss auf die ÖSL [HS17] mit entsprechenden Auswirkungen auf den durch Grünland bereitgestellten gesellschaftlichen Nutzen. Die Öffentlichkeit hat jedoch nur eine begrenzte Kenntnis über die Bereitstellung von ÖSL durch Grünland sowie den Einfluss von Bewirtschaftung auf ÖSL und Tierwohl [SZ22]. Dieser Informationsmangel kann jedoch die Möglichkeit Einzelner beeinflussen,

---

<sup>1</sup> Brandenburgische Technische Universität Cottbus-Senftenberg, Environmental Economics, Erich-Weinert-Str. 1, 03046 Cottbus, oliver.schoettker@b-tu.de,  <https://orcid.org/0000-0002-5768-9860>,

<sup>2</sup> sturm@b-tu.de,  <https://orcid.org/0000-0002-7424-4484>,

<sup>3</sup> waetzold@b-tu.de,  <https://orcid.org/0000-0002-4664-0113>

gut informierte Entscheidungen zu treffen, zum Beispiel im Zusammenhang mit dem Konsum grünlandbezogener Milch- oder Fleischprodukte [MW18].

In dieser Arbeit stellen wir die Konzeption eines Prototyps eines „Softwarebasierten Mehrebenen Informationssystems für die Öffentlichkeit“ (SMIÖff) vor, welches im Rahmen des Forschungsprojektes „GreenGrass“ (greengrass-project.de) entwickelt wird. In „GreenGrass“ werden unterschiedliche Aspekte agronomischer, ökologischer und soziotechnischer Innovationen im Rahmen nachhaltiger Weidewirtschaft untersucht. Zentraler Bestandteil ist die Entwicklung einer virtuellen Hüte- und Zäunungstechnologie, welche nachhaltige Weidewirtschaft, Tierwohl und den Erhalt biologischer Vielfalt unterstützen soll. Zur Unterstützung der Umsetzung einer solchen Technologie werden umfangreiche Fernerkundungsdaten, sowie ökologische Informationen auf Feld- und Landschaftsebene erhoben und u.a. in den Softwarepaketen **SMI** für **Landwirte** (SMILe) [St23] und **SMI** für **Behörden** (SMIBe) (eingereicht zur Vorstellung auf der GIL Jahrestagung 2024) verwendet.

Zur Überbrückung dieser Informationslücke dient **SMIÖff** maßgeblich der Kommunikation von Hintergrundinformationen und Datenzeitreihen zu den Themen innovative Weidewirtschaft und virtuelles Zäunen an die interessierte Öffentlichkeit. **SMIÖff** setzt sich aus den drei Hauptbestandteilen (1) Informationsvermittlung, (2) interaktive Elemente und (3) Präsentation exemplarischer Datenzeitreihen und Karten zusammen. Mögliche Betreiber der Software sind Grünland-Landwirte, Behörden und andere weidewirtschaftliche Akteure, welche grünlandbezogene Informationen in digitalisierter Form an eine interessierte Öffentlichkeit kommunizieren wollen. Konsumenten der browserbasierten Web-App sind öffentliche Stakeholder wie etwa Konsumenten, Touristen oder Anlieger.

## 2 SMIÖff

Viele landwirtschaftliche Betriebe nutzen breite Daten- und Informationsgrundlagen zur Steuerung betrieblicher Abläufe. Daten und Informationen aus verschiedenen Quellen (z. B. Fernerkundungsdaten (Satelliten und UAV; [Hü23; Ko23]), agronomische und ökologische Felddaten [Sc21], Tiergesundheits- und Bewegungsdaten [Ha23]) werden im Rahmen von „precision farming“ und „precision grazing“ genutzt. Neben der internen betrieblichen Verwendung dieser Informationen im Rahmen von „farm management and information systems“ (FMIS), werden derartige Datenquellen zudem zu Monitoring- und Verwaltungszwecken auf behördlicher Seite verwendet. Jedoch hat auch die allgemeine Öffentlichkeit ein grundlegendes Interesse an dieser Informations- und Datenbasis (Abb. 1). Die Bereitstellung einer breiten Informationsbasis kann in diesem Zusammenhang neben der Befriedigung eines allgemeinen Informationsbedürfnisses auch eine Bildungsfunktion erfüllen sowie die Informationsgrundlage für alltägliche Entscheidungen verbessern.

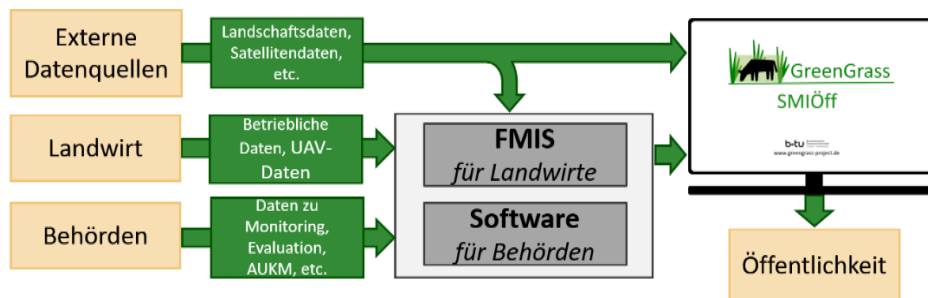


Abb. 1: Konzeption des Informationsflusses verschiedener Datenquellen in das Informationsportal SMIÖff sowie der Anbindung an die Öffentlichkeit

**SMIÖff** dient dazu, diese Informationslücke zu füllen und stellt eine „easy-to-use“ Informationsplattform für die breite Öffentlichkeit zur Verfügung. Relevante Informationen werden der Öffentlichkeit niederschwellig über eine browserbasierte Web-App zugänglich gemacht, welche in bereits bestehende Internetauftritte der Betreiber integriert werden kann. Die konkreten Inhalte der Web-App können dabei individuell vom Betreiber angepasst und so auf den gewünschten Informationskontext ausgerichtet werden. Zur Eingabe der Inhalte wird ein einfacher Contenteditor (für Texte, Grafiken, interaktive Elemente) in die Web-App integriert. Durch die Bereitstellung einer geeigneten Datenstruktur, in welcher die gewünschten Informationen gespeichert werden, sowie der genannten Funktionen der Web-App, kann der andernfalls notwendige hohe Entwicklungs- und Wartungsaufwand auf Seiten der Betreiber reduziert werden. **SMIÖff** kann als eigenständige Software von landwirtschaftlichen und behördlichen Betreibern genutzt und konfiguriert werden und bietet so die Möglichkeit, mehrere voneinander unabhängige, dezentrale Informationsangebote zu schaffen. SMIÖff stellt dabei nicht den Anspruch, ein Ersatz für bereits existierende Content Management Systeme zu sein, sondern stellt vereinfachte Funktionen für ein spezielles Publikum zur Verfügung.

Der für die Öffentlichkeit sichtbare Teil von **SMIÖff** besteht aus drei wesentlichen Bestandteilen, welche eine gezielte und effektive Informationsvermittlung ermöglichen: (1) Der Bereitstellung von Hintergrundinformationen zu den Themen nachhaltige und innovative Weidewirtschaft, virtuelles Hüten von Weidetieren und virtuelles Zäunen sowie deren ökologischen Wirkungen, Tierwohl, relevante Aspekte von Grünlandökologie und ÖSL. (2) Interaktiven Elementen, welche ein verbessertes Nutzererlebnis erlauben, sowie eine gezielte und nachhaltige Informationsvermittlung ermöglichen. Hierzu ist ein Wissensquizz mit zuvor erläuterten Hintergrundinformationen geplant. Weitere Elemente der Gamification dienen dazu, die Informationsvermittlung zu verbessern und Nutzer zu motivieren, sich mit den vermittelten Inhalten auseinanderzusetzen. Geplant sind hier Funktionen zum spielerischen Platzieren virtueller

Zäune auf einer Weide, um mögliche agronomische und ökologische Wirkungen direkt erfahrbar zu machen. Auch sollen Nutzer einfache Entscheidungen zu einer exemplarischen Weidebewirtschaftung treffen, um so die Komplexität agronomischer Entscheidungsfindungen hinsichtlich agronomischer, betriebswirtschaftlicher, regulatorischer und ökologischer Zielsetzungen zu verdeutlichen. Ergebnisse der Gamification-Elemente können zudem in individuellen Erfahrungspunkten oder „Highscores“ dargestellt werden. (3) Die Darstellung exemplarischer Datenzeitreihen und geolokalisierter Kartendarstellungen aus frei verfügbaren Satellitenerdbeobachtungen oder Drohnen-Fernerkundungskampagnen zur Verdeutlichung weidewirtschaftlicher Zusammenhänge und Auswirkungen von Weidewirtschaft auf die umgebende Landschaft und Ökosysteme ergänzt die Informationsgrundlage, und stellt dem Nutzer ein Bild realer Zusammenhänge dar.

### 3 Diskussion und Schlussfolgerung

Grünland ist ein wichtiger Bestandteil europäischer Kulturlandschaften und stellt verschiedene Ökosystemdienstleistungen zur Verfügung. Die landwirtschaftliche Nutzung dieser Kulturlandschaften, unterstützt von modernen Methoden aus dem „precision grazing“, hat sowohl positive als auch negative Auswirkungen auf die Funktionsfähigkeit von Kulturlandschaften und die von ihnen bereitgestellten ÖSL. Um die Nachhaltigkeit von Weidewirtschaft zu erreichen, muss neben einer produktions- und regulierungsseitigen Betrachtung auch die Sicherstellung einer ausreichenden Informationsgrundlage für die interessierte Öffentlichkeit gewährleistet sein. Nicht zuletzt, um die Entscheidungsgrundlage von Akteuren (z. B. Konsumenten) und die gesellschaftliche Akzeptanz der Nutzung landwirtschaftlicher Flächen zu Produktionszwecken zu verbessern. Um diese Informationen einfach bereitzustellen und zielgruppengerecht aufzubereiten und zu vermitteln bedarf es geeigneter niederschwelliger Softwarelösungen. SMIÖff stellt einen konzeptionellen Prototyp für ein Informationstool für die Öffentlichkeit im thematischen Kontext von Weidewirtschaft dar, indem Hintergrundinformationen und Datenzeitreihen an eine interessierte Öffentlichkeit vermittelt werden.

Aktuell befindet sich SMIÖff im Entwicklungsstand eines konzeptionellen Prototyps. Die geplanten Funktionen zur Informationsdarstellung und Vermittlung lassen sich einfach um zusätzliche Features erweitern. Möglich sind hier beispielsweise Umfrage- und Feedbackfunktionen, die Betreibern Einsichten über Nutzerverhalten, gewünschte Funktionen oder andere Datenerhebungsmöglichkeiten bieten. In diesem Zusammenhang können außerdem die innerhalb lokaler Instanzen der Web-App erzielten Erfahrungspunkte in öffentlichen Ranglisten zusammengeführt und dargestellt werden. Für einen möglichen Praxisbetrieb ist es zudem denkbar, zeitnah aktuelle Informationen und Datenzeitreihen aus betrieblich oder behördlich genutzten Informationssystemen direkt in SMIÖff einzuspeisen. In der Planung befinden sich diesbezüglich Funktionen zur Anbindung von SMIÖff an das bereits existierende Informationssystem SMILe [St23] und



das in der Entwicklung befindliche Informationssystem für Behörden (SMIBe). Zudem ist die zukünftige Verwendung öffentlich verfügbarer Datengrundlagen in SMIÖff denkbar. Auf diese Weise kann der Informationsumfang der Software einfach erweitert werden. Hierdurch ist die Verwendung von SMIÖff auch als Vorlage zur Kommunikation anderer landwirtschaftlicher Informationskontexte verwendbar. Dies kann beispielsweise durch an relevanten Orten aufgestellte Hinweistafeln oder QR-Codes unterstützt werden, die Betrachtern vor Ort eine einfache Möglichkeit geben, auf die Inhalte der Web-App zuzugreifen.

**Förderhinweis:** Die vorgestellten Arbeiten sind als Teil des Projektes „GreenGrass“ entstanden, welches vom Bundesministerium für Bildung und Forschung (BMBF) im Rahmen der Förderlinie „Agrarsysteme der Zukunft“ gefördert wird (Fördernummer 031B0734).

#### Literaturverzeichnis

- [BM22] Bundesministerium für Ernährung und Landwirtschaft (BMEL), Statistisches Jahrbuch 2022, Fachserie 3, Reihe 3.1.2.
- [Ha23] Hamidi, D.H.: Using smart farming technologies to improve the sustainability of livestock grazing systems, Georg-August-University Göttingen, 2023.
- [HI22] Horn, J.; Isselstein, J.: How do we feed grazing livestock in the future? A case for knowledge-driven grazing systems. *Grass and Forage Science* 77 (3), 2022.
- [HS17] Hendrickson, J.; Sanderson, M.: Perennial-Based Agricultural Systems and Livestock Impact on Soil and Ecological Services. *Soil Health and Intensification of Agroecosystems*, 2017.
- [Hü23] Hütt, C. et al.: UAV LiDAR Metrics for Monitoring Crop Height, Biomass and Nitrogen Uptake: A Case Study on a Winter Wheat Field Trial. *PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science* 91 (2), 2023.
- [Ko23] Kowalski, K. et al.: A generalized framework for drought monitoring across Central European grassland gradients with Sentinel-2 time series. *Remote Sensing of Environment* 286, 2023.
- [MW18] Markova-Nenova, N.; Wätzold, F.: Fair to the cow or fair to the farmer? The preferences of conventional milk buyers for ethical attributes of milk. *Land Use Policy* 79, 2018.
- [Sc21] Schmiedgen, A. et al.: Impacts of cutting frequency and position to tree line on herbage accumulation in silvopastoral grassland reveal potential for grassland conservation based on land use and cover information. *Annals of Applied Biology* 179 (1), 2021.

- [St23] Sturm, A. et al.: Wann, wo und wie? Ein softwarebasiertes Mehrebenen Informationssystem zur Optimierung von Beweidungssystemen. In C. Hoffmann et al.: Resiliente Agri-Food-Systeme. Lecture Notes in Informatics (LNI) – Proceedings Series of the Gesellschaft für Informatik (GI) Volume P-330. Bonn, 2023.
- [SZ22] Stampa, E.; Zander, K.: Backing biodiversity? German consumers' views on a multi-level biodiversity-labeling scheme for beef from grazing-based production systems. *Journal of Cleaner Production* 370, 2022.

## A crowdsensing-based smartphone app for optimal food storage and real-time best-before dates

Julia Senge<sup>1,2</sup>, Ellen Mielinger<sup>3</sup>, Marie Catherine Wendt<sup>3</sup>, Ramona Weinrich<sup>3</sup>, and Christian Krupitzer<sup>1,2</sup>

**Abstract:** Private households are responsible for 59% of Germany's 11 million tons of food waste. Consumers' behavior significantly contributes to food waste, prompting our concept to develop a smartphone application aimed at diminishing uncertainties about food expiration and safety. Utilizing a Design Science approach, we developed a prototype for a smartphone app, integrating novel functionalities to minimize food waste at the consumer household level. We analyzed existing market applications and, as a result, introduced the Freshlimeter, a unique feature that estimates the real-time best-before date within our app using feedback from consumers. We also highlight the potential for innovative app features, such as integrating a chatbot with image recognition capabilities to enable freshness assessments, especially for unpackaged or opened food.

**Keywords:** agri-food chain, agri-food systems, design science approach, food waste, machine learning, smartphone application

### 1 Introduction

Every year in Germany, around 11 million tons of food are wasted. Private households produce the highest amount (59%) of this wastage [St23]. The origin of this excessive food waste can be attributed to several factors, most notably: 36.6% was due to the perception that the product was spoiled, 15.2% because it seemed unsavory, and 5.8% because of an expired best-before date (BBD) of which almost half is disposed in unopened packaging [SSC19]. Besides saving resources, a 50% reduction of food waste in private households, which the German government aims for until 2030, can save six million tons of CO<sub>2</sub>-equivalent greenhouse gas emissions [BM23].

Some consumers are uncertain about the food's freshness. This uncertainty worsens when individuals lack knowledge or guidance on the product's shelf life and optimal storage

---

<sup>1</sup> University of Hohenheim, Department of Food Informatics, Fruwirthstr. 21, 70599 Stuttgart, Germany, julia.senge@uni-hohenheim.de, christian.krupitzer@uni-hohenheim.de

<sup>2</sup> University of Hohenheim, Computational Science Hub, Schloss Hohenheim, 70599 Stuttgart, Germany

<sup>3</sup> University of Hohenheim, Department of Consumer Behaviour in the Bioeconomy, Wollgrasweg 49, 70599 Stuttgart, Germany, ellen.mielinger@uni-hohenheim.de, mariecatherine.wendt@uni-hohenheim.de, ramona.weinrich@uni-hohenheim.de

conditions [Zi20]. Without clear information, such uncertainties can lead to premature disposal of edible food, contributing to the food waste problem.

To help tackle this, we propose a smartphone application to reduce food waste by enhancing the confidence of consumers' decision-making regarding the expired BBD for packaged products and the edibility of opened or unpacked products. The app distinguishes itself from existing applications by focusing on food items that consumers already possess. Users can scan products and receive feedback regarding the BBD based on reviews from other users. Further, the app offers information about the optimal storage conditions.

In the following, we present a comprehensive overview of the role of the app within the food supply chain. Additionally, we will showcase the app's user interface and functionalities and discuss future features that could enhance the app's value.

## 2 Design and Implementation of the Smartphone Application

This work follows a Design Science Approach [HMP04]. Hence, we developed a prototype of the app as a tool to reduce food waste. In this section, we present the smartphone app concept and its integration into the food supply chain. Further, we describe the app's user interface and implementation. The app was developed in Android Studio, using Kotlin. Kotlin, being concise and interoperable with Java, offers robustness and flexibility for Android development.

### 2.1 Concept and integration into the food supply chain

Fig. 1 shows the food supply chain as part of a digitalized agri-food system [KS24], with our app distinctly positioned at the final consumer stage. Arrows indicate the flow of information, illustrating how feedback from consumers, captured through the app, loops back into the system, benefitting both consumers and manufacturers. A central data repository is fed by the app data, stores data provided by manufacturers (product information) or retailers (discount promotion), and collects and aggregates consumer feedback on the BBDs. As a result, companies can retrieve and utilize this valuable consumer feedback. They also have the option, respecting data sovereignty, to share it with other institutions, such as consultancy firms or research facilities. This data is also used to calculate the *Freshlimeter* score, which indicates the consumability of a food product after exceeding the BBD. Additionally, the data supports a verification of the consumers' reviews. For both types of analysis, we plan to apply machine learning procedures; however, those metrics are not in the scope of this paper and, hence, omitted.

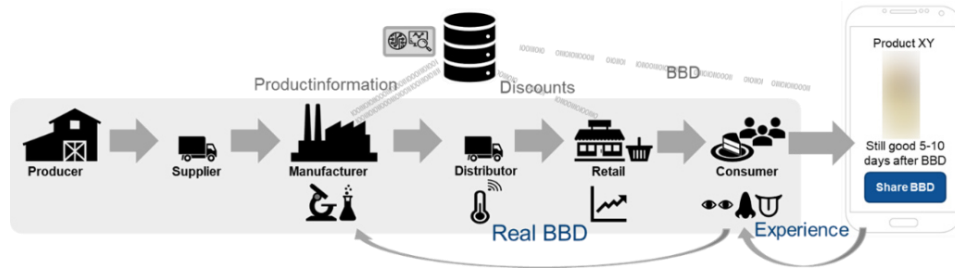


Fig. 1: Integration of the app into the food supply chain

## 2.2 User interface design

An intuitive and user-friendly interface is essential for app engagement. This study focuses on the functionality for determining food freshness and optimal storage conditions. Fig. 2 shows the design of this functionality, which we explain in the following.

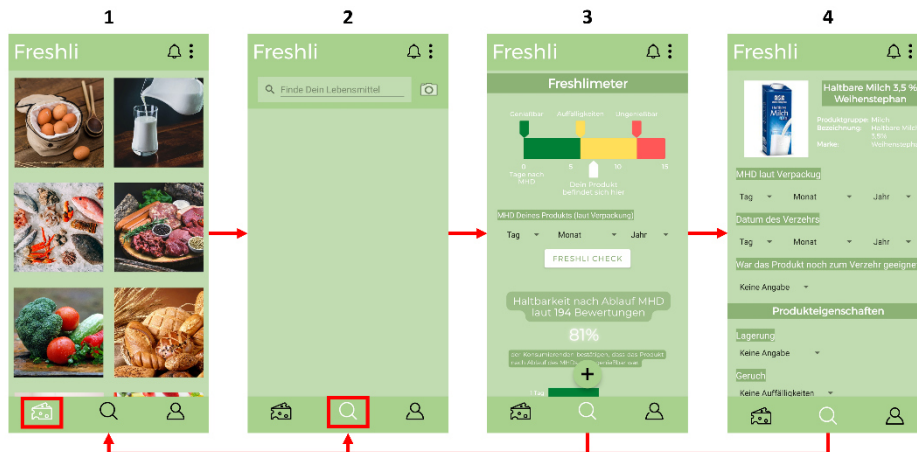


Fig. 2: Interface and interaction of the smartphone application; home screen (1); product search (2); product information (3); product feedback (4)

The home screen (1), indicated by the cheese icon (e.g., (1) bottom left) on the navigation bar, visualizes the product groups of a typical supermarket. Users can tap on any of these categories to access product information and their ideal storage conditions. Navigating to the products search functionality by clicking the magnifier glass icon (e.g., (2) bottom middle), users can effortlessly search for a product in multiple ways: (i) directly entering a product name into the text bar, (ii) using the built-in scanner to capture the barcode, or (iii) snapping a picture of the product package for a visual search.

The search function leads to the product information page (3). Along with general product details, the page presents the unique *Freshlimeter*, a traffic light system that provides an intuitive indication of the product's freshness status after surpassing its BBD. If available, the user can input the BBD of the product to get a personalized freshness assessment based on collective user experiences. The app offers to share product experiences using a standardized form when accessing the consumer feedback page via the plus sign (4). The forms entail details about the product's BBD, consumption date, acceptability, and specific characteristics like taste, smell, and texture. Users also provide information about storage type and a consumption experience rating on a scale from 0 (unable to consume) to 5 (perfectly fine). Additionally, they can leave further comments. This data is assimilated upon submission to refine the app's prediction model for the freshness assessment.

The freshness assessment described above is mainly suitable for packaged food due to the availability of a BBD on the package. A different approach is required for opened or unpacked food since the BBD no longer applies or is missing. For these cases, we plan to integrate a digital assistant designed to simulate human-like dialogue, embark on queries, and provide feedback tailored to the user's responses. This chatbot can offer an educated assessment of the food item's freshness by matching user descriptions with pre-programmed knowledge, such as a sour taste indicating fermentation. However, this approach might need adjustment to cover the different needs of users by integrating an advanced image recognition system into the application to bridge this potential gap. This function enables users to capture a photograph of their food item and compare it against a database of reference images. Each image in this database is tagged with various freshness stages, serving as a visual benchmark. Users will also be able to compare their food to existing pictures provided by the chatbot due to their description to tackle the limitations of picture quality differences. However, this technology exceeds the scope of this paper and will be part of future research.

### **3 Discussion**

In this section, we discuss the capability and limitations of the app prototype based on the previously described features. Furthermore, we conducted a preliminary study with ten students (21-29 years) to evaluate the app prototype; the following section will discuss the insights and results.

#### **3.1 App capability and limitations in minimizing food waste**

Factors that can increase or decrease the likelihood of app utilization, regarding consumer satisfaction and loyalty, can be summarized to four thematic areas: learning benefits, personal benefits, social benefits, and hedonic benefits [Sh23]. The app supports users in learning the best food storage practices and clarifies real BBDs of products, going beyond just their stated expiry dates. Significant advantages include reduced expenses from

extended food life and minimized wastage, combined with peace of mind by removing uncertainties regarding freshness. The ability to share reviews facilitates community engagement, empowering users to benefit from shared experiences and insights.

