

Gefördert durch:



Bundesministerium
für Forschung, Technologie
und Raumfahrt

Digital Agricultural Knowledge and Information System: Innovation integration for landscape smart agriculture DAKIS

Teilprojekt Universität Bonn

Dr. Thomas Gaiser (Projektleitung)

Dr. Clara Bazzo, Dr. Amit Srivastava, Jasper Mohr

Rheinische Friedrich-Wilhelms-Universität Bonn

Institut für Nutzpflanzenwissenschaften und Ressourcenschutz (INRES)

Professur Pflanzenbau, Katzenburgweg 5, 53115 Bonn

Förderkennzeichen:

031 B0729 E

**Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für
Forschung, Technologie und Raumfahrt unter dem Förderkennzeichen 031 B0729 E gefördert. Die
Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren**

Inhaltsverzeichnis

1	Kurzbericht.....	2
1.1	Aufgabenstellung.....	2
1.2	Voraussetzungen unter denen das Vorhaben durchgeführt wurde	2
1.3	Planung und Ablauf des Vorhabens	2
1.4	Wissenschaftlicher und technischer Stand, an den angeknüpft wurde.....	3
1.5	Zusammenarbeit mit anderen Stellen.....	3
2	Ausführliche Darstellung der Ergebnisse.....	4
2.1	Die erzielten Ergebnisse	4
2.2	Voraussichtlicher Nutzen und Fortschreibung des Verwertungsplans	19
2.3	Während des Vorhabens bekannt gewordener Fortschritt auf dem Gebiet des Vorhabens	19
2.4	Erfolgte oder geplante Veröffentlichung der Ergebnisse	19
3	Literaturverzeichnis	20

1 Kurzbericht

1.1 Aufgabenstellung

Das Ziel des DAKIS-Projekts bestand darin, einen Prototyp eines neuen Entscheidungsunterstützungssystems (Decision Support System= DSS) zu entwickeln, das standort- und zielspezifische Anforderungen an Produktion, Ökosystemleistungen (ÖSL) und Biodiversität kleinräumig erfasst, in Einklang setzt und entsprechende Managementempfehlungen gibt. Dementsprechend war die ursprüngliche Fragestellung, wie ein solches DSS aufgebaut sein muss. Zudem muss gewährleistet sein, dass der Aufwand für Maßnahmen zur Förderung verschiedener ÖSL und der Biodiversität für die Betriebe wirtschaftlich tragbar ist, oder entsprechende finanzielle Kompensationen bereitgestellt werden. Daher untersuchte das Projekt auch, ob wie gezielte Anbaumaßnahmen die Bereitstellung von ÖSL und Biodiversität verbessern könnten, und wie hoch die gesellschaftliche Nachfrage nach diesen Leistungen tatsächlich ist.

1.2 Voraussetzungen unter denen das Vorhaben durchgeführt wurde

Das DAKIS Projekt wurde gefördert durch das Bundesministerium für Bildung und Forschung (BMBF) über eine Förderphase von 5 Jahren (1.4.2019 bis 31.3.2024) sowie einer anschließenden kostenneutralen Verlängerung bis zum 31.12.2024 und war in das Förderprogramm „Agrarsysteme der Zukunft“ als eines von acht geförderten Konsortien eingebunden. Das Institut für Nutzpflanzenwissenschaften und Ressourcenschutz (Professur Pflanzenbau) an der Rheinischen Friedrich-Wilhelms-Universität Bonn (Universität Bonn) war im Teilprojekt TP2 (Daten und Sensoren - Echtzeit-Monitoring von Agrarökosystemen) des DAKIS Projektes für die Bearbeitung des Arbeitspakets AP2.1 sowie für die Koordination des Teilprojektes TP3 (Optimierung der Anbau- und Betriebsplanung) und die Bearbeitung des Arbeitspakets AP3.2 (Echtzeitsimulation und Quantifizierung von ÖSL / Biodiversität) zusammen mit dem Zentrum für Agrarlandschaftsforschung (ZALF) zuständig.

1.3 Planung und Ablauf des Vorhabens

Im TP 2 „Daten und Sensoren - Echtzeit-Monitoring von Agrarökosystemen“ wurden erstmals innovative Sensortechnologien kombiniert, so dass eine hochkomplexe, qualitativ hochwertige Datenerfassung auf landwirtschaftlichen Flächen und Landschaften möglich war. Die Koordination der Monitoringaktivitäten lag in den Händen der Universität Bonn. Ausgewählte Ökosystemleistungen (ÖSL) wurden hochauflösend erfasst und an das TP3 weitergeleitet. In TP3 (Optimierung der Anbau- und Betriebsplanung) wurden die in TP2 erfassten Daten zur Ermittlung der optimalen betrieblichen Produktion auf der Grundlage von biophysikalischen Simulations- (AP3.2) und ökonomischen Optimierungsmodellen (AP3.1) verwendet. Die Universität Bonn war für das AP3.2 durch die Entwicklung von prozessbasierten Modellen zur Simulation eines breiten Spektrums von ESS-Variablen im Feld verantwortlich, die dann in die Betriebsmodellierung (AP3.1) integriert wurden. Die in diesem SP entwickelten Modelle sind ein integraler Bestandteil des DAKIS-Systems.