In this preliminary study, the participants expressed difficulties interpreting the *Freshlimeter* on the product information screen. The freshness assessment further compounded this confusion since its presence was not immediately apparent to them. Enhancing its visibility or positioning it more prominently on the page could ensure that users recognize and utilize this essential functionality more intuitively. Furthermore, presenting users with both the *Freshlimeter* and a bar chart on the same page made the information feel dense and overwhelming. Given the consistent feedback, prioritizing one of these visualization tools and centering it on the page can improve the user experience. The feedback mechanism was straightforward and intuitive, suggesting that universal symbols can effectively guide user actions without explicit instructions. The participants also emphasized a distinct need for assessing the freshness of unpacked foods, given their lack of “best before” indications compared to packaged items. Since the chatbot approach was not part of the prototype development, evaluating this feature was impossible.

Furthermore, the data aggregated from these interactions holds immense value. It can offer important feedback to food producers and manufacturers, allowing them to refine their processes based on real-time consumer and industry insights. This proactive approach ensures the maintenance of high-quality standards across the food supply chain.

## 4 Conclusion and Outlook

This work investigated the design of a smartphone application concept to reduce food waste. Therefore, a prototype of the proposed app was developed. Despite challenges in design and functionality, the app concept presents a promising tool for addressing food waste effectively, not just for consumers but throughout the food supply chain. Though the app educates about optimal food storage and real BBDs, our preliminary study highlighted areas for improvement, such as enhancing the visibility and user-friendliness of the *Freshlimeter*.

Given that unpacked food plays a significant role in the uncertainty and gaps in storage knowledge, the app's emphasis on chatbot-like support for supporting consumers in the decision of the edibility of food is an interesting planned future work. For this, we propose the implementation of a chatbot integrated with image recognition capabilities. We are establishing a testbed to assess food freshness by measuring emitted aroma components throughout storage time with metal-oxide sensors. This research also incorporates destructive measurement methods and image-based analysis to create a freshness assessment model. The resulting digital food twin [KNB22] will be integrated into the chatbot to evaluate food freshness according to user responses, considering varied storage conditions and common consumer errors. While the primary aim is to reduce household

food wastage, the application's potential utility extends far beyond individuals. This tool can be deployed across the whole agri-food chain. Employees can swiftly assess product quality without special training at transportation stages or points of sale. Similarly, consumers can use the tool's capabilities during shopping trips for on-the-spot evaluations. There is an opportunity even at the first stage of food production, i.e., harvesting. Farmers and agricultural workers could use the tool to detect and separate spoiled goods instantly, ensuring that only the freshest produce makes its way to the market.

**Acknowledgments:** This work has been funded by the BMBF in the funding scheme “Neue Produkte für die Bioökonomie” under the funding reference number 031B1332.

#### Bibliography

- [BM23] BMEL: Nationale Strategie zur Reduzierung der Lebensmittelverschwendung, [www.bmel.de/DE/themen/ernaehrung/lebensmittelverschwendung/strategie-lebensmittelverschwendung.de](http://www.bmel.de/DE/themen/ernaehrung/lebensmittelverschwendung/strategie-lebensmittelverschwendung.de), Accessed: 14.10.2023.
- [HMP04] Hevner, A.R.; March, S.T.; Park, K.: Design Research in Information Systems Research. *MIS Quarterly* Vol. 28, Nr. 1, 75-105, 2004.
- [KNB22] Krupitzer, C.; Noack, T. & Borsum, C.: Digital Food Twins Combining Data Science and Food Science: System Model, Applications, and Challenges. *Processes* (10): 1781, 2022.
- [KS24] Krupitzer, C.; Stein, A.: Unleashing the Potential of Digitalization in the Agri-Food Chain for Integrated Food Systems. In *Annual Review of Food Science and Technology*, Volume 15, 2024.
- [SSC19] Schmidt, T.; Schneider, F.; Claupein, E.: Food waste in private household in Germany – Analysis of findings of a representative survey conducted by GfK SE in 2016/2017. *Thünen Working Paper 92a*, 2019.
- [Sh23] Shaikh, E. et al.: Consumer satisfaction and consumer loyalty: an empirical case study on the impact of benefits generated through smartphone applications. *International Journal of Public Sector Performance Management* Vol. 12, 119-139, 2023.
- [St23] Statistisches Bundesamt: Lebensmittelabfälle in Deutschland, [www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Umwelt/Abfallwirtschaft/Tabellen/lebensmittelabfaelle..](http://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Umwelt/Abfallwirtschaft/Tabellen/lebensmittelabfaelle..), Accessed: 23.10.2023.
- [Zi20] Zielinska, D. et al.; Consumer Understanding of the Date of Minimum Durability of Food in Association with Quality Evaluation of Food Products After Expiration. *International Journal of Environmental Research and Public Health* Vol. 17, 1632, 2020.



# Ökonomische Bewertung und Vergleich von Pflanzenschutzverfahren mit Fokus auf Herbizidreduktion durch Digitalisierung am Beispiel des Zuckerrübenanbaus

Christian Sponagel <sup>1</sup>, Felix Witte<sup>1</sup> und Enno Bahrs<sup>1</sup>

**Abstract:** Die Reduktion des Einsatzes von chemisch-synthetischen Pflanzenschutzmitteln ist ein wichtiges politisches Ziel. Neue Technologien wie Smart Spraying könnten deshalb künftig an Relevanz gewinnen. Ökonomische Analysen und Kostenvergleiche dieser Technologien sind somit wichtig. Der Beitrag vergleicht daher die Pflanzenschutzkosten der Verfahren eines Feldroboters, der Hacke-Bandspritze sowie Smart Spraying mit der Anhängespritze und analysiert die Herbizid-Vermeidungskosten im Sinne der Effizienz der Herbizidreduktion in Zuckerrüben. Die ökonomische Vorzüglichkeit von Smart Spraying hängt dabei wesentlich von der potenziellen Einsparung und der Rübenanbaufläche ab, wobei sich eine Vorzüglichkeit zu den anderen Verfahren bei 40 % Herbizideinsparung erst bei einer Rübenanbaufläche von etwa 85 ha ergibt. Auch der Einsatz der Hacke-Bandspritze mit 60 % Herbizideinsparung ist erst ab 75 ha Rübenfläche günstiger als eine Standard-Flächenspritzung. Der betrachtete Feldroboter wird vermutlich auch künftig vor allem im Ökolandbau zum Einsatz kommen, wo ein Komplettverzicht auf Herbizide essenziell ist.

**Keywords:** Pflanzenschutz, Kostenvergleich, Zuckerrüben, Robotik, Smart Spraying

## 1 Einleitung

Biodiversität ist ein zentraler Baustein nachhaltiger und resilienter Agrarsysteme, beispielsweise durch die Bereitstellung produktionsrelevanter Ökosystemleistungen wie Bestäubung [Tc12]. Insbesondere der Einsatz von chemisch-synthetischen Pflanzenschutzmitteln stellt jedoch ein Risiko für die Artenvielfalt dar [Ta21]. Die Reduktion der Einsatzmengen und des Risikos des chemisch-synthetischen Pflanzenschutzes ist deshalb ein zentrales Ziel der EU-Farm-to-Fork-Strategie [Eu20]. Herbizide hatten im Jahr 2022 einen Anteil von mehr als 50 % am Inlandsabsatz an Wirkstoffen in Deutschland [Bv23], weshalb sich hier erhebliche Einsparpotenziale ergeben können.

Zur Reduktion des Einsatzes von chemisch-synthetischen Pflanzenschutzmitteln bestehen aus betrieblicher Sicht unterschiedliche Anpassungsmöglichkeiten wie die Umstellung auf den ökologischen Landbau oder ein Komplettverzicht auf chemisch-synthetische

---

<sup>1</sup> Universität Hohenheim, Fachgebiet Landwirtschaftliche Betriebslehre, Schwerzstrasse 44, 70593 Stuttgart, Christian.Sponagel@Uni-Hohenheim.de,  <https://orcid.org/0000-0003-4637-4916>, Felix.Witte@Uni-Hohenheim.de, Bahrs@Uni-Hohenheim.de

Pflanzenschutzmittel unter Einsatz von Mineraldüngern [Zi21]. Der Kompletterzicht kann jedoch mit vergleichsweise hohen Ertragseinbußen verbunden sein und entsprechend hohe Kosten auf einzelbetrieblicher Ebene induzieren, insbesondere beim Anbau von Hackfrüchten wie Zuckerrüben [Ma23]. Im Sinne der Vermeidungskosten für den Einsatz von Pflanzenschutzmitteln könnte ein Teilverzicht somit eine effiziente Alternative in Rüben darstellen. Neue Technologien wie Feldroboter oder KI-gestützte Feldspritzen mit einem sogenannten „Smart Spraying“-Ansatz könnten den Einsatz von Herbiziden in Hackfrüchten deutlich reduzieren [He22; Sp23]. Gemessen am Behandlungsindex machen Herbizide in Zuckerrüben bereits etwa zwei Drittel der eingesetzten Pflanzenschutzmittelmenge aus [Jki22], was das Potenzial gerade in dieser Kultur verdeutlicht. Die Adaption der Technologien wird vor dem Hintergrund der politischen Ziele zur Pflanzenschutzmittelreduktion wahrscheinlich künftig eine größere Rolle spielen. Im Kontext der Technologieakzeptanz und betrieblicher Entscheidungen sind daher ökonomische Bewertungen und Kostenvergleiche wichtig. Zielsetzung dieses Beitrags ist daher ein Kostenvergleich unterschiedlicher (teil-) automatisierter Verfahren des Pflanzenschutzes am Beispiel des Zuckerrübenanbaus, die mit einer Ableitung der Herbizid-Vermeidungskosten kombiniert werden, um die Effizienz des Pflanzenschutzverzichts zu bewerten. Die Arbeit ergänzt bzw. synthetisiert damit bestehende ökonomische Analysen zu Feldrobotern oder Smart Spraying.

## **2 Material und Methoden**

### **2.1 Auswahl der Pflanzenschutzverfahren**

Für die ökonomische Analyse wurden vier Verfahren des Pflanzenschutzeinsatzes in Zuckerrüben ausgewählt: eine Standard-Anhängespritze, eine Hacke-Bandspritze, ein autonomer Feldroboter sowie ein Smart-Spraying-Ansatz. Als Feldroboter wurde der Farmdroid FD 20 [Fa23] exemplarisch ausgewählt, da für diesen bereits Praxiserfahrungen vorliegen [Sp23]. Außerdem wurde die Anhängespritze AMAZONE UX 5201 SmartSprayer als KI-gestütztes Pflanzenschutzverfahren ausgewählt, welche sich bereits im Praxiseinsatz befindet. Durch eine Bilderkennung von Unkräutern in Echtzeit können Herbizide präzise statt breitflächig ausgebracht werden und somit der Aufwand im Rahmen einer Überfahrt um bis zu 70 % reduziert werden [Am23a]. Als Standard-Anhängespritze wurde die korrespondierende Grundmaschine UX 5201 ohne Smart-Spraying-Komponenten gewählt, um eine Vergleichbarkeit herzustellen [Am23b]. Das Verfahren Hacke-Bandspritze wurde durch die Bandspritzeinrichtung RowSpray mit einer 6-m-Arbeitsbreite repräsentiert [Sc23].

## 2.2 Ökonomische Bewertung der ausgewählten Verfahren sowie ihrer Effizienz

Für jedes Verfahren wurden die Direkt- und Arbeiterledigungskosten des Pflanzenschutzsinsatzes kalkuliert. Die ökonomischen Kennzahlen basieren auf Standardkalkulationsdaten [Kt23a], einzelnen Veröffentlichungen [Sp23] und dem persönlichen Kontakt mit den Herstellern und dem Landmaschinenhandel. Die Direktkosten setzen sich dabei aus den Kosten der Pflanzenschutzmittel zusammen, die unter anderem von der verfahrensspezifischen Mengeneinsparung bei Herbiziden abhängen. Es wurden standardmäßig Kosten für Fungizide in Höhe von 70 €/ha sowie Herbizidkosten von 315 €/ha bei voller Einsatzmenge unterstellt [Kt23b]. Die potenzielle Herbizideinsparung wurde im Rahmen einer Sensitivitätsrechnung variiert. Sie betrug zwischen 30 % und 50 % im Falle des Smart-Spraying-Verfahrens [Eu21] und zwischen 40 % und 60 % für das Verfahren Hacke-Bandspritze [Wa22]. Bei Einsatz des Feldroboters liegt die Herbizideinsparung bei 100 %. Da bei diesem Verfahren jedoch mit einer Restverunkrautung gerechnet werden kann, wurde ein Ertragsabschlag von 5 % bzw. geringeren Leistungen von 120 €/ha bei 800 dt Ertrag/ha veranschlagt [Kt23b]. Für alle Verfahren wurden drei Überfahrten für die Unkrautregulierung und eine Überfahrt für die Fungizidanwendung berücksichtigt. Für die Standard-Feldspritze wurden variable Maschinenkosten in Höhe von 3 €/ha pro Überfahrt kalkuliert und für die Hacke-Bandspritze 20 €/ha [Kt23b]. Um den höheren Arbeitsaufwand beim Verfahren Hacke-Bandspritze zu antizipieren, wurden Lohnkosten in Höhe von 32,25 €/ha und Überfahrt angenommen, was einem Lohnansatz von 25 €/Std. entspricht [Kt23b]. Für den Smart Sprayer wurden mangels Datenverfügbarkeit Kosten in doppelter Höhe von 6 €/ha und Überfahrt angenommen. Der Farmdroid wurde mit variablen Maschinenkosten in Höhe von 37 €/ha und Überfahrt bewertet [JH22].

Die Fixkosten der Verfahren wurden gemäß Anschaffungskosten, Nutzungsdauer und Kapazität der Maschinen in Abhängigkeit der Auslastung bzw. der Betriebsgröße ermittelt. Als Anschaffungskosten wurden 90.000 € für den Farmdroid [Sp23], 120.000 € für die Anhängespritze und 100.000 € für die Hacke-Bandspritze angesetzt. Für den Smart Sprayer liegen keine öffentlich zugänglichen Kostendaten vor, sodass im Modell ein Aufpreis von 100 % zur Anhängespritze bzw. 50 % als Sensitivitätsrechnung betrachtet wird. Die Nutzungsdauer wurde für alle Maschinen mit zehn Jahren und der Restwert mit 20 % angenommen. Der maximale Einsatzumfang wurde für die Anhängespritze mit und ohne Smart-Spraying-Komponente bei 1.440 ha behandelte Fläche pro Jahr gesetzt und bei 300 ha für das Hacke-Bandspritze Verfahren [Kt23a] sowie bei 18 ha und Jahr für den Farmdroid [Sp23]. Im Gegensatz zur Anschaffung des Farmdroids oder der Hacke-Bandspritze substituiert eine Pflanzenschutzspritze mit Smart-Spraying-Technologie die Standard-Anhängespritze gänzlich, was bei der Kalkulation der Arbeiterledigungskosten der Fungizidbehandlung berücksichtigt wurde. Demnach fallen insbesondere die Fixkosten für die Anhängespritze als Standardverfahren dennoch an und werden auch der Rübenfläche für die Fungizidapplikation zugeordnet. Die Betriebsfläche wurde in der Berechnung zwischen 40 und 400 ha Ackerland bzw. zehn und 100 ha Zuckerrübenanbaufläche variiert. Die Vermeidungskosten des Herbizideinsatzes wurden

in Bezug auf die Veränderung des Behandlungsindex (BI) als Indikator für die Pflanzenschutzintensität je Einheit im Vergleich zur Flächenspritzung mit der Anhängespritze ohne Einsparung berechnet. Als Referenzwert für den BI diente der Bundesdurchschnitt von 3,05 im Jahr 2021 [Jk22].

### 3 Ergebnisse

Die Ergebnisse zeigen, dass die ökonomische Vorzüglichkeit der Verfahren neben der Betriebsgröße stark von der möglichen Herbizideinsparung abhängt. Bis zu einer Rübenanbaufläche von ca. 67 ha bzw. 85 ha beim Smart-Spraying-Aufpreis von 100 % und einer Herbizideinsparung von 50 % bzw. 40 % ist die Standard-Flächenspritzung das ökonomisch vorzüglichste Verfahren. Bei angenommenen 30 % Herbizideinsparung ist Smart Spraying bis zu einer Rübenanbaufläche von 100 ha nicht vorzüglich. Liegt der Anschaffungspreis jedoch nur um 50 % über dem der Anhängespritze, dann wird eine Vorzüglichkeit bereits bei 59 ha Rübenfläche und 30 % Herbizideinsparung erreicht. Der Einsatz einer Hacke-Bandspritze ist mit einer 60%-Einsparung erst ab ca. 75 ha Rübenfläche günstiger als das Verfahren der Anhängespritze. Die Kosten des Farmdroids haben einen sprungfixen Charakter und es werden kaum Degressionseffekte erzielt.




Abb. 1: Direkt- und Arbeiterledigungskosten des Pflanzenschutzes in Euro je ha Rübenanbaufläche in Abhängigkeit des Verfahrens und des Anbauumfangs

Bis zu einer Rübenanbaufläche von etwa 18 ha sind die Herbizid-Vermeidungskosten je BI-Einheit mit Einsatz des Farmdroid mit Kosten in Höhe von etwa 101 € am niedrigsten. Bis zu einer Rübenanbaufläche von ca. 50 ha zeigt das Verfahren Hacke-Bandspritze die

höchste Effizienz mit Vermeidungskosten von ca. 30 € je BI-Einheit. Smart Spraying mit 100 % Anschaffungspreiszuschlag zeigt mit 50 % Herbizideinsparung ab einer Anbaufläche von ca. 50 ha die niedrigsten Vermeidungskosten. Geringere Einsparungsraten von 30 % oder 40 % sind bis 100 ha Rübenfläche teurer als eine Hacke-Bandspritze mit 60 % Herbizideinsparung. Liegt der Anschaffungspreis von Smart Spraying nur um 50 % über der Anhängespritze, dann ist dieses Verfahren bereits ab einer Rübenfläche von 28 ha unabhängig von der Einsparung das kosteneffizienteste Verfahren der Herbizidreduktion.

#### 4 Diskussion und Schlussfolgerungen

Die Ergebnisse zeigten, dass KI-gestützte Systeme wie Smart Spraying erst bei vergleichsweise großen Betriebsstrukturen unter der geschätzten Herbizideinsparung von 40 % [Eu21] wirtschaftlich sein können. Etwa 6 % der Betriebe mit Zuckerrübenanbau in Deutschland haben eine Betriebsgröße über 500 ha und bewirtschaften ca. 30 % der Rübenfläche insgesamt [Bu23]. Auf diesen Betrieben kann Smart Spraying wirtschaftlich sein, wobei die Herbizideinsparung über 30 % liegen sollte. In kleinstrukturierten Regionen könnte die Technologie am ehesten im Rahmen des überbetrieblichen Maschineneinsatzes Anwendung finden. Die potenziellen PSM-Einsparungspotenziale sowie der mögliche Anschaffungspreis sind relevant für die ökonomische Vorzüglichkeit. Auf betrieblicher Ebene könnte Smart Spraying zur Erhöhung der Wirtschaftlichkeit auch in mehreren Kulturen wie Zuckerrüben und Mais eingesetzt werden. Feldroboter werden vermutlich auch künftig vor allem im Ökolandbau Anwendungspotenzial haben, wo ein Verzicht auf Herbizide essenziell ist. Somit offenbart der Vergleich der Direkt- und Arbeitserledigungsverfahren sowie der Herbizid-Vermeidungskosten unterschiedliche Vorzüglichkeiten der Verfahren, was im Kontext förderpolitischer Ziele von Relevanz ist.

#### Literaturverzeichnis

[Am23a] Amazone: AMAZONE UX SmartSprayer. URL <https://tinyurl.com/mpzburfh>. - abgerufen am 2023-10-17.

[Am23b] Amazone: Anhängespritze UX Super. URL <https://tinyurl.com/3x4xexps>. - abgerufen am 2023-10-17.

[Bu23] Bundesministerium für Ernährung und Landwirtschaft: Bodennutzung und pflanzliche Erzeugung: Kartoffeln und Zuckerrüben. URL <https://tinyurl.com/y855z6hn>. - abgerufen am 2023-10-24.

[Bv23] BVL: Absatz an Pflanzenschutzmitteln in der Bundesrepublik Deutschland. Ergebnisse der Meldungen gemäß § 64 Pflanzenschutzgesetz für das Jahr 2022. URL <https://tinyurl.com/ye2ta287>. - abgerufen am 2023-10-17.

[Eu20] European Commission: Communication from the Commission to the European

Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions. A Farm to Fork Strategy for a fair, healthy and environmentally-friendly food system.

[Eu21] European Commission: Demonstration of an agronomy-integrated see & spray technology for a more sustainable use of pesticide in agriculture. URL <https://webgate.ec.europa.eu/life/publicWebsite/project/details/5724>. - abgerufen am 2023-10-17.

[Fa23] Farmdroid: FD20 Datenblatt. URL <https://farmdroid.dk/de>. - abgerufen am 2023-10-17.

[He22] Herrmann, D. et al.: Innovationen in der Pflanzenschutztechnik. In: Jahrbuch Agrartechnik 2021, Institut für Mobile Maschinen und Nutzfahrzeuge, Bd. 33, 2022.

[Jk22] JKI: PAPA Erhebung des JKI - Ergebnisse. URL <https://papa.julius-kuehn.de/index.php?menuid=29>. - abgerufen am 2023-06-07.

[JH22] Jungwirth, M.; Handler, F.: Arbeitszeitbedarf und Arbeitserledigungskosten eines teilautonomen Feldroboters für die Saat und das Hacken von Biozuckerrüben.

[Kt23a] KTBL: MaKost - Maschinenkosten und Reparaturkosten. URL <https://www.ktbl.de/home/webanwendungen/makost>. - abgerufen am 2023-10-17.

[Kt23b] KTBL: Leistungs-Kostenrechnung Pflanzenbau. URL <https://daten.ktbl.de/vrpflanze/>. - abgerufen am 2023-05-15.

[Ma23] Mack, G. et al.: Modelling policies towards pesticide-free agricultural production systems. In: Agricultural Systems Bd. 207, S. 103642, 2023.

[Sc23] Schmotzer: Bandspritzeinrichtung RowSpray. URL <https://www.schmotzer-ht.de/portfolio/bandspritze/>. - abgerufen am 2023-10-17.

[Sp23] Spykman, O. et al.: Wirtschaftlichkeitsbewertung eines Feldroboters auf Basis erster Erfahrungen im Praxiseinsatz. 43. GIL-Jahrestagung, Resiliente Agri-Food-Systeme. Bonn: Gesellschaft für Informatik e.V., pp. 255-266. Osnabrück. 13.-14. Februar 2023.

[Ts12] Tschamtko, T. et al.: Global food security, biodiversity conservation and the future of agricultural intensification. In: Biological Conservation Bd. 151, Nr. 1, S. 53–59, 2012.

[Ta21] Tang, F. H. M. et al.: Risk of pesticide pollution at the global scale. In: Nature Geoscience Bd. 14, Nr. 4, S. 206–210, 2021.

[Wa22] Warnecke-Busch, G.: Systeme zur Unkrautregulierung mit Hacke und Bandspritze in Zuckerrüben (*Beta vulgaris* subsp. *vulgaris*) - Versuche in Niedersachsen. In: Tagungsband: 30. Deutsche Arbeitsbesprechung über Fragen der Unkrautbiologie und -bekämpfung, Julius-Kühn-Institut, S. 392–399, 2022.

[Zi21] Zimmermann, B. et al.: Mineral-Ecological Cropping Systems – A New Approach to Improve Ecosystem Services by Farming without Chemical Synthetic Plant Protection. In: Agronomy Bd. 11, Nr. 9, S. 1710, 2021.

## Organic sugar beet (*Beta vulgaris* L.) cultivation using the field robot Uckerbot as a system for sustainable farming

### Development and mode of operation

Leonie Steinherr<sup>1</sup>, Miguel Belo<sup>2</sup>, Rodja Trappe<sup>2</sup>, Dafne Acosta-Ortiz<sup>3</sup>, Amanda Birkmann<sup>1</sup>, Tsvetelina Krachunova<sup>3</sup> and Ralf Bloch<sup>1</sup>

**Abstract:** The field robot Uckerbot is an autonomous mobile robot developed in a co-design process by farmers, industry and researchers for intra-row weed control in organic sugar beets. First on-farm results indicated better performance of the Uckerbot compared with common weed hoeing strategies. The robot showed 90% accuracy of sugar beet detection and 88% weed efficiency with a drill mechanism. Further development of the robot includes enabling it to work in a robot swarm for an increase in efficiency and working speed and enabling the image recognition system to distinguish between different weed types. This will allow the Uckerbot to skip tolerable wild field herbs for increased biodiversity.

**Keywords:** organic sugar beet, artificial intelligence, field robot, agroecology concept

## 1 Introduction

The biggest obstacle to strengthening and spreading organic sugar beet is the lack of advanced technology for hoeing weeds in the row. The costs of manual intra-row weed control are decisive for farmers for the profitability of organic sugar beet farming [AH16]. Inter-row conventional mechanical weeding causes losses of sugar beet plants, as the hoeing tools work “blindly” [Ma21]. However, as the young plants are not competitive, it is necessary to start early with mechanical regulation, as losses can range from 26 to 100 % in the four weeks after sowing [GI22]. The combination of mechanical and chemical methods is often mentioned as the most efficient weed control, as manual weeding requires 70 to 300 working hours per ha [Bh20]. However, organic farming is a strategy based on integrated ecologically and economically sustainable crop production methods, which completely excludes the use of herbicides. Digital technologies such as field robots can support intelligent mechanical weeding without using herbicides [K123].

---

<sup>1</sup> Hochschule für nachhaltige Entwicklung Eberswalde, Schicklerstraße 5, 16225 Eberswalde, leonie.steinherr@hnee.de

<sup>2</sup> Zauberzeug GmbH, Hohenholter Str. 43, 48329 Havixbeck, miguel@zauberzeug.com

<sup>3</sup> Leibniz Zentrum für Agrarlandschaftsforschung (ZALF) e.V., Eberswalder Str. 84, 15374 Müncheberg, Tsvetelina.Krachunova@zalf.de

Existing field robots for use in Germany rely mainly on navigation systems to differentiate between crops and weed plants [Kul18]. So far, they cannot differentiate between tolerable wild field herbs and problem weeds. The development of field robotic technologies has focused mainly on the yield-reducing effect of weeds, not taking ecological aspects of weed presence into account [Bo22; Kl23]. Furthermore, there are currently no field robots adapted to heterogeneous, steep, and stony soils [Br22], which are typical for the Uckermark region in Germany. With increasing demands on agriculture and regarding climate change, field robots are expected to react to plant growth, changing weather conditions and biodiversity issues.

The envisaged regional processing of organic sugar beet by the Consun Beet Company GmbH & Co. (CBC; Anklam, Germany) offers great potential for the development of sustainable and regional value chains in the Uckermark region. To exploit the full potential of a sustainable value chain, organic sugar beet cultivation must be regionally expanded. According to the CBC, an area of about 2.000 ha of regional organic beet (or approximately 100.000 t of organic sugar beet) must be cultivated for the sugar factory to be able to process sugar beets for one week. The most important condition for achieving this goal is to acquire more organic farms to participate. In 2022, only 462 ha of organic sugar beet cultivation were under contract with CBC in Anklam. To address the challenges and fears of farmers concerning the mechanical weeding in organic sugar beet, a new region-based, utilised concept for the development of an AI-based field robot was elaborated. As part of the “WIR Region 4.0” joint project “zUckerrübe” funded by the BMBF, a new cultivation method for organic sugar beet with the aid of a newly developed weeding robot has been jointly tested and developed since 2021 by the Eberswalde University for Sustainable Development, the robotics developer Zauberzeug, the Leibniz Institute for High Performance Microelectronics and the Leibniz Centre for Agricultural Landscape Research (ZALF). The Uckerbot is being adapted to the heterogeneous terrain conditions as well as being trained to differentiate between harmful weeds and tolerable wild field herbs, which is beneficial for biodiversity protection and other agro-ecological indicators. The authors hereby briefly present the whole concept for the first time and the current course of the development and test phase of the Uckerbot for the past two years.

## 2 Methodological Approach

The Uckerbot field robot has been tested in ongoing field trials under challenging soil and weather conditions at the research station at Gut Wilmersdorf (two in 2021, two in 2022, four in 2023). For this purpose, different tools (drill and pendulum hoe developed by Zauberzeug GmbH) were tested and scientifically evaluated regarding their weeding efficiency (reduction of weed coverage level, determined at five dates per trial with a wooden scoring framework (0,2x2m<sup>2</sup>) built according to the example of [Wi04]) against common mechanical regulation strategies such as row finger hoe, Feldklasse hoe, and hand weeding. In 2023, the working speed of the robot was tested, too. The prototype



Uckerbot has been continuously developed in a co-design process between the robotic company Zaubergezeug, regional farmers, processors, and researchers with the aim of including the requirements of the farmers as well as the results and experiences from the field trials into the technical development from the very beginning. Furthermore, the most common 60 weed species in the region are being systematised and assessed regarding their effects on sugar beet and their agro-ecological effects at present [St23]. The development of the Uckerbot is still in its initial test phase and will also be further improved in on-farm trials in the course of 2024. Therefore, no publicly accessible data sets are currently available. No public datasets are used in the project, as the Uckerbot prototype is specifically adapted to the conditions of the Uckermark region and is being developed as a new product for the market.

## 2.1 Hardware setup

The field robot Uckerbot is an autonomous mobile robot developed for mechanical weed control. The current prototype comprises a platform with an installation space of less than one cubic metre. The robot weighs 100 kg and represents half the soil pressure of an adult person. The frame of the whole platform is made of weather-resistant stainless steel, equipped with a 5MP RGB-camera for monitoring of the work area. A rubber tracked undercarriage with four brushless direct current (DC) motors (BLDC motor) with 250 W, where each is used as the drive. Therefore, the robot can reach a total power of 1 kW. The robot is equipped with a LiFePo4 battery with 720 Wh. The Uckerbot operates with different changeable and combinable mechanical tools adapted to weeding in different phases of weed growth – a cutting spiral drill for low-earth work (1 to 5 cm working depth) and a pendulum hoe for faster weeding [St23]. Additionally, the weeding tools can be freely positioned over the working width and adjusted in height. The Uckerbot has an integrated artificial intelligence (AI) chip for edge-computing installed on the platform in form of the Zaubergezeug Robot Brain. The Zaubergezeug Robot Brain is an industrial grade controller with an NVIDIA Jetson (Orin) Nano for the AI computations and a microcontroller for the machine communication and control.

## 2.2 Software setup

The system of Uckerbot is programmed with a code based on open-source frameworks (NiceGUI, RoSys and Lizard) developed by Zaubergezeug, which are implemented on the Zaubergezeug Robot Brain, where all together allow the Uckerbot to be controlled and monitored from a distance through a web interface. Lizard is a domain specific language, used to define the hardware behaviour. Lizard runs on the microcontroller and controls inter alia motors and sensors. The Robot system RoSys is similar to ROS, however it is built on modern web technologies, simpler architecture and focuses on mobile robotics. RoSys controls the automations and creates the commands for the microcontroller. For the robot to be manually controlled or for the automatic sequence to be started by the user, a web-based browser interface is generated with the use of NiceGUI. NiceGUI

offers an accessible and Python-based framework for this, which allows the creation of switches, 3D scenes, graphs, and provides built-in remote access via NiceGUI On Air. On the field, the robot scans every 10 cm on average while driving regularly and autonomously along a sugar beet row. It removes weeds from inside the row using AI in the form of a Convolutional Neural Network (CNN). When weeds are detected, the robot drills the weed as programmed. In a case of sugar beet plant detection, the Uckerbot calculates an offset distance of nearly 1.5 cm from the sugar beet to avoid its damage. To simplify the image annotation process and the training of the AI, the Zauberzeug Learning Loop was used.

The system is directly connected to the Robot Brain, so that images captured by the robot are sent to the cloud application as soon as an internet connection is established. The Learning Loop offers a simple data management and annotation process, which was used to annotate the weed and sugar-beet plants using novel point annotations. The training of the model can be started from the cloud application. After training is completed, the trained CNN model can be uploaded to the Uckerbot. Seven people supervised the manual labelling process of 3.500 images to ensure the accuracy of the identification process.

### 3 Results

As the Uckerbot is an interdisciplinary concept, its structure is based on the criteria of industry, research, and regional farmers. Thus, since ecologically managed farms in the region attach great importance to renewable energies, the Uckerbot is adapted to these requirements by being battery driven. The specially developed hoeing tools for difficult soil conditions and stubborn weeds (spiral drill and pendulum hoe) can ensure flexibility for farmers. The feasibility and efficiency of the tool combination is currently being tested in field trials. As a regional robotics concept, the datasets for the classification of sugar beet and weed plants consist only of training images captured in the research area. If the model is used for a current plant recognition, all captured images are automatically sent back to the Learning Loop, which sorts the images according to the recognition accuracy. This allows the user to use images for annotation where the AI model shows a lower recognition certainty. This process was repeated during the field trials to increase the recognition rate of the AI model. Currently, the accuracy of plant detection of the AI-based Uckerbot system averages 80% for weeds and 90% for sugar beets.

The preliminary trial results showed that the Uckerbot is significantly effective in controlling weeds in the row. In 2022, the Uckerbot achieved an average weeding efficiency of 88 % over the field trials in 2022 with the drill mechanism. Figure 1 compares the weed and sugar beet leaf coverage of Uckerbot to the conventional mechanical finger and Feldklasse hoes, and to no treatment four weeks after the sugar beet plots were hoed. The exemplary results from this trial showed that the spiral drill of the Uckerbot achieved significantly lower weed and higher sugar beet leaf coverage.

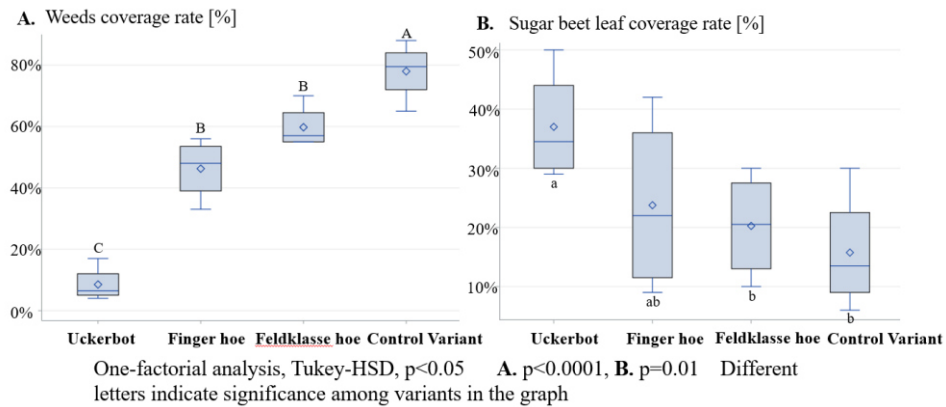


Fig. 1: Weeds coverage and sugar beet leaf and rates [%] four weeks after a hoeing operation compared to a control variant (no treatment) - Exemplary results from field trial II, 2022

The working speed is, however, fairly low with the drill setup, currently averaging 1 linear m in 2 min and 10 sec and the pendulum hoe setup averaging 1 linear m in 39 sec. To increase efficiency and achieve practicality, a further refinement of the image recognition system is necessary, including its ability to distinguish between different weed types. This distinction is crucial for the Uckerbot as it will enable the application of different weeding strategies for different types of weeds (beneficial and harmful) and potentially allow the farmers to increase biodiversity through crop tolerable wild field herbs. For further details of the field trials and weed classification see [St23] and [Bi23].


## 4 Outlook

The Uckerbot is being further developed, including enabling it to work in a robot swarm for an increase in efficiency and working speed. Furthermore, a first commercial derivative of the Uckerbot has been created – the Zauberzeug Feldfreund (Field Friend). This derivative is based on the hardware and software of the Uckerbot and is designed to be used by farmers for various agricultural activities such as weeding, sowing, inspecting, fertilizing, or harvesting by integrating different tools in its protected interior. It is intended to be a flexible helper that can be adapted to specific cultivation requirements. The training data for the Field Friend is continuously expanded and collaboratively improved by the farming community to distinguish different types of field fruits. This collaborative approach ensures that the system is constantly adapting to new challenges. The Field Friend is especially designed for ecological and sustainable fruit and vegetable cultivation, aligning with the global push towards sustainable agricultural practices.

## Bibliography

- [AH16] Abouziena, H.F., Haggag, W.M.: Weed control in Clean Agriculture: A Review. *Planta daninha Viçosa-MG*, 34 (2), p. 377-392, 2016.
- [Bh20] Bhadra, T. et al.: Weed management in sugar beet: A review. *Fundamental and Applied Agriculture*, 5 (2), p. 147-156, 2020.
- [Bi23] Birkmann, A. et al.: Erprobung autonomer Feldrobotik zur Beikrautregulierung für den Bio-Zuckerrübenanbau in der Uckermark. In: V. Bibic; K. Schmidtke: Beiträge zur 16. Wissenschaftstagung Ökologischer Landbau. p. 411-412, 2023.
- [Bo22] Botta, A. et al.: A Review of Robots, Perception, and Tasks in Precision Agriculture. *Applied Mechanics*, 3 (3), p. 830-854, 2022.
- [Br22] Bručienė, I. et al.: Weeding Effectiveness and Changes in Soil Physical Properties Using Inter-Row Hoeing and a Robot. *Agronomy*, 12 (7), 1514, 2022.
- [GI22] Ghaly, A.E., Ibrahim, M.M.: Mechanization of Weed Management in Sugar Beet. In: Misra, V. et al. (eds) *Sugar Beet Cultivation, Management and Processing*, p. 327-367, 2022.
- [KI23] Kliem, L. et al.: Chancen und Risiken der Digitalisierung in der Landwirtschaft aus Sicht des Umwelt- und Naturschutzes. *BfN Schrift 645*. p. 94, 2023.
- [Ku18] Kunz, C. et al.: Camera steered mechanical weed control in sugar beet, maize and soybean. *Precision Agric*, 19, p. 708-720, 2018.
- [Ma21] Machleb, J. et al. Sensor-Based Intrarow Mechanical Weed Control in Sugar Beets with Motorized Finger Weeders. *Agronomy*, 11 (1517), p. 1-17, 2021.
- [St23] Steinherr, L. et al.: Unkrautregulierung im ökologischen Zuckerrübenanbau in der Uckermark In: Kaul, H.-P. et al.: *Digital Tools, Big Data, Modeling and Sensing Methods for Sustainable and Climate Smart Crops and Grassland Systems*. 64. Jahrestagung der Gesellschaft für Pflanzenbauwissenschaften e.V. Göttingen (Mitteilungen der Gesellschaft für Pflanzenbauwissenschaften, 33), p. 131-132, 2023.
- [Wi04] Wilbois, K. et al.: Leitfaden für Praxisversuche. *FibL Deutschland e.V.. BÖL-Bericht-ID 2830*, 2004.

## Verteilung und Zusammensetzung von Abfall in ländlichen Gebieten

Ralph L. Stoop <sup>1</sup>, Markus Sax<sup>1</sup> und Thomas Anken<sup>1</sup>

**Abstract:** Achtlos liegengelassene oder weggeworfene Gegenstände („Littering“) wie Verpackungen, Flaschen, Alu-Dosen usw. stellen nicht nur eine Gefahr für Ökosysteme dar, sondern auch für die Landwirtschaft. Um Littering in der ländlichen Schweiz besser zu verstehen, haben wir mit Drohnen und Smartphones RGB-Farbbilder entlang verschiedener Straßenabschnitte gesammelt. Unsere ersten Analysen deuten darauf hin, dass in Schweizer Landwirtschaftsgebieten die Abfalldichte relativ gering ist, im Bereich von ca. 0,02-0,11 Abfallgegenstände/Straßenmeter (Zigaretten ausgenommen). Außerdem finden wir ein starkes Abfallen der Abfalldichte nach den ersten zwei Metern orthogonal zum Straßenrand. Unsere vorläufigen Resultate, insbesondere die Dichte und räumliche Verteilung der Gegenstände, weisen darauf hin, dass in landwirtschaftlichen Gebieten ein automatisches Aufnehmen vor dem Grünschnitt des Seitenstreifens ausreichend ist.


**Keywords:** Littering, Unrat, Abfalldichte, Abfallverteilung

### 1 Einleitung

Achtlos liegengelassene oder weggeworfene Gegenstände (Unrat, im Folgenden „Littering“ genannt) wie Verpackungen, Flaschen, Alu-Dosen usw. sind vielerorts entlang von Straßenrändern, Banketten und Böschungen anzutreffen [Ba23]. Dort stellen sie nicht nur eine Gefahr für Ökosysteme dar [Sk23], sondern auch für die Landwirtschaft [Sb23]. Immer wieder verletzen sich Nutztiere wie Kühe und Schafe an den spitzen Rückständen von Abfallobjekten, welche den Weg ins Futtermittel finden. Im schlimmsten Fall führt dies sogar zum qualvollen Tod des Tieres. Zusätzlich beeinträchtigt herumliegender Abfall im ländlichen Raum die Wahrnehmung der Natur stark, was sich gerade in touristischen Gebieten ökonomisch niederschlagen kann [Sw12] (siehe z. B. [Ja14] und [Ke17] für entsprechende Abschätzungen für Küstengebiete). Um die negativen Auswirkungen von Littering zu minimieren, wird unsachgemäß entsorgter Abfall in der Regel mit großem zeitlichen und finanziellen Aufwand manuell eingesammelt, da es zurzeit erstaunlicherweise noch keine kombinierten, automatisierten Erkennungs- und Einsammelsysteme gibt.

---

<sup>1</sup> Agroscope, Tänikon 1, 8356 Ettenhausen, Schweiz, ralph.stoop@agroscope.admin.ch,

 <https://orcid.org/0000-0002-5138-8020>, markus.sax@agroscope.admin.ch,  
thomas.anken@agroscope.admin.ch

In diesem Beitrag wollen wir das Phänomen Littering besser verstehen, um aus den gewonnenen Erkenntnissen den konzeptionellen Entwurf eines Einsammelsystems voranzutreiben. Insbesondere wollen wir wissen, welche typischen Abfalldichten im ländlichen Raum der Schweiz anzutreffen sind, und wie die Abfallgegenstände verteilt sind (entlang bzw. orthogonal zum Straßenverlauf). Außerdem wollen wir einen ersten Einblick in die Art des Abfalls (z. B. Getränkedosen, Plastikverpackungen, Papier usw.) erhalten, um besser einschätzen zu können, welche Anforderungen ein zukünftiges Sammelsystem erfüllen sollte.

Wir haben mit Drohnen (unmanned aerial vehicles, UAVs) und Smartphones hochauflösende RGB-Farbbilder entlang verschiedener Straßenabschnitte gesammelt. Nach entsprechendem Annotieren (manuelles Lokalisieren und Klassifizieren der Abfallobjekte in den Bildern) schätzen wir aus den Bildern die örtliche Verteilung und die Zusammensetzung von Littering ab. Zudem dienen die Bilder auch als Datensatz für das Trainieren eines künstlichen neuronalen Netzes in einer laufenden Arbeit.

Erste Analysen weisen darauf hin, dass die Abfalldichte in Schweizer Landwirtschaftsgebieten relativ gering ist: Mit Ausnahme von Zigaretten(stummeln) im Bereich von ca. 0,02-0,11 (Durchschnitt 0,09) Abfallgegenstände pro Straßensegment. Zudem finden wir ein starkes Abfallen der Abfalldichte nach den ersten zwei Metern orthogonal zum Straßenrand, wobei insbesondere scharfkantige Gegenstände wie Getränkedosen gerade häufig im mittleren Bereich (1-2 m) vorkommen. Unsere bisherigen Resultate, insbesondere die geringe Dichte und begrenzte räumliche Verteilung der Gegenstände, deuten darauf hin, dass in landwirtschaftlichen Gebieten ein gezieltes Erkennen und Einsammeln des Abfalls vor dem Schnitt des Seitenstreifens sinnvoll ist.

## 2 Methoden

Aufnahmen von Abfallgegenständen wurden entlang verschiedener Streckenabschnitte der Schweizer Kantone Aargau, St. Gallen, Thurgau und Zürich erstellt. Dabei wurden zum einen Aufnahmen mittels UAVs erstellt, zum anderen direkt beim Entlanglaufen der Straße mittels Smartphone-Kamera.

### 2.1 UAV-basierte Bildaufnahmen

Wir benutzen die Matrice 300 RTK (DJI, Shenzhen, China) UAV mit einer Zenmuse P1 RGB-Kamera (DJI, Shenzhen, China) und dem dazugehörigen 50-mm Objektiv, um hochaufgelöste Bilder von Littering-Situationen zu erheben, wie in Abbildung 1a schematisch dargestellt. Zur Flugplanung benutzen wir DJI Pilot, jedoch wurden einzelne Abschnitte auch manuell geflogen. Die Flughöhe beträgt zwischen 15-20 m und insgesamt wurde eine Gesamtstrecke von ca. 1,6 km, aufgeteilt auf vier Strecken mittels Drohnen untersucht. Insgesamt wurden 172 überlapp-bereinigte Bilder aufgenommen. Da jeweils lineare Flüge entlang der Straße durchgeführt wurden und die Breite des Drohnen-

Footprints ca. 10 m beträgt, konnten somit Daten einer Fläche von ca. 1,6 ha gesammelt werden.




Abb. 1: a. Mittels UAV wird die Abfallverteilung entlang (nicht symbolisiert) und orthogonal zur Straße („orthogonale Distanz“  $d$ ) charakterisiert. b. Dabei wird die Strecke für jeden Gegenstand grob durch das Bild abgeschätzt. c. Resultierende Bilder der Abfallstücke

## 2.2 Aufnahmen per Smartphone

Um weitere Daten zur Abfallverteilung zu erhalten, haben wir zusätzliche Bilder vom Straßenrand per Smartphone gesammelt. Im Vergleich zu Drohnenaufnahmen liegt der Vorteil dieser Methode in der sehr viel einfacheren Ausführung und effizienteren Analyse der Bilder, da sich in jedem Bild mindestens ein Abfallgegenstand befindet und deshalb leicht bestimmt werden kann. Auf einem Streckenabschnitt von 350 m wurden so 33 Bilder aufgenommen. Dies entspricht einer untersuchten Fläche von ca. 0,14 ha.

## 2.3 Bestimmung der Abfallverteilung und Abfallzusammensetzung

Von den insgesamt 205 Bildern wurden bisher 162 annotiert und ausgewertet, was einer Gesamtfläche von ca. 1,2 ha entspricht. Die Distanz vom Abfall-Objekt zum Straßenrand (orthogonaler Abstand  $d$ , Abb. 1a) schätzen wir direkt aus dem Einzelbild. Obwohl die genaue Messung des orthogonalen Abstandes aus den Bildern nur mittels Fotogrammetrie möglich ist, erlauben die bekannten Größen typischer Abfall-Objekte (wie z.B. Getränke-Dose, Zigarettenstummel, etc.) eine grobe Abschätzung des Abstandes aus dem Einzelbild, wie in Abbildung 1b dargestellt. Dabei wird der Skalierungsfaktor durch die bekannte Größe des Objektes abgeschätzt und dann auf die Distanz des Objektes zum Straßenrand angewandt. Zusätzlich wurden einige Kontrollmessungen mit Messband getätigt. Wir sind jedoch prinzipiell nur an einer m-Genauigkeit (Bereich +/- 0.5m) interessiert und begnügen uns deshalb mit relativ groben Schätzungen.

Die resultierende Bildqualität erlaubt in den meisten Fällen eine klare Zuweisung zu den Klassen „Getränkedose, Flasche, Verpackung, Zigarette, Papier/Karton, Übrige“, siehe Abbildung 1c. Eine Ausnahme bilden hier Zigarettenstummel, welche aufgrund ihrer geringen Größe nur auf versiegelten Flächen gut erkennbar und im hohen Gras oft schwierig zu entdecken sind. Unsere gefundenen Werte entsprechen deshalb einer

konservativen Schätzung – die tatsächliche Anzahl von Zigarettenstummel würde wahrscheinlich höher ausfallen.