Zu Beginn des Vorhabens lag der Schwerpunkt der Arbeiten im Teilprojekt der Universität Bonn auf der Bearbeitung von des Arbeitspaketes AP2.1. Es wurden invasive und nicht-invasive Monitoringaktivitäten auf dem DAKIS Agroforststandort Großmutz aufgebaut und koordinieren. Im Jahr 2020 wurde zusätzlich ein boden- und luftgestützten Monitoring auf dem DAKIS Grünlandexperiment Paulinenaue und dem Grünland-Reallabor „Wandlitz“ aufgebaut und koordiniert. Durch den Ausbruch der Corona-Pandemie im März 2020 wurde die Durchführung von Feldarbeiten auf allen DAKIS Versuchsstandorten erheblich erschwert. Unter

Schlussbericht

großem persönlichen Einsatz der DAKIS Mitarbeiter sowie von Mitarbeitern unseres Lehrstuhls konnte ein Minimum von Monitoringaktivitäten auf den DAKIS Versuchsstandorten Großmutz, Paulinenaue und Wandlitz über die Zeit der Coronapandemie aufrechterhalten werden. Erste Vorarbeiten in AP3.2 wurden bereits 2020 durchgeführt. Nach den ersten zwei Jahren der Datenerhebung auf den DAKIS Versuchsstandorten, wurden dann prozess-basierte Simulationsmodelle im SIMPLACE Framework für die Acker- und Grünlandstandorte in Brandenburg aufgebaut, mit denen eine Reihe von ÖSL dynamisch simuliert werden können. Parallel zur Modellentwicklung wurden in Kooperation mit AP3.1 Übergabeschnittstellen zwischen den biophysikalischen Modellen im SIMPLACE Framework und dem ökonomischen Betriebsmodell MODAM erarbeitet.

1.4 Wissenschaftlicher und technischer Stand, an den angeknüpft wurde

Eine standortangepasste Landwirtschaft mit optimierten Produktionsmethoden und Prozessen ist in Deutschland bereits gängige Praxis. Mit Methoden des Precision Farming (PF) können Feldvariabilitäten durch digitale Technik in modernen Managementsystemen identifiziert, eingemessen, analysiert und bewertet werden, um Handlungsentscheidungen abzuleiten (EPRS 2016, Wolfert et al. 2017). Diverse Marktakteure bieten die Möglichkeit, mit Hilfe von Software den Betrieb über ein digitales Managementsystem zu bewirtschaften (Porter & Heppemann 2014, Von Löbbecke & Krudewig 2015). Ferner werden durch Informations- und Kommunikationstechnologien im „Internet der Dinge“ vernetzte und intelligente Produkte mit innovativen und zukunftsorientierten „smarten“ Schlüsseltechnologien für eine Landwirtschaft 4.0 bereitgestellt, welche aus Forschung und Praxis nicht mehr wegzudenken sind.

In den Betriebsmanagementkreislauf sind bereits heute smarte Systeme (Smart Farming, SF) integriert, die unterschiedliche ackerbaulich relevante Parameter in Echtzeit erheben, analysieren, entsprechende Handlungsempfehlungen ausgeben und diese direkt, z.T. autonom, umsetzen können (Porter & Heppelmann 2014, Weltzien 2016, Wolfert 2017). Die Innovation dieser Technologien der Landwirtschaft 4.0 liegt in den neuen Möglichkeiten zur Vernetzung der Komponenten aus PF, SF, Robotik und Sensorik/ Fernerkundung, welche derzeit v.a. in der Forschung erprobt werden. Hier stehen derzeit auch neue Anbausysteme, die sich besonders mit Hilfe von SF-Technologien umsetzen lassen, im Vordergrund (Techen & Helming 2017). „Spot Farming“ ist beispielsweise ein System, das auf kleinräumige („Spot“) Bewirtschaftung abzielt und so auf zukünftige Bedürfnisse und Rahmenbedingungen flexibel reagieren soll. Dazu werden u.a. drahtlose Sensornetzwerke, mobile Roboter und Analysetools untersucht und optimiert (Wegener et al. 2017).

1.5 Zusammenarbeit mit anderen Stellen

Das Vorhaben an der Universität Bonn war eingebunden in ein Konsortium mit neun weiteren Partnern: (1) Leibniz-Zentrum für Agrarlandschaftsforschung (ZALF), (2) Forschungszentrum Jülich (FZJ), (3) Leibniz-Institut für innovative Mikroelektronik (IHP), (4) Deutsches Forschungszentrum für Künstliche Intelligenz (DFKI), (5) Hochschule Osnabrück (HSO), (6) Hochschule für nachhaltige Entwicklung Eberswalde (HNEE), (7) Leibniz-Institut für Agrartechnik und Bioökonomie (ATB), (8) Fraunhofer Institut für System- und Innovationsforschung (FH ISI) und (9) Europa-Universität Viadrina Frankfurt (Oder) (EUV). Das ZALF koordinierte das Konsortium sowie die Teilprojekte TP1, TP5 und TP6 (Tabelle 1). Die Universität Bonn koordinierte das Teilprojekt TP3, das eng mit den Teilprojekten TP2, TP4 und TP5 zusammenarbeitet, die jeweils von IHP, DFKI und ZALF koordiniert wurden. Monatlich fand ein Treffen der Teilprojektleiter statt, die

Schlussbericht

sicherstellten, dass die Ergebnisse in den Teilprojekten ausgetauscht und im DAKIS Prototyp integriert wurden.

2 Ausführliche Darstellung der Ergebnisse

2.1 Die erzielten Ergebnisse

Die wichtigsten Ergebnisse sollen hier anhand der Teilprojekte TP2 (Daten und Sensorik) und TP3 (Optimierung der Anbau- und Betriebsplanung), an denen die Universität Bonn beteiligt war bzw. die Universität Bonn koordinierte, dargestellt werden. Im TP 2 „Daten und Sensoren - Echtzeit-Monitoring von Agrarökosystemen“ wurden erstmals innovative Sensortechnologien kombiniert, so dass eine hochkomplexe, qualitativ hochwertige Datenerfassung auf landwirtschaftlichen Flächen und Landschaften möglich war. Die Koordination der Monitoringaktivitäten sowie die Bearbeitung des Arbeitspakete AP2.1 (Boden- und luftgestütztes Monitoring) lag in den Händen der Universität Bonn. Die ESS wurden hochauflösend erfasst und an das SP3 weitergeleitet. In SP3 (Optimierung der Anbau- und Betriebsplanung) wurden die in SP2 erfassten Daten zur Ermittlung der optimalen betrieblichen Produktion auf der Grundlage von bio-physikalischen Simulations- (AP3.2) und ökonomischen Optimierungsmodellen (AP3.1) verwendet. Die Universität Bonn war für das AP3.2 durch die Entwicklung von prozessbasierten Modellen zur Simulation eines breiten Spektrums von ESS-Variablen im Feld verantwortlich, die dann in die Betriebsmodellierung (AP3.1) integriert wurden. Die in diesem SP entwickelten Modelle sind ein integraler Bestandteil des DAKIS-Systems.

AP2.1 Boden- und luftgestütztes Monitoring von Pflanzenbeständen

Das Teilprojekt TP5 (DAKIS Implementierung) hatte in 2021 unter Leitung der Hochschule für nachhaltige Entwicklung Eberswalde (HNEE) an zwei Grünlandstandorten (Paulinenaue und Wandlitz) Versuche zur Auswirkung der Schnitthäufigkeit auf die Biomasseproduktion, die Futterqualität und die Biodiversität angelegt. Außerdem leitete TP5 einen Agroforstversuch auf einem Praxisbetrieb in Brandenburg. Die Aufgabe der Universität Bonn war es diese drei Standorte regelmäßig mit drohnengetragenen Sensoren zu befliegen und zu beproben (Ground truthing).

AP2.1.1 Monitoring der Ackerkulturen in einem Agroforstsystem

Im Agroforstsystem Großmutz, das im Jahr 2017 auf einem 5,6 ha großen Praxis Schlag angelegt worden war, lag der Schwerpunkt des Monitorings auf der raum-zeitlichen Variabilität der pflanzlichen Biomasse der Ackerkulturen, dem Ertrag, der potenziellen Bodenerosion und der räumlichen Verbreitung der Bodeneigenschaften. Dazu wurde zu Beginn des Projekts eine großmaßstäbige Bodenkarte aus insgesamt 88 Bohrpunkten generiert (Abbildung 1). Kontinuierliche Messungen der Biomasse, des Blattflächenindex und des Kornertrags sowie die Auswertung von Satellitenbildern (Abbildung 2) und von Bildern von drohnengetragenen Multispektralkameras zeigten eine gewisse Stabilität der Teilschläge mit hohem, mittlerem und niedrigem NDVI.