### 3 Resultate und Diskussion

#### 3.1 Abfallverteilung

Die Abfallverteilung orthogonal zum Straßenrand ist in Abbildung 2a dargestellt. Um den relevanten Bereich abschätzen zu können, benutzen wir einen exponentiellen Abfall  $N(d)$ ,

$$N(d) = N_0 e^{-d/l}$$

wobei  $l$  die charakteristische Distanz des Abfalles darstellt und  $N_0$  die Anzahl der Gegenstände direkt am Straßenrand ( $d = 0$ ). Da unser Datensatz hauptsächlich durch die Anzahl der gefundenen Zigaretten (565 Stück) bestimmt ist, stellen wir die Abfallverteilung mit und ohne Zigaretten getrennt dar. Dies ist auch aus Sicht eines zukünftigen automatischen Einsammelsystems sinnvoll, da dieses die unterschiedlichen Gefahrenpotenziale des Abfalls miteinbeziehen muss. Wir finden, dass die Verteilung des Abfalls mit einem exponentiellen Abfall mit einer charakteristischen Distanz von 0,4 m bzw. 1,3 m (mit Zigaretten, Inset Abb. 2a, bzw. ohne Zigaretten, Abb. 2a) vernünftig beschrieben wird. Unsere Resultate zeigen auf, dass der erste Meter hauptsächlich durch Zigaretten verunreinigt ist, dass aber größere Abfallgegenstände auch weiter von der Straße entfernt (bis ca. 3 m) weiterhin relativ häufig sind, wobei auch deren Dichte exponentiell abfällt.




Abb. 2: a) Verteilung der Abfallgegenstände bezüglich dem orthogonalen Abstand  $d$  vom Straßenrand, b) Abfallzusammensetzung

Entlang der Straße wurden relativ geringe Abfalldichten in den untersuchten Gebieten gefunden, mit Werten von 0,02 bis 0,11 Abfallgegenstände pro Straßenmeter (ohne Zigarettenstummel), wobei der Durchschnitt bei ca. 0,09 lag (d. h. ca. alle 10 Straßenmeter ein Gegenstand). Allerdings gilt hier zu beachten, dass die Aufnahmen typischerweise bei eher stärker verschmutzten Streckenabschnitten gemacht wurden, um genügend Daten für



die orthogonale Verteilung (Abb. 2) sammeln zu können. Die tatsächliche Dichte im ländlichen Raum der Schweiz könnte also sogar noch etwas geringer sein (im Bereich 0,02 Abfallgegenstände pro Straßenmeter). Glücklicherweise scheint Littering im ländlichen Raum (im Gegensatz zum urbanen Raum) in der Schweiz eine relativ schwache Ausprägung zu haben, welche sich auf wenige „Hotspots“ konzentriert, typischerweise Ortsausgang und nach Fastfood/Take-Away-Möglichkeiten. An diesen Stellen sind punktuell durchaus deutlich höhere Dichten zu erwarten, abhängig von dem Wochentag (Wochenende/Veranstaltungen) und der Reinigungshäufigkeit.

Die Verteilung der verschiedenen Abfallarten ist in Abbildung 2b dargestellt, wobei wiederum Zigaretten ausgenommen sind, um den Vergleich einfacher zu gestalten. Wenig erstaunlich sind Überreste verschiedenster Verpackungsarten die am häufigsten angetroffene Abfallart. Diese Klasse enthält mehrheitlich Verpackungen aus Plastik/Kunststoff, kann aber nicht immer klar von der Klasse Papier/Karton unterschieden werden, da Verpackungen häufig aus Zusammensetzungen dieser Materialien bestehen. Bezüglich landwirtschaftlichem Gefahrenpotenzial können wir Getränkedosen aus Aluminium als die am stärksten verbreitete Abfallart identifizieren, mit großem Vorsprung auf (Glas)Flaschen, welche nur sehr selten anzutreffen waren.

Aufgrund der vorläufig beobachteten geringen Dichte stellen wir ein kontinuierliches, streifenweises Aufsaugen des gesamten Grünbereichs in Frage, mit Ausnahme von Hotspots mit sehr starker Verschmutzung in den ersten 1-2 Streifen (bis ca. 1,5 m vom Straßenrand entfernt). Bei geringer Abfalldichte könnte sich ein punktuelles Aufsaugen empfehlen, welches nur verschmutzte Flächen absaugt. Dies wäre über ein vorangebrachtes Erkennungssystem (z. B. eine Kamera mit Edge-Device zur automatischen Erkennung) zu realisieren, welches bei vorhandenem Littering die Saugfunktion des Grünpflegekopfs einschaltet. Dies würde zu einer Schonung von Kleinstlebewesen führen und gleichzeitig das manuelle Aufsammeln von Abfall minimieren. Zudem könnten die Daten des Erkennungsmoduls zur Zustandsanalyse bzw. Qualitätskontrolle verwendet werden.

## 4 Schlussfolgerung

Unsachgemäß entsorgter Abfall stellt aufgrund seines hohen Gefahrenpotenzials für die Landwirtschaft und seines schädlichen Einflusses auf die Umwelt und Landschaftswahrnehmung eine große Herausforderung dar. In urbanen Räumen bilden bereits heute automatische Erkennungssysteme eine wichtige Stütze [Co23], in der ländlichen Schweiz scheinen solche Systeme jedoch noch nicht etabliert zu sein. Ein Grund dafür könnten die relativ niedrigen Abfalldichten entlang der Straße sein im Einklang mit unserem (nicht repräsentativen) Datensatz (Dichte zwischen 0,02-0,11 Gegenstand pro Straßenmeter, d. h. alle 9-50 m ein Abfallobjekt). Nichtsdestotrotz stellt auch diese Art der Verschmutzung ein Problem dar, da in ländlichen Gebieten auch deutlich weniger häufig der Straßenrand gereinigt werden kann. Für die Zukunft schlagen

wir ein automatisiertes Aufnahmeverfahren vor, welches nur punktuell (bei gegebener Verunreinigung) absaugt und damit nur die relevanten Flächen behandelt. Die automatische Erkennung bildet dabei ein wichtiges Element, welches den Luftstrom des Grünpflegekopfs intelligent steuert, und steht im Zentrum zukünftiger Bemühungen. Wir sind überzeugt, dass ein solches intelligentes Verfahren auch Kleinstwesen schont und somit einen Beitrag zur Biodiversität leisten wird.

#### Literaturverzeichnis

- [Ba23] BAFU – Schweizerisches Bundesamt für Umwelt - Littering, <https://www.bafu.admin.ch/bafu/de/home/themen/abfall/fachinformationen/abfallpolitik-und-massnahmen/littering.html>, Stand: 23.10.2023.
- [Co23] Cortexia SA, Take control of your City's Cleanliness, [www.cortexia.ch](http://www.cortexia.ch), Stand: 23.10.2023.
- [Ja14] Jang, Y. C. et al.: Estimation of lost tourism revenue in Geoje Island from the 2011 marine debris pollution event in South Korea, *Marine Pollution Bulletin*, 81, S. 49-54, 2014.
- [Ke17] Krelling, A. P., Williams, A. T. and Turra A.: Differences in perception and reaction of tourist groups to beach marine debris that can influence a loss of tourism revenue in coastal areas, *Marine Policy*, 85, S. 87-99, 2017.
- [Sb23] SBV, schweizerischer Bauernverband, <https://www.sbv-usp.ch/de/littering>, Stand 23.10.2023.
- [Sk23] Sklodowski J.: To litter or not to litter that is the question, or the impact of tourist litter pollution on the macrofauna, *Applied Soil Ecology*, 190, 105022, 2023.
- [Sw12] Swiss Info, Switzerland comes clean on its obsession, [https://www.swissinfo.ch/eng/myth-or-reality-\\_switzerland-comes-clean-on-its-obsession/33472792](https://www.swissinfo.ch/eng/myth-or-reality-_switzerland-comes-clean-on-its-obsession/33472792), Stand: 24.10.2023.

## Teilflächenspezifische Aussaat von Körnermais: Potenziale und Limitationen

### Erkenntnisse aus mehrjährigen Feldversuchen

Beat Vinzent <sup>1</sup>, Franz-Xaver Maidl<sup>1</sup> und Markus Gandorfer<sup>1</sup>

**Abstract:** Auf Basis mehrjähriger Feldversuchsdaten wurden in Parzellenversuchen unter süddeutschen Anbaubedingungen auf Standorten unterschiedlicher Ertragsfähigkeit die Auswirkungen einer Saatstärkenvariation bei Körnermais auf Kornerträge und saatgutkostenfreie Leistung analysiert. Die Variation der Saatstärke auf den Kornertrag war insgesamt nicht sehr ausgeprägt, die Saatgutkosten hingegen unterschieden sich deutlich. In zwei von drei Einzeljahren ergaben sich trotz des breiten ökonomischen Optimums in der ex-post-Betrachtung moderate Vorteile für eine teilflächenspezifische Saat, erstaunlicherweise lag das ökonomische Optimum der Saatstärke auf den getesteten Standort sehr hoch.


**Keywords:** Precision Farming, teilflächenspezifische Aussaat, Variable Rate Control, Körnermais

## 1 Einleitung

Wissenschaftliche wie auch praxisnahe Untersuchungen zum Einfluss einer teilflächenspezifischen Variation von Saatstärken auf die Ertragsleistung und Anbaukosten im Pflanzenbau werden seit langem durchgeführt [RK02]. Bis heute hat die teilflächenspezifische Saat bei den meisten Kulturen keine umfassende Verbreitung in Bayern erfahren [GG22]. Bei Kulturen mit ausschließlich vegetativer Ertragsbildung sowie bei Kulturen mit mehreren Ertragsstrukturparametern ist das Potenzial gering (Kartoffeln, Getreide, Raps), wohingegen Kulturen mit wenigen Ertragsstrukturparametern wie Mais ein gewisses Reaktionspotenzial aufweisen können [HM02; Du22]. Untersuchungen aus den USA zeigen, dass die teilflächenspezifische Saat bei Mais unter speziellen Anbaubedingungen wie Direktsaatverfahren oder großen Bewirtschaftungseinheiten von der Praxis angenommen wird [HRC22].

Wie bei anderen Precision-Farming-Technologien werden von Anwendern immer wieder hohe Investitionskosten als Hemmnis für eine Investition genannt, eine Hürde, die teilweise mit der Verfügbarkeit günstiger bis kostenloser Satelliteninformationen über die teilschlagspezifische Standortgüte überwunden wurde [VMG23]. Moderne Traktoren und

---

<sup>1</sup> Bayerische Landesanstalt für Landwirtschaft, Institut für Landtechnik und Tierhaltung, Kleeberg 14, 94099 Ruhstorf, beat.vinzent@lfl.bayern.de , franz.xaver.maidl@lfl.bayern.de, markus.gandorfer@lfl.bayern.de

Einzelkorndrillen sind außerdem immer öfter hard- wie auch softwareseitig dafür vorgerüstet, georeferenzierte Applikationskarten abzuarbeiten. Folglich ist die Forschungsfrage neu zu beantworten, inwiefern sich nun potenzielle Anwendungsszenarien für die teilflächenspezifische Saat von Körnermais unter der Prämisse ergeben, dass die Informationskosten für die teilflächenspezifische Standortgüte und die Maschinenausstattung in vielen betrieblichen Situationen nur noch eine untergeordnete bis keine Rolle mehr spielen. Die Zielgröße für die ökonomische Bewertung der teilflächenspezifischen Aussaat ist damit im Wesentlichen die saatgutkostenfreie Leistung, welche kostenseitig die Variabilität der Saatgutkosten und auf der Leistungsseite eine eventuelle teilflächenspezifische Reaktion im Kornertrag des Pflanzenbestandes berücksichtigt.

## 2 Material und Methoden

Auf Basis mehrjähriger Feldversuchsdaten in den Untersuchungsjahren 2020 bis 2023 wurden zur Beantwortung der Versuchsfrage Kleinparzellenversuche an einem niederbayerischen Standort mit einer hohen Körnermaisandichte im unteren Rottal durchgeführt. Die Versuche wurden auf verschiedenen Feldern in einem Umkreis von 2 km angelegt. Als Varianten wurde eine fünfstufige Spreizung der Saatstärke zwischen 6 und 14 Körnern pro Quadratmeter in einem lateinischen Rechteck mit 4 Wiederholungen angelegt, wobei ausschließlich die mittleren beiden Reihen einer Parzelle zur Ertragsermittlung herangezogen wurden. Die Körnerreifezahl der verwendeten Sorten bewegten sich im Bereich von K 230-240, alle kulturbegleitenden Anbaumaßnahmen (Bodenbearbeitung, Düngung, Pflanzenschutz) wurden betriebsüblich optimal durchgeführt. Die Maisaussaat fand in allen Versuchsjahren zwischen dem 25. April und dem 5. Mai statt, die Ernte zwischen dem 20. und 30. Oktober. Das Versuchsjahr 2021 war aufgrund eines Hagelschadens nicht auswertbar. Bei der Ernte wurde der Ertrag parzellengenau mithilfe eines Versuchsmähdreschers gewogen. Zur Analyse des Effekts einer teilflächenspezifischen Aussaat wurde die Versuchsanlage stets zweimal im selben Feld angelegt, im Hoch- und im Niedrigertragsbereich. Die so gewonnene Datengrundlage dient der Analyse teilflächenspezifischer Produktionsfunktionen. Als Informationsquelle für die Differenzierung in Hoch- und Niedrigertragsbereich dienten mehrjährige Satellitenaufnahmen des NDVI, die beispielsweise auch für die teilflächenspezifische N-Düngung herangezogen werden [VMG23].

Die Berechnung der saatgutkostenfreien Leistung (SKL) gründet auf mehrjährigen Durchschnittspreisen (2020-2023) des LfL-Deckungsbeitragsrechners [LfL23]. So wurde als Erzeugerpreis ein Körnermaispreis von 24,91 €/dt brutto für trockene Ware angenommen, bei den Kosten wurde eine Einheit Maissaatgut mit 116,93 € inkl. MwSt. bewertet. Dies ergibt eine Spreizung der Saatgutkosten von 140 €/ha bei einer Saatstärke von 6 Körnern pro Quadratmeter und 327 €/ha bei 14 Körnern pro Quadratmeter. Die SKL der einzelnen Parzellen dienten schließlich zur Schätzung teilflächenspezifischer Funktionen der SKL (Polynom 2. Grades; OLS-Regression) wie in Abbildung 2

dargestellt. Auf Basis dieser Funktionen wurde für jede Teilfläche in jedem Jahr die gewinnmaximierende Saatstärke sowie die resultierende SKL berechnet (Abb. 3). Liegt die gewinnmaximierende Saatstärke außerhalb des untersuchten Bereichs, so wurde die niedrigste bzw. höchste getestete Saatstärke angenommen. Bei einheitlicher Aussaat wurde die Saatstärke ermittelt, die für den Gesamtschlag bestehend aus je 50 % Hoch- bzw. Niedrigertrag die SKL maximiert.

### 3 Ergebnisse

Bei der Betrachtung der mehrjährigen Versuchsdaten fällt auf, dass das Ertragspotenzial an den Versuchsstandorten sehr hoch ist. Zudem fallen die Jahrgangseffekte der über alle Saatstärken gemittelten Erträge oft höher als die Unterschiede zwischen Hoch- und Niedrigertragsstandort innerhalb eines Jahres auf (Abb. 1).




Abb. 1: Körnermaiserträge im Hoch- und Niedrigertragsbereich der einzelnen Versuchsjahre

Wie aus der folgenden Abbildung ersichtlich wird, spiegelten sich trotz Abgrenzung von Hoch- und Niedrigertrag auf Basis mehrjähriger satellitendatenbasierter NDVI-Karten diese Unterschiede im Mais in den Versuchsjahren nicht klar wider. Dies mag in der langen Standzeit der Kultur Mais sowie in artspezifischen Faktoren begründet sein: Weiterhin ist festzuhalten, dass die Ertragsvarianz, die sich dann konsequenterweise auch in der Varianz der SKL zeigt, innerhalb der Ertragszonen stark ausgeprägt ist. Zentral ist weiterhin der Befund, dass die Funktionen einen flachen Verlauf aufweisen und damit ein breites Optimum der optimalen Saatstärke anzeigen.

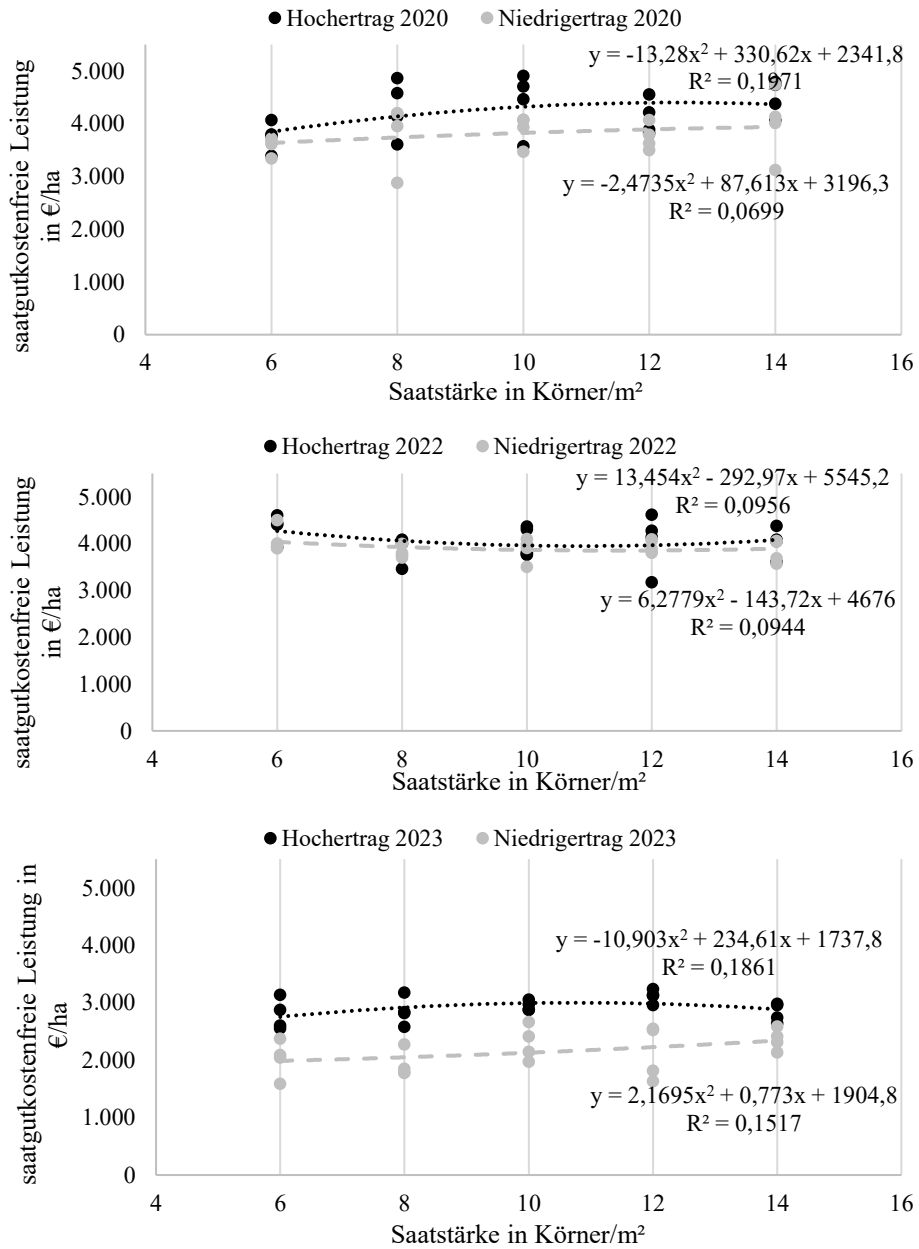


Abb. 2: Funktionen der teilflächenspezifischen saatgutfreien Leistungen in den Versuchsjahren 2020, 2022 und 2023

Die in Abbildung 2 dargestellten teilflächenspezifischen Funktionen der SKL dienen dann als Basis zur Ermittlung der in Tabelle 1 dargestellten ökonomisch optimalen Saatstärken sowie daraus resultierenden SKL. Die Versuchsdaten des Jahres 2022 wurden nicht weiter ausgewertet, da wie bereits erläutert keine Differenzierung der Ertragszonen gelungen ist. Die Analysen zeigen, dass in den Jahren 2020 sowie 2023 in der Hoch- und Niedrigertragszone durch eine teilflächenspezifisch optimierte Saatstärke im Vergleich zu einer einheitlich optimierten Saatstärke eine höhere SKL erzielt werden konnte. Die Effekte sind jedoch moderat. Würde man von einem Modellschlag ausgehen, der je zu 50 % aus Hoch- bzw. Niedrigertrag besteht, so würde sich auf Basis der dargestellten ex-post Analysen ein ökonomisches Potenzial für eine teilflächenspezifische Aussaat von im besten Fall 56 €/ha im Jahr 2023 sowie von 12 €/ha im Jahr 2020 ergeben (Tab. 1).

|             | Hohertrag   |             | Niedrigertrag          |             |
|-------------|---|-------------|------------------------|-------------|
|             | teilflächen-spezifisch                                      | einheitlich | teilflächen-spezifisch | einheitlich |
|             | ökonomisch optimale Saatstärke in Körner/m <sup>2</sup>     |             |                        |             |
| <b>2020</b> | 12,4  | 13,3        | 14,0                   | 13,3        |
| <b>2023</b> | 10,8  | 13,5        | 14,0                   | 13,5        |
|             | saatgutkostenfreie Leistung im ökonomischen Optimum in €/ha |             |                        |             |
| <b>2020</b> | 4.400   | 4.391       | 3.938                  | 3.923       |
| <b>2023</b> | 3.000   | 2.919       | 2.341                  | 2.309       |

Tab. 1: Ökonomisch optimale Saatstärken und resultierende saatgutkostenfreie Leistungen

## 4 Diskussion

Die mehrjährig durchgeführten Kleinparzellenversuche zeigten auf Hoch- und Niedrigertragsteilstandorten variierende Kornertragspotenziale und starke Jahreseffekte, allerdings bestand innerhalb der jeweiligen Teilschläge eine nur sehr geringe Beziehung zwischen Saatstärke und Kornertrag, so dass sich ein relativ breites Optimum für die Saatstärke ergibt. Wie die dargestellten Analysen zeigen, begrenzen breite Optima für die Saatstärken die ökonomischen Potenziale einer teilflächenspezifischen Aussaat. Eine Erklärung dafür liefern vermutlich die Eigenschaften moderner Hybridsorten, die in einem weiten Bereich sehr stabil gegen biotischen und abiotischen Stress sind, d. h. es kommt mit hoher Sicherheit zu einer Kolbenausbildung, solange Wasser nicht der limitierende Faktor ist. Dies erklärt ebenfalls die in mehreren Fällen beobachtete Zunahme der saatgutkostenfreien Leistung in beiden Teilstandorten mit steigender Saatstärke. Nicht vergessen werden darf dabei aber, dass bei höheren Saatstärken über 10 Körnern/m<sup>2</sup> auch

im Mais das Risiko für Lager beispielsweise infolge von Unwettern zunimmt, was sich aufgrund der verglichen mit anderen Kulturpflanzen niedrigen Bestandesdichten stark mindernd auf den Kornertrag sowie das ökonomische Endergebnis auswirken kann. Eine Ursache für die große Elastizität der optimalen Saatstärke kann auch in der Gunstlage des Versuchsstandortes als Kombination von Bodengüte, Wärme und Niederschlag begründet sein. Im Mittel schwächere Standorte mögen eine höhere Ertragssensitivität auf eine variable Saatstärke provozieren, möglicherweise kann es aber durch die angezüchtete Umweltstabilität des Maises auch zu einem noch breiteren Optimum der Saatstärke kommen.




#### Literaturverzeichnis

- [Du22] Du, Z. et al.: Corn variable-rate seeding decision based on gradient boosting decision tree model. *Computers and Electronics in Agriculture* 198 107025. DOI: <https://doi.org/10.1016/j.compag.2022.107025>, 2022.
- [HCR22] Hanson, E.; Cossette, M.; Roberts, D.: The adoption and usage of precision agriculture technologies in North Dakota. *Technology in Society* 71, 102087. DOI: <https://doi.org/10.1016/j.techsoc.2022.102087>, 2022.
- [HM02] Huber, G., F.-X. Maidl: Yield formation and nitrogen uptake of maize on heterogenous growing sites – spectroscopic detection of the nutrition status. *European Society for Agronomy*, 633-635, 2002.
- [GG22] Gabriel, A.; Gandorfer, M.: Adoption of digital technologies in agriculture – an inventory in a European small-scale farming region. *Precision Agriculture*, 1-24. DOI: [10.1007/s11119-022-09931-1](https://doi.org/10.1007/s11119-022-09931-1), 2022.
- [LfL23] Landesanstalt für Landwirtschaft: Deckungsbeiträge und Kalkulationsdaten – Körnermais, <https://www.stmelf.bayern.de/idb/koernermais.html>, abgerufen am 31.10.2023.
- [RK02] Roth, R.; Kühn, J.: Bestandesführung und differenzierte Aussaat. In (KTBL Hrsg.): *Precision Agriculture: Herausforderungen an integrative Forschung, Entwicklung und Anwendung in der Praxis*, Darmstadt 2002. S. 225-236, 2002.
- [VMG23] Vinzent, B.; Maidl, M.; Gandorfer, M.: Analyse ausgewählter digitaler Lösungen zur N-Düngung – Erkenntnisse aus dreijährigen Feldversuchen. Referate der 43. GIL-Jahrestagung in Osnabrück, A. Meyer-Aurich et al. (Hrsg.), S. 525-530, 2023.



## Synthetic fields, real gains

### Enhancing smart agriculture through hybrid datasets

Paul Wachter <sup>1</sup>, Niklas Kruse <sup>2</sup> and Julius Schöning <sup>2</sup>

**Abstract:** Artificial intelligence (AI) promises transformative impacts on society, industry, and agriculture, while being heavily reliant on diverse, quality data. The resource-intensive “data problem” has initialized a shift to synthetic data. One downside of synthetic data is known as the “reality gap”, a lack of realism. Hybrid data, combining synthetic and real data, addresses this. The paper examines terminological inconsistencies and proposes a unified taxonomy for real, synthetic, augmented, and hybrid data. It aims to enhance AI training datasets in smart agriculture, addressing the challenges in the agricultural data landscape. Utilizing hybrid data in AI models offers improved prediction performance and adaptability.

**Keywords:** hybrid data, synthetic data, augmented data, smart farming, reality gap

## 1 Introduction

Artificial intelligence (AI) has been one of the most prominent topics in recent years. It has emerged as an essential technology in agriculture, enabling advancements in crop management [SWT23], soil analysis [Wa23], yield prediction, and identification of plant diseases and weeds, among others. One fundamental aspect of this technology is the importance of the data used to train these systems. Acquiring, creating, preparing, and labeling this data can incur significant costs, known as the “data problem” [Ni21]. For example, data sparsity, i.e., missing data, or class imbalance, i.e., a skewed distribution of data, are resulting problems that are highly common in the agricultural sector [Co22]. One solution to this problem is synthetic data. The IT research firm and consultancy Gartner predicts that in 2030, 60 % of all data used to train AI systems will be synthetically generated [GA23]. While cost-effective, synthetic data lacks realism, termed the “reality gap” [Ni21]. Hybrid data addresses this by combining synthetic and real data by leveraging cheap synthetic data and bridging the gap with a smaller amount

---

<sup>1</sup> Osnabrück University, Institute of Cognitive Science, Neuer Graben 29, 49074,

pwachter@uni-osnabrueck.de,  <https://orcid.org/0000-0002-6224-6140>

<sup>2</sup> Osnabrück University of Applied Sciences, Faculty of Engineering and Computer Science, Albrechtstr. 30,

49076 Osnabrück, niklas.kruse@hs-osnabrueck.de,  <https://orcid.org/0009-0001-7080-6662>;

j.schoening@hs-osnabrueck.de  <https://www.orcid.org/0000-0003-4921-5179>

of real data [Fa19]. However, inconsistent terminology in current literature remains a challenge.

## **2 Existing taxonomy of real, synthetic, augmented, and hybrid**

In the following literature review, the terminology for different data types is inconsistently used, except for “real data”. This section clarifies the definitions of “real data”, “synthetic data”, “augmented data”, and “hybrid data” to address these inconsistencies.

### **2.1 Real data**

The Cambridge Academic Content Dictionary defines data as “information collected for use” [CA08], underscoring the essential aspect of real data obtained from the physical world through observations or measurements. Real data originates from real-world sources, including sensors, devices, and human interactions. Importantly, this definition is consistently used in all literature sources we have examined.

### **2.2 Augmented data and synthetic data**

The fundamental distinction in the definitions of augmented data lies in whether it includes or excludes synthetic data. An example of the first is given by [Ni21], where augmented data is defined as “[...] transformations of the input data that change the target labels in predictable ways”. In contrast, synthetic data, as per [Ni21], is entirely generated manually or by an algorithm, which may include generation through generative AI. Despite the training of these algorithms on real data, their output is considered synthetic, not augmented data. In this context, augmented data consists of transformed real data, while synthetic data comprises entirely generated data.

The second interpretation, where augmented data includes synthetic data, can be found in [GCB23]: “[augmented data is] data that has been altered to include extra information. Synthetic data is data that has been created artificially, using data augmentation techniques”. Here, synthetic data is explicitly categorized as a subset of augmented data.

### **2.3 Partially synthetic and hybrid data**

Partially synthetic and hybrid data refer both to a fusion of real and synthetic data. Again, differing interpretations exist. [EMH20] defines partial synthetic data as a mix of artificially generated and retained parts of real data, resembling traditional de-identification. [EMH20] characterizes hybrid data similarly, blending synthetic and real data, but with the synthetic part based on theoretical understanding, even if actual data is

lacking. Thus, partially synthetic data masks real data, while hybrid data introduces new synthetic elements. In practice, [EMH20]’s definition of partially synthetic data is widely used, particularly in disclosure control for tabular and sensitive data [Jo22; GLR22]. Its application to other data types, like images, is less common, cf. [GZ18].

The prevalent definition of hybrid datasets, per [Ni21], is “using synthetic data to augment existing real datasets”. Unlike [EMH20], [Ni21] specifies that the term hybrid is applicable to datasets, not individual data samples. Lastly, [TO23] uses the term hybrid to describe datasets, but here, hybrid datasets contain only synthetic samples, which are selected based on similarity to samples in a real dataset.

### 3 Consistent taxonomy of real, synthetic, augmented, and hybrid

Ensuring effective knowledge transfer from academia to practical applications in the agricultural sector requires consistent terminology. Therefore, a unified terminology and taxonomy for categorizing data types is proposed in Figure 1.

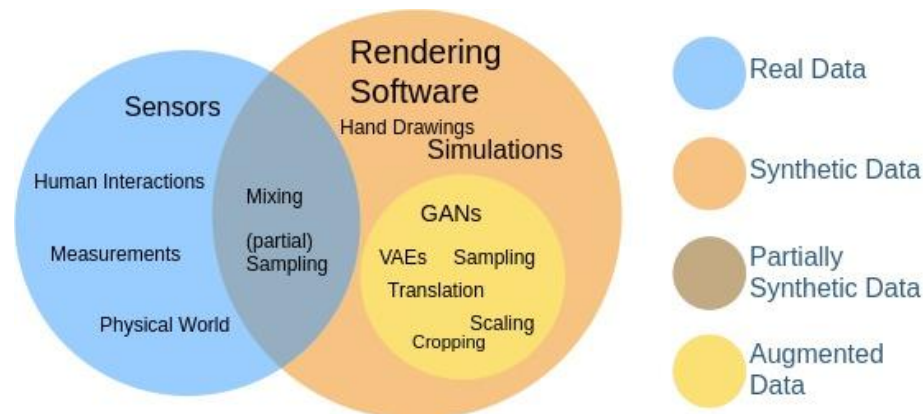


Fig. 1: Taxonomy of real, partially synthetic, synthetic, and augmented data

We define real data as information collected from the physical world, as presented in Section 2.1, while synthetic data is all artificially generated and transformed data. This includes manual processes, mathematical models, algorithms, and simulations. We define augmented data as a subset of synthetic data. Augmented data samples are transformations of real data samples, which can be basic modifications, like cropping and rotation, as well as more complex transformations, such as those achieved through generative AI. This means we define the data samples produced by generative AI as transformations of the data used to train the generative AI, i.e., augmented data. If a dataset contains both real and augmented samples, it is an augmented dataset. We define partially synthetic only for data samples. They possess real and synthetic attributes; one part originates from real sources, while the other is synthetically generated. Lastly, we

define the term hybrid only for datasets, not samples. A hybrid dataset contains both real and synthetic samples; the latter are not augmented data samples. This is a crucial distinction because it would be considered an augmented dataset without this condition. It is important to note that if it meets this criterion, a dataset can still include augmented data samples while being labeled as hybrid data.

## 4 Benefits of hybrid data

The main challenge with synthetic data is the “reality gap” [Ni21], also known as the “domain gap” [Wa19], stemming from differences from real data. This gap causes a significant drop in prediction performance when models trained on synthetic data are deployed in real-world scenarios. Domain adaption techniques try to adapt the synthetic to the real to close this gap. One domain adaption technique is hybrid data, which utilizes cheap and in large quantities available synthetic data while containing real data to bridge the gap to the actual environment. On the one hand, this improves the model’s prediction performance, and on the other, it reduces the need for real data.

### 4.1 Required amount of data and model’s prediction performance

Using hybrid data is particularly valuable in scenarios that suffer from the data sparsity problem, where producing a sufficient volume of real data is impractical. Various publications propose and assess a data ratio of 10 % real data and 90 % synthetic data. This ratio has demonstrated notable significance in enhancing model prediction performance, often outperforming models trained only on multiple times the amount of real data. For instance, in [RHB17], this 10 % real and 90 % synthetic data ratio was utilized for their best-performing model. In [Ge17], using only 10 % of the available real data, combined with 100 % of the synthetic data, yielded higher or comparable detection accuracies than when trained on 100 % of the real data and 0 % of the synthetic data. A similar result is obtained in [Fa19]. In general, as the quantity of real data increases, there is an improvement in model prediction performance. However, even in scenarios where a large amount of real data is available, introducing hybrid data continues to enhance model prediction performance, as demonstrated in [Tr18] and [Fa19]. Lastly, a study conducted by [Wa19] examines the effectiveness of hybrid data in contrast to another domain adaptation method, which was based on a Structural Similarity Index embedding cycle GAN, and shows that the former yielded superior prediction performance.

### 4.2 Use in agriculture

Data sparsity and class imbalance are frequently encountered in agricultural data, cf. [Co22], [SWT23]. Considering the results presented above, the problem of data sparsity

can be mitigated by combining the existing real datasets with synthetic ones. An example of this is given by [WMH18]. Here, a leaf segmentation model was trained on hybrid data, consisting of only 128 real images combined with 10.000 synthetic images. The resulting model outperformed all the state-of-the-art approaches.

Similarly, in [CPN20], a model for plant-weed segmentation trained using real, purely synthetic, and hybrid data was assessed. The number of used samples was 734 real samples, 734 synthetic samples, and 734 synthetic plus 100 real samples. While the model trained only on synthetic samples achieved significantly lower prediction performance compared to the model trained on only real samples, the model trained on the hybrid dataset achieved comparable prediction performance. However, only a tiny amount of the real data was added to the synthetic data. Lastly, [GCK20] showed that a hybrid data approach can be used in scenarios where the data exhibits class imbalance. On the task of strawberry detection, they improved their models F1-scores, which are typically used to quantify the prediction performance in cases of class imbalance, using hybrid data. The model's overall accuracy was neither improved nor harmed, but the model's bias towards one class could be reduced.

## 5 Conclusion

The “data problem” is one of the fundamental problems in deploying AI systems in agriculture. Synthetic data is a promising and cost-effective alternative, but it comes with the problem of the “reality gap”. Hybrid data, a combination of synthetic and real data, has shown to be a promising solution to bridge the reality gap and enhance AI model prediction performance and adaptability. AI models can achieve impressive results by using just a small amount of real data combined with synthetic data, sometimes even outperforming those trained on a greater quantity of real data. In the context of agriculture, where problems like data sparsity or class imbalance are widespread, it is possible to significantly improve the prediction performance of AI models and reduce their biases with the use of hybrid data, making them more adaptable to real-world scenarios. A unified taxonomy of the different data types clarifies their differences and similarities, ensuring their potential is fully realized in agricultural production. As next steps, we will use this taxonomy to create hybrid data sets and research methods for using hybrid data for AI-based agrarian applications.

### Bibliography

- [CA08] Cambridge Academic Dictionary. Cambridge University Press, Cambridge, 2008.
- [Co22] Condran, S. et. al.: Machine Learning in Precision Agriculture: A Survey on Trends, Applications and Evaluations Over Two Decades. IEEE Access, vol. 10, S. 73786-73803, 2022.
- [CPN20] Carbone, C.; Potena, C.; Nardi, D.: Simulation of near Infrared Sensor in Unity for Plantweed Segmentation Classification. In: International Conference on Simulation

- and Modeling Methodologies, Technologies and Applications - Volume 1: SIMULTECH, S.81-90, 2020.
- [EMH20] El Emam, K.; Mosquera, L.; Hoptroff, R.: Practical Synthetic Data Generation. O'Reilly Media, Inc, Sebastopol, 2020.
- [Fa19] Farzan, E.N. et. al.: How much real data do we actually need: Analyzing object detection performance using synthetic and real data. CoRR., 2019.
- [GA23] Gartner, [https://blogs.gartner.com/andrew\\_white/2021/07/24/by-2024-60-of-the-data-used-for-the-development-of-ai-and-analytics-projects-will-be-synthetically-generated/](https://blogs.gartner.com/andrew_white/2021/07/24/by-2024-60-of-the-data-used-for-the-development-of-ai-and-analytics-projects-will-be-synthetically-generated/), Accessed: 15.12.2023.
- [GCB23] Gürsakal, N.; Çelik, S.; Birişçi E.: Synthetic Data for Deep Learning: Generate Synthetic Data for Decision Making and Applications with Python and R. Apress, Berkeley CA, 2023.
- [GCK20] Goondram, S.; Cosgun, A.; Kulić, D.: Strawberry Detection using Mixed Training on Simulated and Real Data. ArXiv, abs/2008.10236, 2020.
- [Ge17] Georgakakis, G. et al.: Synthesizing training data for object detection in indoor scenes. ArXiv, 2017.
- [GLR22] Grund S.; Lüdtke O.; Robitzsch A.: Using synthetic data to improve the reproducibility of statistical results in psychological research. Psychological Methods, 2022.
- [Jo22] Jordan, J. et. al.: Synthetic Data - what, why and how? ArXiv, 2022.
- [Ni21] Nikolenko, S.I.: Synthetic Data for Deep Learning. Springer Cham, 2021.
- [RHB17] Rajpura, P.S.; Hegde. R.S.; Bojinov, H.: Object Detection Using Deep CNNs Trained on Synthetic Images. ArXiv, 2017.
- [SWT23] Schöning, J.; Wachter, P; Trautz, D.: Crop rotation and management tools for every farmer?: The current status on crop rotation and management tools for enabling sustainable agriculture worldwide. Smart Agricultural Technology 3, S. 100086, 2023.
- [TO23] Towards Data Science, <https://towardsdatascience.com/synthetic-data-key-benefits-types-generation-methods-and-challenges-11b0ad304b55>, Accessed: 15.12.2023.
- [Tr18] Tremblay, J. et al.: Training deep networks with synthetic data: Bridging the reality gap by domain randomization. In: Proceedings of the IEEE conference on computer vision and pattern recognition workshops (CVPRW), 2018.
- [Wa19] Q. Wang, et. al.: Learning From Synthetic Data for Crowd Counting in the Wild. In Conference on Computer Vision and Pattern Recognition (CVPR), S. 8190-8199. Long Beach, CA, USA, 2019.
- [Wa23] Wachter, P. et al.: A Smartphone App for Simple Soil Structure Analysis. IEEE International Humanitarian Technology Conference (IHTC) 2022.
- [WMH18] Ward, D.; Moghadam, P.; Hudson, N.: In: Proceedings of the British Machine Vision Conference (BMVC) Workshop on Computer Vision Problems in Plant Phenotyping (CVPPP), 2018.

## Robotic process control for multi-vegetable micro spot-farming using digital twin simulation

Bettina Weber<sup>1</sup>, Sahil Chande<sup>2</sup>, Simon Maike<sup>1</sup>, Maarten Verbunt<sup>1</sup>, Ting Sheng Lee<sup>1</sup>, Rolf Becker<sup>2</sup> and Josef Franko<sup>1</sup>

**Abstract:** Current robotic approaches in smart farming are often limited to a specific task such as weeding or harvesting. Contrary to this, the AgriPV-Bot aims at sustainable and efficient micro spot full vegetable farming by focusing on mixed vegetable cultivation through automated horticultural processes. Such a holistic approach requires sophisticated robotic process control. This paper presents the development of the underlying state machine built in ROS SMACH to handle a variety of tasks within the system. All processes and interactions of sensors and actuators are first simulated on the digital twin software Gazebo before being deployed in the real environment. This allows for rapid iterations of software and reduces dependencies on season and crop availability regarding physical field tests.

**Keywords:** micro spot-farming, process control in agriculture, full farming automation, state machines, digital twin

### 1 Introduction

The objective of ideal agricultural vegetable production comprises sustainable yield maximization while using less intrusive processes and fewer chemicals in order to reduce the negative impact on the environment. However, this target is difficult to achieve in conventional farming where heavy machinery and chemistry usage are dominant. Tractors with varying implements or even specialized stand-alone harvesters are often limited to specific tasks such that they are rarely used throughout the season. Within this framework, digitalization and automation is challenging and leads to an expensive agricultural transformation since each implement, for example, would require its own sensors, or overall new machinery has to be developed such as the large-scale automation system Nexat. This system, however, focuses on crop production in conventional agriculture. A more disruptive approach towards smart farming is the development of smaller robotic systems. Companies like Agriintelli, Pixelfarming or FarmDroid, for example, already provide mobile robots for agricultural processes, but those are usually limited to one task or a small number of tasks, such as harvesting, planting, or weeding. Hence, they cannot be utilized for the entire farming process as reviewed in [WPM23]. In contrast, the AgriPV-Bot is developed as a semi-mobile multipurpose autonomous full vegetable

---

<sup>1</sup> AI.Land GmbH, Siebenhäuser 7, 47906 Kempen, info@a-i.land

<sup>2</sup> Hochschule Rhein-Waal, Friedrich-Heinrich-Allee 25, 47475 Kamp-Lintfort, rolf.becker@hochschule-rhein-waal.de

farming field robot. The idea is to bring the state of the art of indoor automation to an outdoor environment in order to perform full farming with regard to selective and precise cultivation of vegetables.

## 2 AgriPV-Bot Prototype

The semi-mobile platform with its prototype shown in Fig. 1 covers a circular acreage where multiple types of vegetables can be cultivated at the same time. While the current prototype operates with a traverse length of 8 meters, the full system aims at 24 meters. The traverse is rotatably fixed on one end and equipped with a main drive on the other end to execute the rotation.



Fig. 1: Prototype of AgriPV-Bot

Individually controllable carriages can drive along the rails of each side of the traverse. One side is reserved for the planting carriage, whereas the other side is employed by a carriage for cultivation processes, see Fig. 2.






| Planting Carriage   |   | Cultivation Carriage  |   |   |
|---|---|---|---|---|
| <b>Soil Preparation Tool</b>  | <b>Sapling Tool</b>   | <b>Weeding Tool</b>   | <b>Irrigation Tool</b>  | <b>Harvesting Tool</b>  |
|  |  |  |  |  |
| Softens soil at planting spot.  | Leads saplings to planting spot.  | Weed control with electrocution.  | Water injection in root area.   | Gripper for harvesting.   |

Fig. 2: Implements used in AgriPV-Bot

The planting carriage includes two tools, one for soil preparation and the other for positioning saplings. Each tool is mounted on a separate z-axis since both require vertical movement only. In contrast, the cultivation carriage includes a multi-axis robotic arm and a tool-changing system containing an electrical weeding tool, an irrigation tool and a gripper for harvesting. These processes are dependent on the type of crop and need a higher



flexibility in movement. In addition to these end effectors and actuators, numerous sensors are installed in order to gather and provide data for decision making and process control (IoT devices). With respect to data acquisition, the system uses a combination of high resolution RGB cameras and stereo cameras for depth information.

In comparison to smaller mobile platforms, a major advantage is that the farming tools on the carriages can hover over the field along the rails almost independent of the soil, weather, or vegetable conditions. Solar panels above the traverse in combination with battery storage allow for a self-sufficient operating system. In addition, the traverse provides storage for vegetable boxes in between the rails, which can be filled by the robot directly on the field with a variety of vegetables. The system can perform all horticultural processes precisely on the spot and less intrusive than in conventional farming since no heavy machinery is interfering with the utilized agricultural area. All plants are cultivated individually considering their specific needs and monitored closely during their growth stadiums. Throughout the year, precision farming on the spot is thereby fulfilled on an environmentally sound basis.

Within this sophisticated approach of the AgriPV-Bot, this paper focusses on robotic process control of the system. A variety of methods and tools can be applied to design robotic behavior in a way that all components work efficiently as a unit. A finite state machine is the most common approach, while being one of the simplest [Fo14]. Such a finite state machine includes an arbitrary number of states where only one single state can be active at the same time. For the AgriPV-Bot, state machines are developed using the ROS (Robot Operating System) SMACH library to control the robot and provide a high-level control mechanism, see [ROS23] and [BC10]. To quickly improve software development and optimize process control, a model of the cultivated field is designed, and all processes are simulated using the software Gazebo. The goal is to optimize the interaction of different horticultural processes with respect to precision, resource input as well as time and energy consumption. The overall system then purveys a predictive task scheduler that passes the order of tasks along to ROS and an underlying ERP (enterprise resource planning) system which provides the database for monitoring and cultivating each individual plant.

### **3 Robotic Control and State Machines**

As the link between sensors and actuators, the robotic control can be divided into high- and low-level, see Fig. 3. The state machine on the high-level side is developed with ROS SMACH. The task scheduler determines the upcoming task for the system in terms of which task must be handled at roughly which position. At this point, the state machine takes over and reports back to the task scheduler regarding the progress. An overview of the main state machine is given in Fig. 4. All data is stored in an ERP system, respectively the database. This database is evaluated by the task scheduler to determine the upcoming processes, which are forwarded to the system to be handled by the state machine. At the

beginning, the traverse and the required carriage are brought into the position such that the tool can reach the provided spot. Afterwards, the respective task can be executed including a potential tool change on the cultivation carriage.

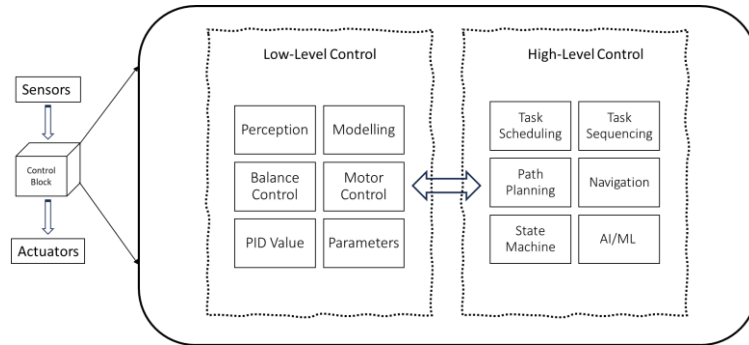


Fig. 3: Low-level and high-level control inside control block

All tasks are monitored by visual sensors, especially with respect to the cultivation carriage where the exact position and orientation of the tools is determined in real-time in ROS, based on this feedback.

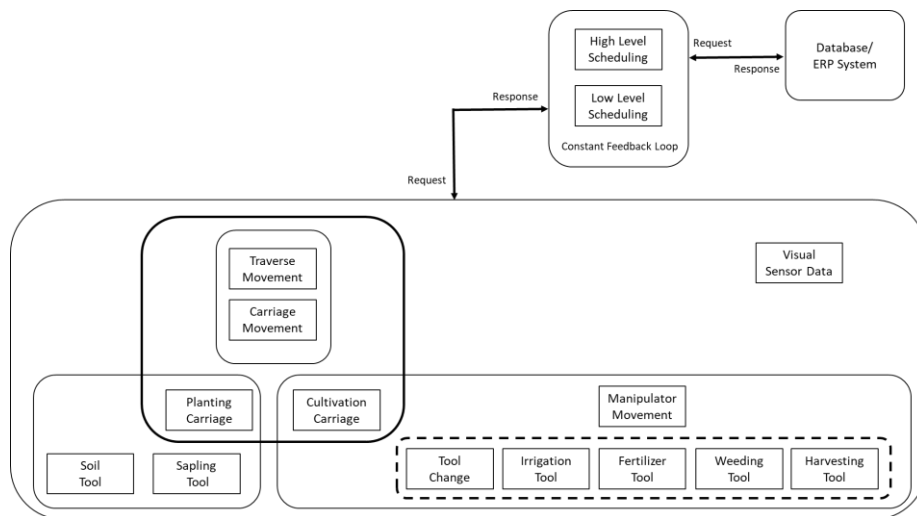


Fig. 4: Main state machine overview

Designing such state machines with multiple states and stages for robotic systems is a complex task. That is why a state machine decomposition methodology is used. This intuitive approach splits the main task into sub tasks and consequently creates multiple state machines which will merge into one at the end. Multiple containers such as iterative containers and concurrence containers are used to minimize the repetitive code within the

state machines. Additionally, the action server wrapper class is taken to monitor the execution of the state machines. The state machines are developed with the aid of a digital twin of the AgriPV-Bot in the simulation environment Gazebo. For that purpose, all dimensions and kinematics of the real system in terms of the traverse, carriages, single-axis actuators, multi-axis robotic arm and tools are created in the model. Additionally, the structure of the real field is scanned and included to obtain a simulation environment as accurate as possible. Adding the information of the operational speed of all actuators to the model and updating the rates of sensors allows for a detailed development and optimization of each sub state-machine. Furthermore, the interaction of the system in terms of ROS with the task scheduler and the underlying ERP system can be investigated extensively before all hardware is fully functional.

## 4 Results

The overall AgriPV-Bot system is at an early stage of development where each process can be executed separately on the real system but requires more automation and integration. Right now, the focus lies on software development, where the simulation and the integration of the task scheduler and the ERP system are being optimized. The system's state machine including all sub state-machines to cultivate and monitor a vegetable from soil preparation to harvesting has been set up and included into the simulation. An exemplary sub state-machine for harvesting and placing the vegetable into a box within the traverse built by ROS SMACH is shown in Fig. 5.




Fig. 5: Exemplary sub state-machine for harvesting vegetables

The simulation environment has been built according to the real prototype on the test field, see Fig. 6. Different cultivation steps can hereby be tested, validated, and optimized. Not

only does the simulation help with the process development itself, but it also helps to identify the design parameters for tools and actuators in general to fulfill their tasks. This enables an economically sensible and time-saving approach to hardware development. Once all processes are available within the simulation, a detailed process analysis will be executed to reveal further optimization potentials.




Fig. 6: Simulation model of AgriPV-Bot

## 5 Conclusion

This paper presents the approach for robotic process control of the micro-spot full vegetable farming AgriPV-Bot. Nested state machines built in ROS SMACH are developed and tested within the simulation environment Gazebo. The system is currently at an early stage of development such that future work will focus on two aspects: on the one hand, the process controls will be deployed on the real system in order to validate the simulation. On the other hand, the state machines will be improved in terms of additional states, error handling and optimization of process time and efficiency.

**Acknowledgements:** We would like to thank Deutsche Bundesstiftung Umwelt (DBU) for their support within the project *AgriPV-Bot Synergetische Kombination von Photovoltaik und Agrarrobotik im Gemüsebau* (38214/01).

### Bibliography

- [BC10] Bohren, J.; Cousins, S: The smach high-level executive [ros news]. IEEE Robotics & Automation Magazine, 17(4), 18-20, 2010.
- [Fo14] Foukarakis, M. et al.: Combining finite state machine and decision-making tools for adaptable robot behavior. In Universal Access in Human-Computer Interaction. Aging and Assistive Environments: 8th International Conference, UAHCI 2014, Proceedings, Part III 8 (pp. 625-635). Springer International Publishing, 2014.
- [ROS23] Robot Operating System State Machine (ROS-SMACH), [wiki.ros.org/smach](http://wiki.ros.org/smach), Stand: 20.10.2023
- [WPM23] Wakchaure, M.; Patle, B. K.; Mahindrakar, A. K.: Application of AI techniques and robotics in agriculture: A review. Artificial Intelligence in the Life Sciences, 100057, 2023.

## Soil moisture simulations for a sustainable irrigation management

Jan Lukas Wenzel <sup>1</sup>, Christopher Conrad<sup>1</sup> and Julia Pöhlitz<sup>1</sup>

**Abstract:** Accurate estimations of crop water requirements accounting for spatial heterogeneous soil properties are recognized as a major contribution towards a sustainable agricultural irrigation management. Crop-specific irrigation demand estimations may be improved by physics-based soil moisture models, although spatially distributed soil moisture simulations strongly rely on profound assessments of the model accuracy and applicability under open-field conditions. Hence, this study aims to investigate simulated root-zone soil moisture dynamics on a variably irrigated potato field provided by the HYDRUS-1D model and its suitability for irrigation management purposes in terms of input parameter requirements and applicability on larger, heterogeneous sites. All simulations were highly accurate ( $RMSE = 0.018 \text{ m}^3 \text{ m}^{-3}$ ), when compared to in-situ measurements, but varied stronger in topsoil than in subsoil layers. A pixel-based approach using aggregated soil properties, phenological characteristics and meteorological conditions enables appropriate trade-offs between simulation accuracy and the parameterization effort and applicability in irrigation management.

**Keywords:** HYDRUS-1D, plant available water, irrigation decision support systems, gun sprinkler irrigation, potato production


### 1 Introduction

Increasing competition for freshwater resources are major concerns for agricultural authorities worldwide. The development of adaptation strategies is indispensable for a sustainable and demand-driven irrigation management [Fa21]. The potato crop (*Solanum Tuberosum* L.), in particular, requires additional water for securing the optimum soil water budgets. Location-specific variances of the crop water demand often lead to a limited accuracy of crop water demand estimations on larger and heterogeneous sites [AS23]. Spatial variances in soil hydraulic properties, in particular, contribute to a reduced crop water productivity [BS17]. Physics-based soil moisture models may increase the accuracy of estimated crop water demands with regard to spatial and temporal variances [YHH19].

The HYDRUS-1D model [ŠGŠ05], for instance, is a well-known tool for simulating soil moisture dynamics within the unsaturated soil profile by using a mechanistic solution of the Richards equation via coupling a multi-layer soil moisture scheme with a single-layer canopy scheme. Several approaches have been suggested for improving agricultural

---

<sup>1</sup> Department of Geocology, Institute of Geosciences and Geography, Martin Luther University Halle-Wittenberg, von-Seckendorff-Platz 4, 06120 Halle (Saale), jan.wenzel@geo.uni-halle.de,

 <https://orcid.org/0000-0002-1389-7289>

irrigation management, or for increasing the simulation and prediction ability of soil moisture dynamics, solute transport and crop growth [Sh18]. An often-proposed approach aims towards the coupling of the HYDRUS-1D model with crop models or empirical hydrological models [Tu21; Wa21], but increases the parameterization requirements and hence the applicability of physics-based models in practical irrigation management.

Moreover, the applicability of the HYDRUS-1D model for spatial distributed crop water balance estimations under open-field conditions strongly depends on (i) profound model accuracy and performance assessments under open-field conditions, and (ii) the availability of spatial and depth-distributed soil hydraulic properties, phenological characteristics, and meteorological conditions [Te20].

Hence, this study aims towards a novel investigation of the accuracy of root-zone (0 cm - 60 cm) soil moisture simulations, provided by the HYDRUS-1D model on a variably irrigated potato field under open-field conditions. The results of this study may serve for future in-depth assessments of the farm level model applicability in terms of data requirements. An innovative, pixel-based approach is discussed for location-specific irrigation demand estimations of the potato crop.

## 2 Material and Methods

A field experiment was conducted under open-field conditions from May to September 2022 on a loamy-sandy ( $814 \text{ g kg}^{-1}$  sand,  $166 \text{ g kg}^{-1}$  silt,  $20 \text{ g kg}^{-1}$  clay) potato field in Mecklenburg-Western Pomerania, Germany (35 ha,  $53^{\circ}56'29'' \text{ N}$ ,  $13^{\circ}14'40'' \text{ E}$ , Fig. 1).

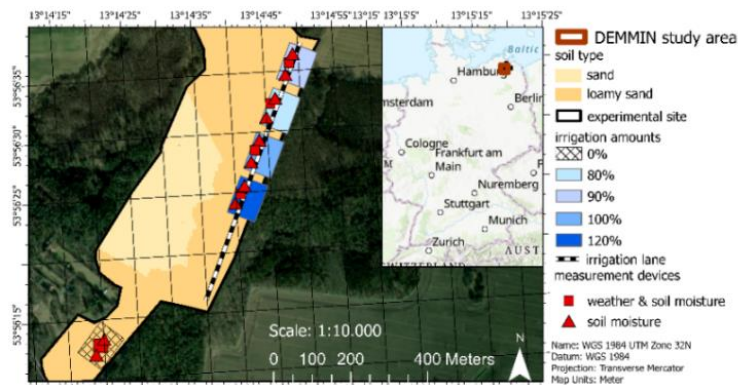


Fig. 1: Study site and experimental design. Four differently irrigated test plots (each 172 m x 72 m) were installed in 2022 on a homogeneous loamy sandy potato site

Four test plots (172 m x 72 m each) were installed within one gun sprinkler irrigation lane. Irrigation was scheduled iteratively each irrigation day by the local farmer. Each test plot was irrigated with one irrigation amount: the common irrigation of the local farmer

(100 %), two deficit irrigation amounts (80 %, 90 %), and one abundant irrigation amount (120 %). The total irrigation amounts were: 121 mm (80 %), 126 mm (90 %), 133 mm (100 %), 152 mm (120 %). Agrometeorological conditions were observed in each test plot using smart weather sensors (Arable Mark 2, Arable Labs, Inc., Princeton, NJ, USA). Root-zone (0 cm - 60 cm, in 10 cm increments) soil moisture was observed in triplicate per test plot using 60 cm Sentek Drill&Drop profile probes. The irrigation system was controlled in-field using 7-min GPS based speed and location data, which were used to derive location specific (4.5 m per point, 10 datasets per soil moisture probe) irrigation amounts. These location specific data enabled the consideration of spatial and temporal variances in the irrigation amounts due to technical properties of the utilized irrigation system and ensured the highest possible accuracy of irrigation amounts for soil moisture simulations under open-field conditions.

The HYDRUS-1D [ŠGŠ05] model was used for simulating daily depth-distributed (0 cm - 60 cm, in 10 cm increments) soil moisture dynamics at each location of a soil moisture probe. The “van Genuchten-Mualem” relationship between soil moisture and pressure head [Ge80; Mu76] was applied for solving the Richards equation. The sink term in the Richards equation accounting for root water uptake was solved using atmospheric boundary conditions accounting for the crop specific evapotranspiration rates based on in-situ measured meteorological conditions. The profile depth was set to 80 cm, discretized into four layers (0 cm - 10 cm, 10 cm - 20 cm, 20 cm - 30 cm, 30 cm - 80 cm), with a freely draining boundary condition (Fig. 2).

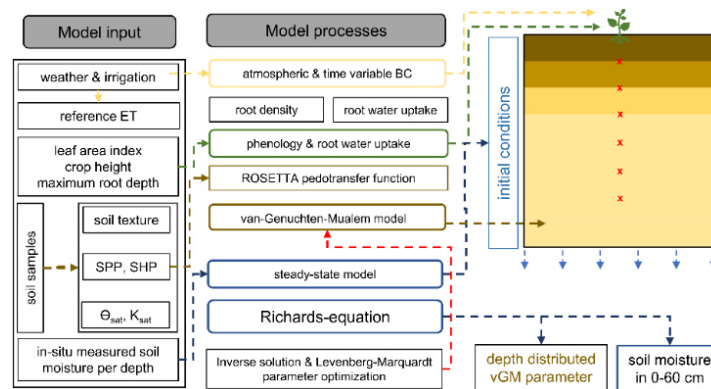


Fig. 2: Flow diagram for depth-distributed (red points) soil moisture simulations

The required van Genuchten-Mualem parameters ( $\alpha$ ,  $n$ , residual water content) were estimated using the integrated ROSETTA pedotransfer function [SLG01], based on laboratory determined water content at saturation and at permanent wilting point and soil textural classes. The maximum rooting depth of the potato crop was set to 60 cm, and root water uptake was assumed to decrease with water stress [FKZ78]. All simulations were calibrated using an inverse parameter optimization-based model solution and validated via

in-situ measured soil moisture dynamics using the root mean square error (RMSE), the mean absolute error (MAE), and the coefficient of determination ( $R^2$ ).

### 3 Results and Discussion

Simulated soil moisture dynamics were in good agreement with in-situ measurements (RMSE =  $0.018 \text{ m}^3 \text{ m}^{-3}$ , MAE =  $0.014 \text{ m}^3 \text{ m}^{-3}$ ,  $R^2 = 0.645$ , for all irrigation amounts, Tab. 1). Significant differences in the accuracy between different soil depths were found for the RMSE ( $p = 0.003$ ) between 20 cm depth and all other depths and for the MAE ( $p < 0.001$ ) between 10 cm, 20 cm and 60 cm, and all other depths. The  $R^2$  was significantly ( $p < 0.001$ ) highest in 60 cm depth and lowest in 30 cm depth. The model accuracy may further be increased by controlled experimental conditions, which, however, contradict to model assessments under open-field conditions. These open-field conditions are of particular importance for deriving adaptation strategies in agricultural practice [Li16]. In this study, the use of in-situ derived irrigation amounts ensured the highest possible accuracy of simulated soil moisture dynamics with varying irrigation amounts.

| soil depth | RMSE ( $\text{m}^3 \text{ m}^{-3}$ ) | MAE ( $\text{m}^3 \text{ m}^{-3}$ ) | $R^2$ (-) |
|------------|--------------------------------------|-------------------------------------|-----------|
| 10         | 0.019 a                              | 0.014 b                             | 0.618 ab  |
| 20         | 0.014 b                              | 0.012 b                             | 0.640 b   |
| 30         | 0.020 a                              | 0.018 a                             | 0.581 a   |
| 40         | 0.020 a                              | 0.018 a                             | 0.631 b   |
| 50         | 0.018 a                              | 0.017 a                             | 0.661 b   |
| 60         | 0.016 ab                             | 0.015 b                             | 0.741 c   |

Tab. 1: Model performance metrics (Root mean square error, RMSE ( $\text{m}^3 \text{ m}^{-3}$ ), mean absolute error, MAE ( $\text{m}^3 \text{ m}^{-3}$ ), and coefficient of determination,  $R^2$ ). Lower-case letters indicate statistically significant differences metrics between different soil depths

Less accurate results in the topsoil (0 cm - 30 cm) may be due to the effects of evapotranspiration, precipitation and irrigation and due to a temporally and spatially erratic root water uptake of potato crops during early growth stages [Qi14]. Potato ridging may have altered the soil hydraulic properties and the two-dimensional features of water flow dynamics in a potato ridge [St08], indicated by significantly less accurate simulations in 30 cm and 40 cm depth. The effects of wetting front dynamics were accurately simulated. The average deviations between in-situ measured and simulated soil moisture content after an irrigation event were  $-0.026 \text{ m}^3 \text{ m}^{-3}$ ,  $0.008 \text{ m}^3 \text{ m}^{-3}$ ,  $-0.004 \text{ m}^3 \text{ m}^{-3}$ ,  $-0.016 \text{ m}^3 \text{ m}^{-3}$ ,  $-0.022 \text{ m}^3 \text{ m}^{-3}$ , and  $-0.013 \text{ m}^3 \text{ m}^{-3}$ , for each depth (0 cm - 60 cm) separately.

The HYDRUS-1D model is generally considered to provide an increased accuracy of simulated crop water demands, when compared to evapotranspiration-based models [Gu20]. It is hence often recommended for irrigation management purposes, despite its increased parameterization requirements [La23]. A more straightforward parameterization, contrarily, usually prevents accurate and spatially distributed crop water



demand estimations, especially under open-field conditions [LL18]. Trade-offs between the required accuracy of crop water demand estimations for a sustainable irrigation management and the increased parameterization effort of physics-based models are indispensable for the practical applicability of physics-based soil moisture models. Novel approaches are required for an automatic integration of spatially distributed soil hydraulic properties, atmospheric boundary conditions, and phenological characteristics [YHH19].

## 4 Conclusions and Perspectives

In this study, depth-distributed soil moisture simulations were conducted on variably irrigated potato field using the HYDRUS-1D model. The accuracy of simulated soil moisture dynamics in comparison with in-situ measurements indicated a high suitability of the HYDRUS-1D model for improving crop water demand estimations in practical irrigation management. Such accuracy assessments at varying irrigation amounts and under open-field conditions are of particular importance for assessing the implementation of physics-based models (e.g., HYDRUS-1D) into easy-to-adopt irrigation decision support systems. The necessity of depth-distributed soil hydraulic properties and van Genuchten-Mualem parameters in physics-based models is a major limitation for spatial distributed estimations of root-zone soil moisture. Despite novel technologies (e.g., remote sensing data) and open-data repositories, these data requirements often inhibit a simple application of comprehensive modeling approaches in agricultural practice.

Forthcoming, an innovative pixel-based application of the HYDRUS-1D model is implemented for a spatially distributed farm-level crop water demand estimation. Specific intra-site specific areas with homogeneous soil conditions derived from validated soil base maps are used for the delineation of irrigation management zones. Spatially distributed agrometeorological conditions are implemented by freely available data repositories by the German Meteorological Service. Crop-specific root water uptake-rates are simulated via the integration of remotely sensed phenological characteristics. All simulations are applied on a spatial resolution of 50 m x 50 m, accounting for trade-offs between the required accuracy of simulated soil moisture dynamics, the parameterization effort and the accuracy of water application using gun sprinkler irrigation systems under open-field conditions. These approaches may serve as potential measures for improving agricultural irrigation management towards a demand-driven water supply and for implementing distributed soil moisture simulations into easy-to-use irrigation decision support systems.

### Bibliography

- [AS23] Ahmad, U.; Sharma, L.: A review of Best Management Practices for potato crop using Precision Agricultural Technologies. *Smart Agricultural Technology* 4, 100220, 2023.
- [BS17] Bastiaanssen, W. G. M.; Steduto, P.: The water productivity score (WPS) at global and regional level: Methodology and first results from remote sensing measurements of wheat rice and maize. *Science of the Total Environment* 575, S. 595–611, 2017.

- [Fa21] FAO: The State of Food Security and Nutrition in the World 2021. Rome, 2021.
- [FKZ78] Feddes, R. A.; Kowalik, P. J.; Zaradny, H.: Simulation of Field Water Use and Crop Yield. John Wiley & Sons INC., 1978.
- [Ge80] van Genuchten, M. T.: A Closed-form Equation for Predicting the Hydraulic Conductivity of Unsaturated Soils. *Soil Science Society of America Journal* 44/5, S. 892–898, 1980.
- [Gu20] Gu, Z. et al.: Irrigation Scheduling Approaches and Applications: A Review. *Journal of Irrigation and Drainage Engineering* 146/6, 04020007, 2020.
- [La23] Lazarovitch, N. et al.: Chapter Two - Modeling of irrigation and related processes with HYDRUS. In (Sparks, D. L., Hrsg.): *Advances in Agronomy* 181, S. 79–181, 2023.
- [Li16] Li, X. et al.: Irrigation water productivity is more influenced by agronomic practice factors than by climatic factors in Hexi Corridor, Northwest China. *Scientific Reports* 6, 37971, 2016.
- [LL18] Lundström, C.; Lindblom, J.: Considering farmers' situated knowledge of using agricultural decision support systems (AgriDSS) to Foster farming practices: The case of CropSAT. *Agricultural Systems* 159, S. 9–20, 2018.
- [Mu76] Mualem, Y.: A new model for predicting the hydraulic conductivity of unsaturated porous media. *Water Resources Research* 12/3, S. 513–522, 1976.
- [Qi14] Qin, S. et al.: Effect of ridge-furrow and plastic-mulching planting patterns on yield formation and water movement of potato in a semi-arid area. *Agricultural Water Management*, 131, S. 87-94, 2014.
- [Sh18] Shelia, V. et al.: Coupling DSSAT and HYDRUS-1D for simulations of soil water dynamics in the soil-plant-atmosphere system. *Journal of Hydrology and Hydromechanics* 66/2, S. 232–245, 2018.
- [ŠGS05] Šimůnek, J.; van Genuchten, M.T.; Šejna, M.: The HYDRUS-1D Software package for simulating the one-dimensional movement of water, heat, and multiple solutes in variably-saturated media. Univ. of Cal. Research Reports, Riverside, CA, USA, 2005.
- [St08] Starr, G. C. et al.: Soil water in relation to irrigation, water uptake and potato yield in a humid climate. *Agricultural Water Management* 95/3, S. 292–300, 2008.
- [Te20] Tenreiro, T. R. et al.: Water modelling approaches and opportunities to simulate spatial water variations at crop field level. *Agricultural Water Management* 240, 106254, 2020.
- [Tu21] Tu, A. et al.: Water budget components estimation for a mature citrus orchard of southern China based on HYDRUS-1D model. *Agricultural Water Management* 243, 106426, 2021.
- [Wa21] Wang, X. et al.: Projection of the climate change effects on soil water dynamics of summer maize grown in water repellent soils using APSIM and HYDRUS-1D models. *Computers and Electronics in Agriculture* 185, 106142, 2021.
- [YHH19] Yost, J. L.; Huang, J.; Hartemink, A. E.: Spatial-temporal analysis of soil water storage and deep drainage under irrigated potatoes in the Central Sands of Wisconsin, USA. *Agricultural Water Management* 217, S. 226–235, 2019.

# Model for the calculation of soil compaction on agricultural land

Clemens Westerkamp<sup>1</sup>, Christian Thünemann<sup>1</sup> and Marco Schaarschmidt<sup>1</sup>

**Abstract:** The risk of soil compaction is a growing concern in agriculture as machinery becomes larger and larger. In this paper, a model is presented that generates a spatial estimation of the soil compaction based on soil survey mapping, soil moisture data and machinery data. The Soil Compaction Index describes the risk of harmful compaction of soil. Feasibility and deployment as an Agri-Gaia service were evaluated by an application for researchers and practitioners to predict areas with high soil compaction risk and adapt agricultural processes accordingly.

**Keywords:** soil compaction, soil simulation models, precision farming, field sensors

## 1 Introduction

The increasing size and mass of agricultural machinery leads to soil compaction and impairs the natural functions of the soil such as the intrinsic stability. Results are negative effects on plant growth and increased flooding risk. To avoid soil compaction, recommendations for machine operation are needed and provided as an example service of the Agri-Gaia platform project [Ag23]. A soil compaction model for calculating the risk of harmful compaction is developed and can be used for different field types. It integrates data sources including soil properties, weather, and machine data. Reference data e.g. from field sensors or penetrometer tests can be used for correction.

The Soil Compaction Index (SCI) describes the relationship between the intrinsic stability of the soil and the load caused by agricultural machines. It is calculated for a given field and real experiments are used to demonstrate the applicability.

## 2 Related Work

### 2.1 State of the art

Decision-making tools for assessing soil trafficability can be found in [VDI 6101], which defines trafficability under a certain tyre pressure, but ignores site-specific soil differences.

---

<sup>1</sup> University of Applied Sciences Osnabrück, Institute of Computer Engineering, Albrechtstr. 30, 49076 Osnabrück, c.westerkamp@hs-osnabrueck.de

To quantify the soil stress, the soil load is used as contact surface pressure of the agricultural machine leading to soil compaction and shear deformation of the topsoil [Am18]. Preload is one parameter for determining the soil stability of agricultural land [Le10]. It is defined as the ground's internal stability against compression and resists the pressure exerted by a vehicle wheel affecting the stability of the subsoil below the topsoil.

The measurement of penetration resistance using a manual vertical penetrometer allows the indirect determination of soil strength over depth. It delivers useful results as reference data for soil compaction models. In addition, field sensors can be used.

## 2.2 Parameters and models from soil science

The soil type is divided based on the size distribution of soil grains. The pedological mapping guide (KA5) and the United States Department of Agriculture (USDA) distinguishes between 21 soil types based on the proportions of sand, clay, and silt [Am18; Un87]. Soil structure describes the arrangement of soil components in space, including the cavity system, which affects the soil water and air budget [MBE21].

Several parameters are used in soil compaction models: dead water (TW) is water bound in the soil and unavailable to plants. It affects inherent stability [Ge11]. Volumetric field capacity (FC) represents the amount of water remaining after two days. It can be used to determine other parameters such as soil water supply and air capacity [We09]. Volumetric air capacity (LK) describes the relative proportion of air in the soil at field capacity [Sc09]. Usable field capacity (nFK) is the difference between field capacity and dead water content of the soil, representing the amount of water available to plants.

The German Federal Institute for Geosciences and Natural Resources provides a soil overview map 1:200,000 (BÜK), which provides recorded soil information in a database [Bu21]. For a given location soil type according to KA5, soil structure, humus content, and storage density are delivered.

The inherent stability of the soil according to [VDI 6101] is influenced by the soil type, aggregate stability, humus content, storage density, structural shape, pore size distribution, lime content, and water content [WB16]. [Le10] describes the calculation of inherent stability of the soil as a function of the soil type present. Regression approaches for individual soil types are selected to estimate the inherent stability at field capacity  $\sigma_{FK}$ .

The influence of soil moisture on soil pre-compaction is considered according to [Rü12]. In general, the logarithm of soil inherent stability  $\log_{\sigma_p}$  is the sum of the logarithm of inherent stability at field capacity  $\log_{\sigma_{FK}}$  and soil moisture  $\Delta \log_{\sigma_w}$ . In detail, constants  $a$  through  $e$  are used to describe soil type, while volumetric soil moisture  $w$  is described as a fraction of volumetric field capacity  $FK$ .

$$\Delta \log_{\sigma_w} = a + b \cdot \log_{\sigma_{FK}} + c \cdot \frac{w}{FK} + d \cdot \left(\frac{w}{FK}\right)^2 + e \cdot \log_{\sigma_{FK}} \cdot \frac{w}{FK} \quad (1)$$

In [Ko92] it is assumed that the contact area is flat, horizontal, and circular and loaded with the uniformly distributed normal stress  $q$ . The product of the normal stress  $q$  and the area are equal to the vertical load of the soil exerted by the tire  $\sigma_z$  as described in (3).

$$\sigma_z = 100 \cdot q \cdot \left( 1 - \cos^v \left( \arctan \left( \frac{1}{z} \cdot \left( \frac{P}{\pi q} \right)^{\frac{1}{2}} \right) \right) \right) \quad (2)$$

For the calculation, the concentration factor  $v$  and the depth  $z$  in cm are needed. As an extension of this formula, if the depth is 0 cm,  $\sigma_z = q$ , as a rule of thumb  $q = 2p_i$  with  $p_i$  = internal tire pressure in bar, and  $v = 4$  as the given concentration factor. The parameter  $P$  stands for the wheel load of the agricultural machine in kg [Ko92]. One possibility to evaluate soil compaction is the soil compaction index according to Rücknagel [Rü15].

$$SCI = \log_{\sigma_z} - \log_{\sigma_p} \quad (3)$$

The soil compaction index  $SCI$  is calculated by the difference of the soil loading  $\log_{\sigma_z}$  and the soil inherent stability  $\log_{\sigma_p}$ . Since soil compaction only occurs when the soil load exceeds the inherent stability of the soil, all  $SCI < 0$  are set to the value 0. For the soil compaction risk classification, the  $SCI$  is divided into five classes. These range from low to very high [Rü21].

### 2.3 Terranimo soil compaction model

Terranimo offers a web-based service to estimate the soil compaction risk. It compares the inherent stability of the soil with the load from an agricultural machine [St14]. Terranimo uses four individual models and requires manual input of soil type and soil moisture.

### 2.4 Weather services from the DWD

The German Weather Service (DWD) provides an open data platform for climate data with the Climate Data Center (CDC). There are about 480 stations distributed over Germany, each of which calculates a value for soil moisture [De20]. The values from the CDC have a lower temporal and spatial resolution than field sensor microclimate data.

## 3 The Agri-Gaia Soil Compaction Model

The structure of the model for calculating soil compaction consists of the models and input parameters of soil science described in the previous section. These are combined into an overall model that outputs the  $SCI$  as an indicator for determining soil compaction.

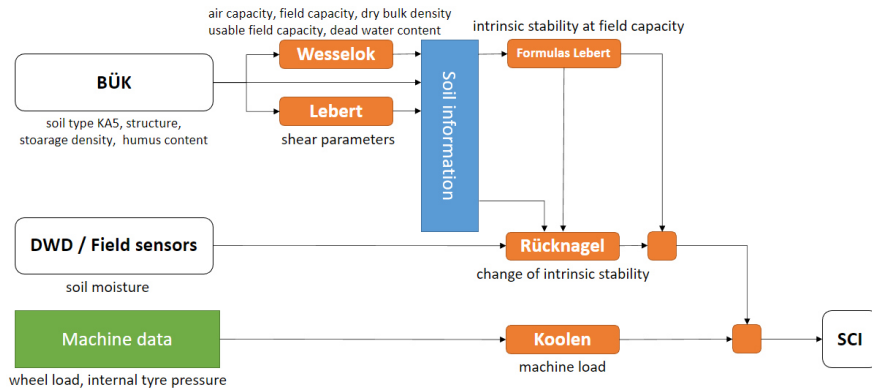


Fig. 1: Data Flow and calculations in the Agri-Gaia Soil Compaction Model

Fig. 1 shows the model for calculating soil compaction. For a given geographic position, data on soil parameters are obtained from the BÜK. Soil water balance and the shear parameters are determined according to [We09] and [Le10] and used in the calculation of the inherent stability at field capacity. The soil moisture from DWD data or field sensors (or both) is used to calculate the inherent stability. This and the inherent stability at field capacity are combined to obtain  $\log_{\sigma_p}$  as described in section 2.2.

The load of the agricultural machine is calculated by the parameters of wheel load and tire inflation pressure. The depth is related to the specified moisture values. The concentration factor is assumed to be 4 but can also be calculated as described in [Rü21]. As a result, the load of the machine and the inherent stability of the soil are combined into the SCI.

## 4 Implementation and Experiment

### 4.1 Model implementation

The described model was implemented as a Python application with a web client. The agricultural area can be selected by importing field boundaries. The soil moisture data of the nearest station of the DWD are obtained via CDC. Machine parameters such as wheel load and tire pressure are entered manually or can come from a machine data base. Field sensor and penetrometer data can be imported as reference values, if available. The ground load is calculated at 30 cm, 60 cm or 90 cm and presented as SCI risk distribution maps.

### 4.2 Comparison of Agri-Gaia Soil Model and field sensor data

In a series of experiments at the Agro-Northwest experimental field in Bohmte, near Osnabrueck, the microclimate was determined for a test field. 41 field sensors recorded

data on air humidity and temperature at 30, 60, 90 cm. This real soil data was used as GroundTruth to adapt and improve the initial soil compaction model.

### 4.3 Application of the Agri-Gaia Soil Compaction model

Agri-Gaia is providing AI based farming services for deployment on a web server or a computer at a farmer's or contractor's site to assess the risk of soil compaction with given weather and machine data. To improve accuracy, field and penetrometer data can be used.

## 5 Discussion

Some aspects of the model are subject to further research. Using BÜK250 as a data source for soil data is spatially limited due to its low resolution. In heterogeneous environments additional reference values from fields sensors, machine data penetrometer measurements improve the model quality. Deviations in tyre type or profile will be integrated in the next version. All described aspects will be evaluated in the next vegetation cycle.

## 6 Conclusion

The Agri-Gaia soil compaction model was adapted by data from field sensors and gives reliable values for different surfaces. Further experiments at different locations as well as the comparison with penetrometer results are planned at the next vegetation cycle.

**Acknowledgements:** This work was carried out within the framework of the research project Agri-Gaia, which is funded by the German Federal Ministry for Economic Affairs and Climate Action (BMWK). We gratefully acknowledge support by other Agri-Gaia scientists as well as practitioners at Gut Arenshorst, Bohmte, Germany, where the field tests were carried out.

### Bibliography

- [Ag23] Agri-Gaia, An economic-agricultural AI-Ecosystem Agricultural and Food Domain. <https://www.agri-gaia.de/>, Funded by the German Federal Ministry for Economic Affairs and Climate Action (BMWK), 2023.
- [Am18] Amelung, W. et al.: Lehrbuch der Bodenkunde. Springer, Berlin, 2018.
- [Bu21] Bundesanstalt für Geowissenschaften und Rohstoffe, Bodenübersichtskarte 1:200.000, 2018.
- [De20] Deutscher Wetterdienst (DWD) CDC- OpenData, [https://opendata.dwd.de/climate\\_environment/](https://opendata.dwd.de/climate_environment/), Stand: 12.10.2023.

- [Ge11] Geischeder, R.: Bodenbelastung und Bodenbeanspruchung unterschiedlicher Fahrwerkskonfigurationen. Dissertation, München, 2011.
- [Ko92] Koolen, A. J. et al.: Prediction of aspects of soil-wheel systems. *Soil and Tillage Research*, 24, S. 381–396, 1992.
- [Le10] Lebert, M.: Entwicklung eines Prüfkonzeptes zur Erfassung der tatsächlichen Verdichtungsgefährdung landwirtschaftlich genutzter Böden, 2010.
- [MBE21] Martin, C.; Bürkle, D.; Eiblmaier, M.: Bodengefüge. *Lexikon der Geographie*, Spektrum Akademischer Verlag, Heidelberg, 2021.
- [Rü12] Rücknagel, J. et al. A simple model to estimate change in precompression stress as a function of water content on the basis of precompression stress at field capacity. In *Geoderma*, 2012, 177-178; S. 1–7.
- [Rü15] Rücknagel, J. et al.: Indicator-based assessment of the soil compaction risk at arable sites using the model REPRO. *Ecological Indicators*, 52; S. 341–352, 2015.
- [Rü21] Rücknagel, J. Methodological aspects and algorithms for estimating soil strength and their applications with the model REPRO. *Habilitationsschrift*, Halle (Saale), 2021.
- [Sc09] Schreiber, M.: Auftretende Kräfte und physikalisch-mechanische Auswirkungen bei Kontakt zwischen Fahrwerken/Reifen landwirtschaftlicher Maschinen und ausgewählten Ackerflächen-Bodengefügen. *Cuvillier*, Göttingen, 2009.
- [St14] Stettler, M. et al.: Terranimo® – ein webbasiertes Modell zur Abschätzung des Bodenverdichtungsrisikos. 132–138 Seiten / *LANDTECHNIK*, Bd. 69 Nr. 3 (2014), 2014.
- [Un87] United States Department of Agriculture: Soil Mechanics Level I. Module 3 – USDA Textural Soil Classification. *Study Guide*, 1987.
- [VDI 6101] VDI 6101:07.2014, Maschineneinsatz unter Berücksichtigung der Befahrbarkeit landwirtschaftlich genutzter Böden, 2014.
- [WB16] Weyer, T.; Boeddinghaus, R.: Bodenverdichtungen vermeiden. *Bodenfruchtbarkeit erhalten und wiederherstellen*, 2016.
- [We09] Wessolek, G. et al.: *Bodenökologie und Bodengenese*. Berlin, 2009.



## Mapping invasive Lupine on grasslands using UAV images and deep learning

Jayan Wijesingha <sup>1</sup>, Damian Schulze-Brüninghoff and Michael Wachendorf


**Abstract:** Semi-natural grasslands are threatened by invasive species. This study employs high-resolution images captured by an unmanned aerial vehicle (UAV) and deep learning techniques to map Lupine (*Lupinus polyphyllus* Lindl.) in grasslands, which is one of the most common invasive species in European grasslands. The methodology involves RGB image acquisition, structure from motion processing, canopy height modelling, and deep learning semantic segmentation model development. The resulting models were trained on RGB data, canopy surface height data, and their combination. The models demonstrate high accuracy and efficacy in identifying Lupine distribution. These models offer a valuable tool for continuously monitoring and managing invasive Lupine, with potential applications in similar environments without retraining. The method is beneficial for early-stage invasion detection, facilitating more targeted management efforts for ecologists.

**Keywords:** invasive species, grassland, deep learning, segmentation, UAV images

### 1 Introduction

Semi-natural grasslands are complex, heterogeneous ecosystems comprising a rich mosaic of native plant species. They play a vital role in maintaining ecological stability and sustaining many ecosystem services [Gi09]. Moreover, these grasslands serve as biodiversity hotspots, contributing to soil fertility, carbon sequestration, and nutrient cycling, and they offer a valuable reservoir of genetic resources for native flora and fauna. Nevertheless, semi-natural grasslands are at risk due to various naturogenic and anthropogenic factors. Among the challenges confronting semi-natural grasslands, invasive species pose a widespread threat. Invasive species are non-native organisms that, when introduced to a new ecosystem, often outcompete native species and disrupt the ecological balance [PR11]. One such invader that has gained considerable attention in European grasslands and other herbaceous vegetation is *Lupinus polyphyllus* Lindl., commonly known as Lupine [La08]. Native to North America, Lupine has become an exemplary invasive, taking its roots far from its natural habitat and causing substantial ecological and economic consequences. Lupine's ability to flourish in non-native environments and its rapid growth and abundant seed production have made it a challenging threat in many European grasslands. Lupine is known for its ornamental

---

<sup>1</sup> Universität Kassel, Grünlandwissenschaft und Nachwachsende Rohstoffe, Steinstraße 19, 37213, Witzenhausen, Deutschland, jayan.wijesingha@uni-kassel.de,  <https://orcid.org/0000-0003-2574-6303>

purple or blue-violet flowers, which are appreciated in the landscape in contrast to its ecological disturbance.

During the last few decades, Lupine has invaded substantial areas of low-mountain semi-natural grasslands in the Rhön biosphere in Germany [OM05]. Like common invasive species, Lupine competes with native plant species for essential resources such as water, nutrients, and sunlight. Its rapid growth can influence the native herbaceous vegetation, which causes the loss of species diversity. On the other hand, it can disturb the foraging and nesting habits of animal species native to the local ecosystem, leading to food web imbalances. Furthermore, the presence of Lupine in grasslands could reduce their usability for forage production and livestock grazing, triggering economic losses to local farmers.

Understanding the spatial distribution of Lupine within grassland ecosystems is vital to effectively manage and monitor its expansion. Mapping the distribution of Lupine in grasslands was usually conducted by digitising high-resolution aerial images. However, due to the time- and labour-intensive workflow, the time gap between the two Lupine distribution maps was 18 years [K119]. Since time is crucial for limiting the expansion of rapidly growing invasive species like Lupine, a simple and repeatable workflow is required to map Lupine on grasslands. In response to this need, [Wi20] developed a workflow using unmanned aerial vehicle (UAV) borne imaging and object-based image analysis (OBIA) techniques for Lupine mapping. That developed workflow resulted in a mean overall accuracy of 89 % for estimating Lupine on grasslands. Moreover, the results indicated that the developed models can appropriately be applied to any spatial location or time.

Nevertheless, the developed workflow presented some technical difficulties related to the application of OBIA. For example, problems were encountered in determining threshold values, labelling the segments and accepting the resulting segments [Wi20]. Recent studies showed that deep learning (DL) models, such as convolutional neural network (CNN) semantic segmentation models, could be more effective than OBIA for mapping invasive species [KEF19]. Considering these findings, this study hypothesised that DL models could effectively map Lupine on grasslands. Therefore, this study employed high-resolution UAV images and DL techniques to map invasive Lupine on grasslands to prove that hypothesis.

## 2 Materials and Methods

Two sites in the Rhön biosphere reserve were selected as study plots for this study. One site is a former mountain hay meadow (G1), and the other one an old *Nardus stricta* grassland (G2). In both plots, a 50 m by 30 m area was selected as an experimental site. UAV-borne images were collected over both sites on three dates during the summer of 2019 (12 June – D1, 26 June – D2, 09 July – D3). In total, six datasets were collected, and

they were named using the site name and the sampling date (i.e., G1-D1, G1-D2, G1-D3, G2-D1, G2-D2, and G2-D3).

UAV-borne images were acquired using a DJI Phantom IV quadcopter (DJI, China) with an off-the-shelf camera (FC330). The camera was capable of capturing high-resolution 12-megapixel images in the red (R), green (G), and blue (B) spectral bands. The UAV was operated at a flying altitude of 20 meters, which provided a 1 cm ground sampling distance. The UAV was flown on a double-grid mission containing two perpendicular flight paths. The camera operated in automatic mode, capturing nadir-looking images according to a predetermined image overlap configuration, with an 80 % overlap in both forward and side directions. All six flight sessions were conducted between 12:00 and 14:00 to avoid the shadow effects. In addition, another UAV-borne image dataset was collected on 19 August when fields were completely mowed.

The collected UAV-borne images were processed using Agisoft Photoscan software to obtain ortho-mosaic and digital surface models (DSM). The software employed structure from motion technology to stitch single images and derive a three-dimensional model. The DSM derived from the 19 August image dataset was considered as the digital terrain model (DTM), and all six DSM were subtracted from the DTM and canopy surface height (CSH) for each date and site were generated. The CSH contained the relative sward heights of the grass canopies. A reference Lupine coverage map for each dataset was created by manually digitising each RGB ortho-mosaic.

To feed into DL models, the RGB ortho-mosaic images, the CSH, and the labels (manually digitised Lupine map images) were divided into 6.55 m<sup>2</sup> area image chips (256 by 256 pixels). As this was a semantic segmentation problem, the famous “UNET” architecture DL models were employed to develop DL models for this study. Instead of training images from scratch with random weight initialisation, a UNET model with a “Resnet50” backbone pre-trained with “Imagenet” data was employed in this study. The pre-trained UNET model was taken from the “segmentation\_model” Python library, which was compatible with Keras and TensorFlow environments [Ia19].

Three distinct models were developed based on different input datasets. The first model was only developed using RGB images (3 bands), and the second model was built with CSH data (1 band). The third model was developed using RGB and CSH data (4 bands). The model development and evaluation process employed the spatial-temporal cross-validation (SPCV) methodology, which helped to understand the robustness of the developed model for various spatial and temporal conditions. Within each cross-validation fold, a distinct spatial-temporal category dataset was reserved for testing, while the remaining data served as the basis for model training. For example, in one instance, the model was trained using all data except the G1-D1 data, and the unused data for training was employed to validate the model. The model evaluation used the accuracy and intersection over union (IoU) metrics [Ev15]. The accuracy explained how many pixels were correctly segmented over the total number of pixels, which provides an overview of the model performance. The IoU calculates the overlap between the predicted segmented

region and the actual annotated region from the data. It provides a measure of how well predicted segmented regions align with actual annotated regions, which range between zero and one.

### 3 Results

Two example predictions from the model with RGB and CSH data are shown in Figure 1. The models trained only with RGB images showed an average accuracy of 91.6 % and an average IoU of 0.69. From each SPCV fold, the highest accuracy was obtained by the D3 datasets from both sites (G1-D3, G2-D3), and the accuracy was 95 % (IoU = 0.76). The D1 datasets from both sites (G1-D1, G2-D1) showed the lowest validation accuracy (88 % and 86 %) and IoU (0.66 and 0.61).

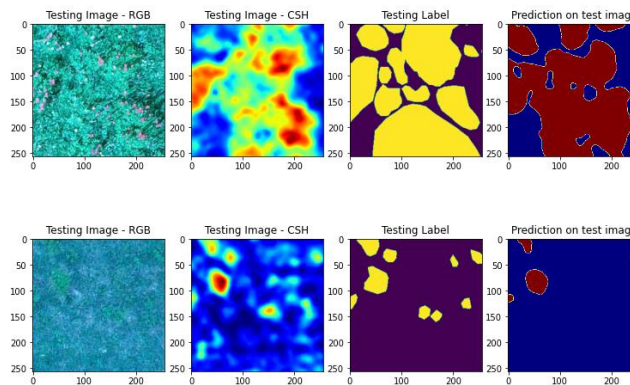


Fig. 1: An example RGB images (1<sup>st</sup> column), canopy surface height (CSH) data (2<sup>nd</sup> column), actual annotation Lupine areas as yellow colour (3<sup>rd</sup> column), and deep learning model predicted Lupine areas as red colour (4<sup>th</sup> column). The first row shows an image chip from G1-D1 dataset and the second row is a chip from G2-D3 dataset

The models developed only with the sward heights (CSH) resulted in 89.7 % of average accuracy and 0.64 of average IoU. These mean performance metrics were slightly lower than the metrics obtained by the models with the RGB data. Similar to the pattern of the results from RGB image models, the highest accuracy and IoU values were obtained by the two datasets from D3. The validation of G1-D3 resulted in 94.2 % accuracy (IoU = 0.70), while the G2-D3 achieved 93.3 % accuracy (IoU = 0.71). The D1 datasets had the lowest performance, achieving the accuracy values of 85.6 % and 82.2 % (IoU = 0.62 and 0.52), respectively, for the G1-D1 and G2-D1 datasets.

The models combining RGB images and CSH data showed no improvement compared to the RGB-only models. According to model performances, the mean accuracy of the combined data models was 91.4 % (IoU = 0.69), which was similar to the model

performance from the RGB data models. Further, the relative Lupine area and the model accuracy were significantly negatively correlated (-0.90).

## 4 Discussion

The outcomes of this study showed that the developed methodology combining UAV images and DL can be successfully applied for mapping Lupine in semi-natural grasslands. As reported, the models with RGB images could segment Lupine with an average accuracy of 91.6 %, higher than the reported average accuracy from OBIA workflow (89.2 %) with the same dataset [Wi20]. The developed DL model provided better outcomes, avoiding complex steps such as segmentation, attribute computation, and index calculations which were done in OBIA. Further, these results confirmed that invasive species in grasslands can be successfully mapped based solely on very high resolution RGB image data without the need for additional spectral information (e.g., near-infrared).

Similarly, the model with exclusive use of CSH data could segment Lupine with 89.7 % average accuracy, which is better than reported accuracy with OBIA but slightly lower accuracy than using only RGB data models. Moreover, no other studies were found in literature reporting on the application of exclusively CSH data for the mapping of non-woody invasive species, making this study the first one to demonstrate the potential application of solely CSH data in grasslands. Nevertheless, combining RGB and CSH data did not improve model prediction capabilities compared to their single use. One possible reason could be the model architecture, which allowed only a three-band image input. To overcome that, an additional pre-step was introduced to convert a four-band image into a three-band image. This step could limit the advantage of using four bands as it is, which may lead to no improvement of the model performance even with the combination of two different data.

Similar to the results reported by [Wi20], the model outputs from this study also showed an inversely proportional relationship between segmentation accuracy and the relative Lupine share. As the Lupine area expands, the segmentation procedure tends to overestimate Lupine coverage because it becomes challenging to distinguish between Lupine and grass vegetation. Accordingly, the developed models showed higher segmentation accuracy when the relative Lupine area was lower or none (e.g., after regular mowing events). This is an important outcome that helps to identify newly invaded grasslands where the invasion is still easy to manage and control.

## 5 Conclusions



This study successfully demonstrated application of very high-resolution UAV-borne RGB images and DL methods for mapping invasive Lupine on semi-natural grasslands. The application of exclusively RGB images or CSH data showed that there is a possibility

of mapping Lupine on grasslands in different locations and time instances. Furthermore, the developed models exhibited the potential for transferability to diverse geographic regions, thus effectively addressing the constraints inherent in the conventional approach to Lupine mapping.

#### Bibliography

- [Ev15] Everingham, M. et al.: The Pascal Visual Object Classes Challenge: A Retrospective. In: *International Journal of Computer Vision* Bd. 111, Nr. 1, S. 98–136, 2015.
- [Gi09] Gibson, D.J.: *Grasses and grassland ecology*: Oxford University Press, 2009 – ISBN 978-0-19-852918-7.
- [Ia19] Iakubovskii, P.: *Segmentation Models*. In: GitHub repository, GitHub, 2019.
- [KEF19] Kattenborn, T.; Eichel, J.; Fassnacht, F.E.: Convolutional Neural Networks enable efficient, accurate and fine-grained segmentation of plant species and communities from high-resolution UAV imagery. In: *Scientific Reports* Bd. 9, Springer US, Nr. 1, S. 1–9, 2019, ISBN 4159801953797.
- [Kl19] Klinger, Y.P. et al.: Applying landscape structure analysis to assess the spatio-temporal distribution of an invasive legume in the Rho UNESCO Biosphere Reserve Bd. 21, S. 2735–2749, 2019.
- [La08] Lambdon, P.W. et al.: Alien flora of Europe: Species diversity, temporal trends, geographical patterns and research needs. In: *Preslia* Bd. 80, Nr. 2, S. 101–149, 2008.
- [OM05] Otte, A.; Maul, P.: Verbreitungsschwerpunkte und strukturelle Einnischung der Stauden-Lupine (*Lupinus polyphyllus* Lindl.) in Bergwiesen der Rhön. In: *Tuexenia* Bd. 25, S. 151–182, 2005.
- [PR11] Pyšek, P.; Richardson, D. M.: Invasive plants. In: *Ecological Engineering* Bd. 2011, Nr. 26 September, S. 2011–2020, 2011.
- [Wi20] Wijesingha, J. et al.: Mapping invasive *Lupinus polyphyllus* Lindl. in semi-natural grasslands using object-based analysis of UAV-borne images. In: *Journal of Photogrammetry, Remote Sensing and Geoinformation Science (PFG)*, Springer International Publishing, S. 16, 2020.

## Implementierung eines Noisy-Student-Ansatzes zur Verbesserung der automatischen Detektionsleistung bei Ferkeln

Martin Wutke <sup>1,2</sup>, Anne Holzhauer<sup>1,3</sup>, Ulrich Hartmann<sup>4</sup>, Marc-Alexander Lieboldt<sup>4</sup>  
und Imke Traulsen <sup>1</sup>

**Abstract:** Die Verwendung überwachter Lernalgorithmen aus dem Bereich der künstlichen Intelligenz hält vermehrt Einzug im wissenschaftlichen Alltag. Vor allem die Nutzung von Kamertechnologie und Objekterkennung zeigt großes Potenzial im ethologischen Kontext. Da der Prozess der Datenannotation einen Großteil der zeitlichen und kostenbezogenen Ressourcen vereinnahmt, werden langfristig innovative Trainingsansätze notwendig. Die vorliegende Studie beschreibt diesbezüglich einen semi-überwachten Noisy-Student-Ansatz zur automatischen Datengenerierung und Verbesserung der Objektdetektion am Beispiel neugeborener Ferkel. Im Rahmen eines zweistufigen Modellansatzes wird ein auf händisch annotierten Daten trainiertes Lehrermodell zur Erzeugung von Pseudo-Annotationen und zum Training eines Schülermodells verwendet. Im Ergebnis kann auf diese Weise eine Verbesserung der Detektionsleistung mit einem Recall-Wert von 0,453 auf 0,707 und einem mAP<sub>0.5</sub>-Wert von 0,773 auf 0,839 erzielt werden. Die Ergebnisse dieser Studie werden im weiteren Projektverlauf zur Untersuchung des Abferkelprozesses und der Bestimmung kritischer Informationen zum Geburtsverlauf beitragen.


**Keywords:** Computer Vision, Noisy-Student, Objekterkennung, Abferkelung

### 1 Einleitung

Die Beobachtung und Analyse des Tierverhaltens mittels Kamera- und Sensortechnologie ist mittlerweile ein vielgenutztes Werkzeug in akademischen Forschungsdisziplinen wie der Nutztierethologie, der Tierernährung oder Zuchtprogrammen. Neben der konventionellen Bild- und Videoauswertung ermöglichen selbstlernende Algorithmen aus dem Bereich der künstlichen Intelligenz eine kontinuierliche und effiziente

---

<sup>1</sup>Christian-Albrechts-Universität zu Kiel, Behavioural Informatics in Livestock Husbandry, Hermann-

Rodewald-Straße 6, 24118 Kiel, mwutke@tierzucht.uni-kiel.de, <https://orcid.org/0000-0001-7839-2751>;

aholzhauer@tierzucht.uni-kiel.de; itraulsen@tierzucht.uni-kiel.de, <https://orcid.org/0000-0001-9761-0291>

<sup>2</sup>Fachhochschule Südwestfalen, Statistik und Data Science in der Agrarwirtschaft, Lübecker Ring 2, 59494

Soest, Deutschland, wutke.martin@fh-swf.de

<sup>3</sup>Georg-August-Universität Göttingen, Systeme der Nutztierhaltung, Albrecht-Thaer-Weg 3, 37075 Göttingen, Deutschland, anne.holzhauer@uni-goettingen.de

<sup>4</sup>Landwirtschaftskammer Niedersachsen, Geschäftsbereich Landwirtschaft, FB 3.7, Mars-la-Tour-Straße 6, 26121 Oldenburg, ulrich.Hartmann@lwk-niedersachsen.de; marc-alexander.lieboldt@lwk-niedersachsen.de

Arbeitserleichterung und liefern zielgerichtete Informationen wie die Position und Orientierung von Einzeltieren. Im Kontext der Schweinehaltung kommt der robusten Erkennung von Ferkeln im Rahmen von Geburtsüberwachungssystemen eine hohe Bedeutung zu. Da die Phase der Modellimplementierung und Parameteranpassung einen nicht unerheblichen Bedarf an Zeit und Know-how erfordert und vor allem der hierfür notwendige Annotationsaufwand und die anschließende Datenverarbeitung bei vielen Forschungsvorhaben als limitierende Faktoren wirken, werden langfristig innovative Annotations- und Trainingsparadigmen notwendig. Aus diesem Grund wurde im Rahmen der vorliegenden Studie der Idee eines Noisy-Student-Ansatzes [Xi20] zur automatischen Datenannotation und Detektion von neugeborenen Ferkeln gefolgt, wobei die Generierung neuer Trainingsinstanzen anhand eines auf manuellen Daten trainierten Lehrermodells erfolgt. Im Ergebnis kann ein neu trainiertes Schülermodell flexibel zur Objektdetektion der gesamten Abferkelbucht oder zur Überwachung spezifisch ausgewählter Teilbereiche genutzt werden.

Der Aufbau der vorliegenden Arbeit gliedert sich wie folgt: Kapitel 2 beschreibt die zugrundeliegende Datenstruktur und Datenvorverarbeitung und gibt einen Einblick in das Grundkonzept des Noisy-Student-Trainings und der Modellimplementierung. Die Ergebnisse des Modellvergleichs und vorhandene Herausforderungen werden nachfolgend in Kapitel 3 beschrieben und diskutiert. Kapitel 4 rundet diese Arbeit mit einem Ausblick auf weitere Forschungsvorhaben ab.

## 2 Material und Methode

### 2.1 Datenerhebung und Datenannotation

Die für die Studie verwendeten Videodaten wurden im Rahmen des Verbundprojekts „Experimentierfeld DigiSchwein“ (Förderkennzeichen: 28DE109G18) von Mai 2021 bis August 2023 erhoben [Li22]. Auf Basis von 175 Abferkelungen mit einer durchschnittlichen Wurfgröße von 19 Ferkeln, einer Mindestwurfgröße von 14 Ferkeln und einer maximalen Wurfgröße von 24 Ferkeln wurden Videoaufnahmen sowohl von fixierten als auch freien Abferkelungen erhoben. Da eines der Projektteilziele die Entwicklung eines Monitoringsystems zur Bewertung des Geburtsverlaufes darstellt, wurden für die Videoaufzeichnung RGB-Kameras vom Typ Axis 3206LVE 3m mittig über acht Einzelabferkelbuchten installiert, welche über 22 Durchgänge den Geburtsprozess aufzeichneten. Jedes Video wurde mit einer Auflösung von 1920 x 1080 Pixeln und einer Rate von 20 Bildern pro Sekunde erfasst. Für das initiale Modelltraining wurden 1100 Einzelbilder händisch annotiert, wobei die vier Objektklassen *Kopf*, *Hinterteil*, *Schwanz* und *Ferkel* durch eine Bounding-Box-Annotation markiert wurden. Zur Beurteilung des Trainingsprozesses wurden 90 Prozent der Daten für das Modelltraining und 10 Prozent der Daten für die Modellvalidierung während des Trainings genutzt. Die Trainingsdaten wurden darüber hinaus durch Verwendung einer horizontalen



Drehung und vertikalen Drehung augmentiert. Somit konnte die Heterogenität der enthaltenen Informationen des Trainingsdatensatzes gesteigert und die Datensatzgröße der manuell annotierten Trainingsdaten auf 3960 Bilder erhöht werden.

## 2.2 Noisy-Student-Training und Generierung der Pseudo-Annotationen

Die Grundidee des vorgestellten Ansatzes zielt auf eine robuste Detektion der Objektklasse *Ferkel* ab, um langfristig die Bestimmung des Geburtszeitpunktes und der individuellen Geburtsintervalle neugeborener Ferkel zu erzielen. Da vor allem die Ferkelerkennung und die Bestimmung der Geburtsintervalle eine hohe Detektionsgüte voraussetzen, ist eine entsprechend hohe Anzahl annotierter Bildinformationen notwendig. Um den damit zusammenhängenden Zeit- und Kostenbedarf des Annotationsprozesses zu reduzieren, wurde ein Noisy-Student-Trainingsansatz gewählt, welcher im Kern auf einem zweistufigen Modellansatz, bestehend aus einem Lehrer- und einem Schülermodell, basiert. Bei dieser semi-überwachten Lernmethode wird zunächst das Lehrermodell in Form eines Convolutional Neural Networks (CNN) anhand der händisch erstellten Bildannotationen trainiert, welches nachfolgend zur Generierung von Pseudo-Annotationen für nicht annotierte Bilder genutzt wird [Ku23]. Anhand der Pseudo-Annotationen wird iterativ eine Reihe von Schülermodellen trainiert, wobei das jeweils vorhergehende Modell als neues Lehrermodell fungiert [Pa20].

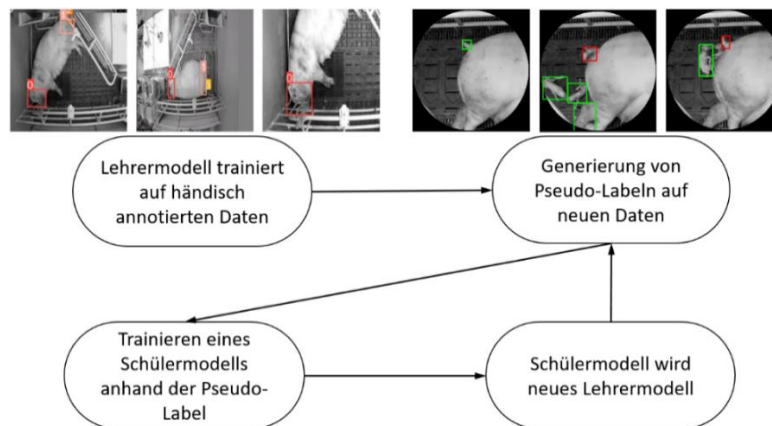


Abb. 1: Während das Lehrermodell auf händisch annotierten Bildern trainiert wurde, werden die Vorhersageergebnisse des Lehrermodells zur Generierung von Pseudo-Annotationen und dem Training des ersten Schülermodells verwendet. Iterativ wird das Schülermodell zum neuen Lehrermodell bis ein zufriedenstellendes Detektionsergebnis erreicht wird. In Anlehnung an [Xi20].

Um die Komplexität der Buchtenumgebung zu reduzieren und darüber hinaus die Generalisierungseigenschaften des Schülermodells auf unterschiedliche Buchtenumgebungen zu erhöhen, wurden die Pseudo-Annotationen auf einen verkleinerten

Zielbereich erstellt, welcher sich am Hinterteil der Sau befindet und lediglich die Objektklassen *Ferkel* und *Schwanz* umfasst. Die generierten Pseudo-Annotationen weisen somit einen verkleinerten Möglichkeitsraum der zu detektierenden Objektklassen auf, um das Risiko von Missklassifikationen zu verringern. Für den Trainingsprozess des Lehrers als auch des Schülermodells wurde dem Vorgehen früherer Studien gefolgt [Lu23; We23; XF23] und ein CNN mit einer Yolov8-Architektur [Jo20] zur Objektdetektion verwendet. Abbildung 1 illustriert beispielhaft die Grundidee des vorgestellten Ansatzes.

### 3 Ergebnisse und Diskussion

Zur Evaluation der Modellleistung wurde neben den individuellen Validierungsdatensätzen des Modelltrainings ein gemeinsamer Testdatensatz bestehend aus 100 zufällig ausgewählten Einzelbildern mit einer unterschiedlichen Anzahl neugeborener Ferkel manuell annotiert. Hierbei wurden die Hinterteilannotationen der Sau zur Erzeugung des Zielbereichs verwendet, um die erforderliche Bildstruktur für das Schülermodell zu generieren. Die Evaluationsergebnisse sind nachfolgend in Tabelle 1 angeführt.

| Klasse     | Lehrermodell |          |                |                  | Schülermodell |          |                |                  |
|------------|--------------|----------|----------------|------------------|---------------|----------|----------------|------------------|
|            | <i>P</i>     | <i>R</i> | <i>mAP</i> 0.5 | <i>mAP</i> :0.95 | <i>P</i>      | <i>R</i> | <i>mAP</i> 0.5 | <i>mAP</i> :0.95 |
| Kopf       | 0,926        | 0,940    | 0,945          | 0,557            | -             | -        | -              | -                |
| Hinterteil | 0,883        | 0,529    | 0,762          | 0,275            | -             | -        | -              | -                |
| Schwanz    | 0,592        | 0,344    | 0,349          | 0,098            | 0,609         | 0,188    | 0,265          | 0,092            |
| Ferkel     | 0,976        | 0,453    | 0,773          | 0,470            | 0,913         | 0,707    | 0,839          | 0,495            |

Tab 1: Ergebnisse des Modellvergleichs zwischen Lehrer- und Schülermodell basierend auf 100 annotierten Testbildern. Für den Vergleich wurden die Evaluationsmetriken Precision (*P*), Recall (*R*), mean average Precision (*mAP*) für einen IoU-Wert von 0,5 sowie dem mittleren *mAP*-Wert für IoU-Werte von 0,5 bis 0,95 mit einem Schrittmaß von 0,05 verwendet

Im direkten Vergleich erreicht das Lehrermodell eine Detektionsgüte für die Objektklasse *Ferkel* von 0,976 für *P*, 0,453 für *R* und 0,773 für *mAP*0.5. Trotz des hohen *P*-Werts und einer geringen Falschklassifikationsrate erreicht das Lehrermodell lediglich einen *R*-Wert von 0,453, was darauf hindeutet, dass eine nicht unerhebliche Anzahl von Ferkeln nicht detektiert wird. Dem gegenüber erzielt das Schülermodell einen verbesserten *R*-Wert von 0,707 und einen *mAP*0.5-Wert von 0,839, wodurch ein signifikant höherer Anteil an Ferkeln korrekt lokalisiert und klassifiziert wird. Dieses Modellverhalten zeigt sich ebenfalls bei manueller Überprüfung der klassifizierten Einzelbilder aus dem Testdatensatz, was in Abbildung 2 anhand von zwei Beispielbilder illustriert wird.

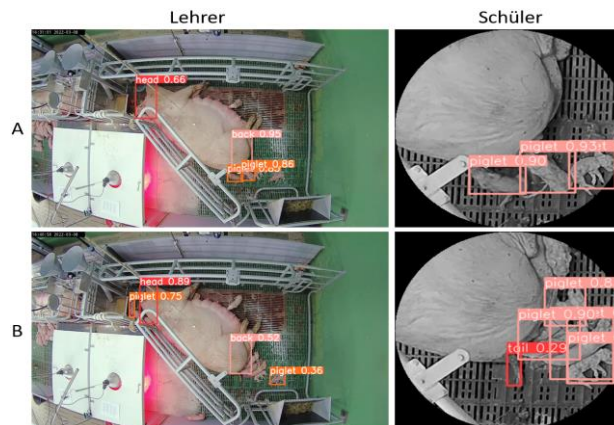


Abb. 2: Durch das Lehrermodell wurden in (A) zwei von drei Ferkel im Zielbereich detektiert, während das Schülermodell alle Ferkel erfolgreich bestimmen konnte. (B) Vor allem Situationen mit Ferkeln in geringer Distanz zueinander zeigen sich für das Lehrermodell erschwerend, wohingegen das Schülermodell alle vier Ferkel detektiert

Im Vergleich zu früheren Studien wie [Ho21], bei der alle Ferkel im Rahmen eines einstufigen Verfahrens im gesamten Buchtbereich detektiert werden, fokussiert sich der gezeigte Ansatz auf die Detektion neugeborener Ferkel im Zielbereich, um kritische Informationen wie beispielsweise individuelle Geburtsintervalle zu bestimmen. Somit können einerseits nicht-relevante Informationen außerhalb des Zielbereichs gefiltert und darüber hinaus das Problem von Objektverdeckungen und nicht-detektierten Ferkeln reduziert werden. Trotz der verbesserten Detektionsgüte des Schülermodells beschränkt die bestehende Abhängigkeit von der Detektionsleistung des Lehrermodells das Potenzial des gezeigten Ansatzes. Um einen nutzenstiftenden Einsatz in zukünftigen Geburtsmonitoringsystemen gewährleisten zu können, ist eine robuste Körperteilerkennung des Lehrermodells notwendig, weshalb die kontinuierliche Verbesserung des Trainingsdatensatzes des Lehrermodells nach wie vor eine hohe Relevanz besitzt.

#### 4 Zusammenfassung und Fazit

Unter Verwendung eines Noisy-Student-Ansatzes beschreibt die vorliegende Studie eine Methode zur Verringerung des Annotationsaufwandes für überwachte Lernalgorithmen und zur Verbesserung der Ferkeldetektion im Rahmen von Geburtsmonitoringsystemen. Eingebunden als Arbeitspaket in dem größeren Verbundprojekt „Experimentierfeld DigiSchwein“ sollen das vorgestellte Lehrer- und Schülermodell in den kommenden Arbeitsschritten kritische Geburtsinformationen wie den Beginn des Geburtsprozesses und individuelle Geburtsintervalle zur Ableitung von Handlungsempfehlungen und der zeitnahen Bestimmung von Geburtsstörungen ermöglichen. Um die Modellleistungen zu

erhöhen und bestehende Limitationen zu verringern, könnten sich weiterführende Arbeiten auf die Verbesserung und gezielte Erweiterung des Lehrerdatsatzes fokussieren.

**Förderhinweis:** Die Förderung dieses Vorhabens erfolgt aus Mitteln des Bundesministeriums für Ernährung und Landwirtschaft auf Beschluss des Deutschen Bundestages (Förderkennzeichen 28DE109G18). Die Projektträgerschaft erfolgt über die Bundesanstalt für Landwirtschaft und Ernährung im Rahmen des Zukunftsprogramms Digitalpolitik Landwirtschaft. Die Projektpartner bedanken sich für die Unterstützung.

#### Literaturverzeichnis

- [Ho21] Ho, K.-Y., Tsai, Y.-J., Kuo, Y.-F.: Automatic monitoring of lactation frequency of sows and movement quantification of newborn piglets in farrowing houses using convolutional neural networks. *Computers and Electronics in Agriculture*, 189, 106376, 2021. <https://doi.org/10.1016/j.compag.2021.106376>
- [Jo20] Jocher, Glenn et al.: ultralytics/yolov5: v3. 0. In: *Zenodo*, 2020.
- [Ku23] Kurita, Yuki et al.: Accurate deep learning model using semi-supervised learning and Noisy Student for cervical cancer screening in low magnification images. In: Giannini, A. (Hrsg.) *PLOS ONE* Bd. 18 (2023), Nr. 5, S. e0285996.
- [Li22] Lieboldt, Marc-Alexander et al.: Wissenstransfer im Experimentierfeld DigiSchwein. 42. GIL-Jahrestagung, Künstliche Intelligenz in der Agrar- und Ernährungswirtschaft. 2022.
- [Lu23] Luo, Sheng et al.: Dead Laying Hens Detection Using TIR-NIR-Depth Images and Deep Learning on a Commercial Farm. In: *Animals* Bd. 13, Nr. 11, S. 1861, 2023.
- [Pa20] Park, Daniel S. et al.: Improved Noisy Student Training for Automatic Speech Recognition. In: *Interspeech 2020*, arXiv:2005.09629 [cs, eess], S. 2817–2821, 2020.
- [We23] Wei, Jiacheng et al.: Detection of Pig Movement and Aggression Using Deep Learning Approaches. In: *Animals* Bd. 13, Nr. 19, S. 3074, 2023.
- [XF23] Xiao, Xin; Feng, Xinlong: Multi-Object Pedestrian Tracking Using Improved YOLOv8 and OC-SORT. In: *Sensors* Bd. 23, Nr. 20, S. 8439, 2023.
- [Xi20] Xie, Qizhe et al.: Self-Training With Noisy Student Improves ImageNet Classification. In: *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Seattle, WA, USA : IEEE, 2020, ISBN 978-1-72817-168-5, S. 10684–10695.

## **Keynote: Digitale Landwirtschaft und der Erhalt von Artenvielfalt – gibt es einen Zusammenhang?**

Markus Frank<sup>1</sup>

### **Abstract Keynote:**

Die Widerstandsfähigkeit oder Resilienz der landwirtschaftlichen Produktion gewinnt immer mehr an Bedeutung, da der Klimawandel und der Verlust der biologischen Vielfalt die landwirtschaftliche Produktion immer unbeständiger macht. In dieser Keynote sollen die verschiedenen Rollen digitaler Entscheidungshilfen für den Erhalt und die Steigerung von Biodiversität beleuchtet werden. Es wird aufgezeigt, wie u.a. die teilflächen-spezifische Bewirtschaftung beitragen kann, die existierende Artenvielfalt in der Agrarlandschaft zu schonen. Die große Bedeutung der Modellierung der Auswirkungen des Ackerbaus auf die Artenvielfalt und deren Management wird zudem beleuchtet. Hierbei ist das Aufzeigen von potenziellen Synergien oder Zielkonflikten von Ökologie und Ökonomie von zentraler Bedeutung. Schließlich wird die Bedeutung der Interoperabilität der eingesetzten digitalen Werkzeuge diskutiert, um eine Skalierung der biodiversitäts-fördernden Anbaustrategien zu erreichen und über die Wertschöpfungskette einen „Market Pull“ für einen biodiversitäts-schonenderen Ackerbau zu erzeugen.

**Prof. Dr. Markus Frank** studierte Biologie mit dem Schwerpunkt Pflanzenphysiologie an den Universitäten Kiel, Köln und Tübingen. Daneben absolvierte Markus Frank ein MBA-Studium an der Surrey Business School in Guildford, England. Nach seiner Promotion am Zentrum für Molekularbiologie der Pflanzen in Tübingen arbeitete Markus Frank mehrere Jahre in der landwirtschaftlichen Forschung und Entwicklung der BASF-Gruppe. Zuletzt verantwortete er das Programm zur Bewertung der Nachhaltigkeit landwirtschaftlicher Produktionssysteme von BASF SE in Limburgerhof. Seit September 2018 ist Markus Frank Professor für „Pflanzengesundheitsmanagement“ an der Hochschule für Wirtschaft und Umwelt Nürtingen-Geislingen.

---

<sup>1</sup> Hochschule für Wirtschaft und Umwelt Nürtingen-Geislingen, Institut für Angewandte Agrarforschung, Neckarsteige 6-10, 72622 Nürtingen, markus.frank@hfwu.de