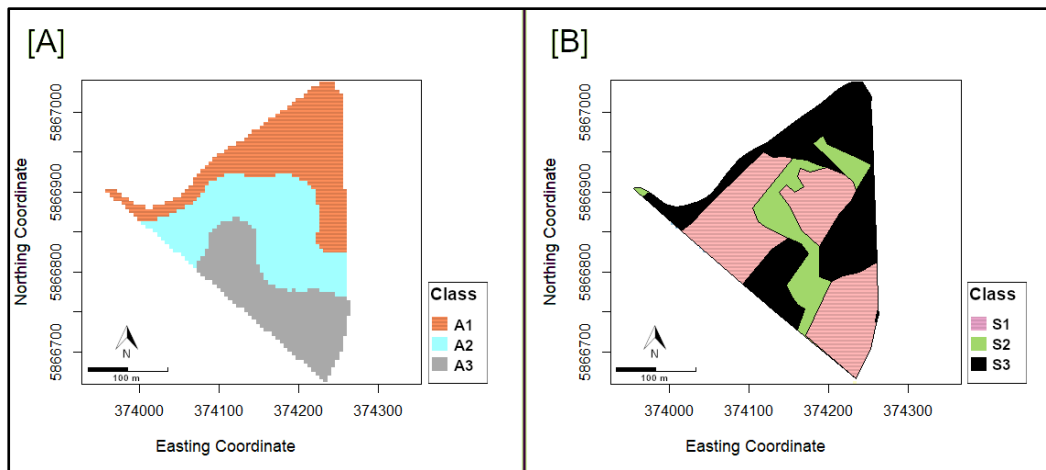


Abbildung 1: Räumliche Verteilung der drei Boden- und Höhenklassen. (A): Höhenklassen. A1: < 53,5 m ü. M., A2: 53,5 - 55,37 m ü. M., A3: > 55,37 m ü. M. (B): Bodenklassen. S1: Obergrenze der lehmigen Schicht in < 60 cm Tiefe, S2: Obergrenze der lehmigen Schicht in 60 - 100 cm Tiefe, S3: Keine lehmige Schicht. EPSG: 32633 (Mohr et al. 2023)

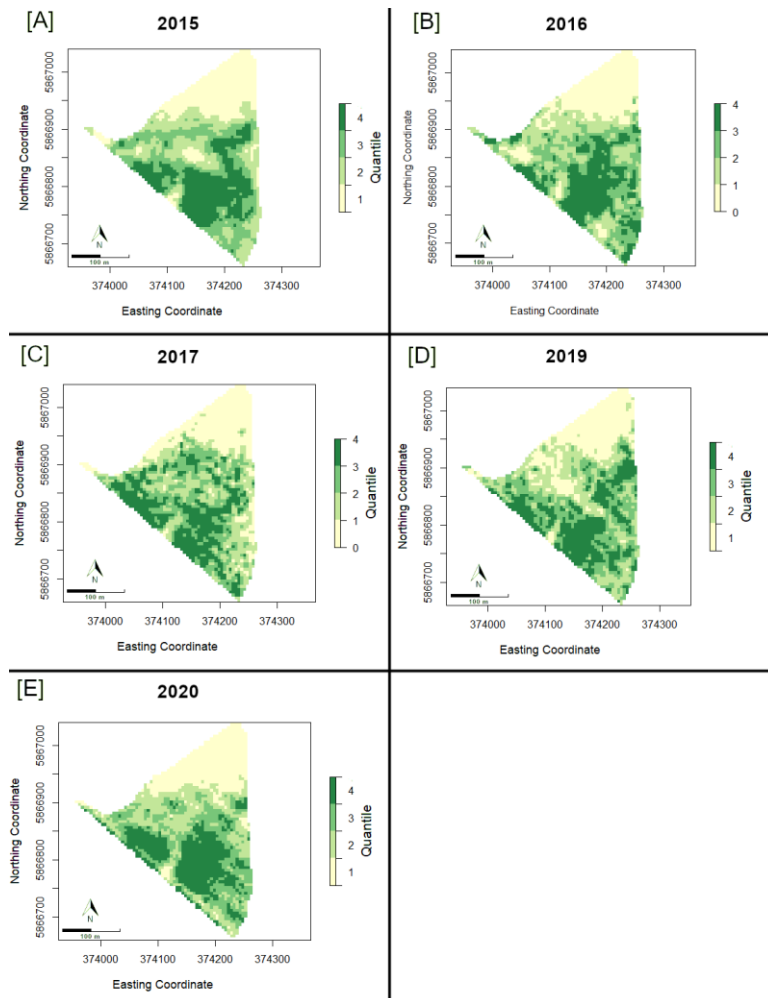


Abbildung 2: NDVI-Werte aller Erfassungen im Juni, aufgeteilt in Quartile (1-4). 1 (hellgelb) entspricht dem Quartil 1 (niedrigste NDVI-Werte) und 4 (dunkelgrün) dem Quartil 4 (höchste NDVI-Werte). (A): Juni 2015, (B): Juni 2016, (C): Juni 2017, (D): Juni 2019, (E): Juni 2020. Die Einstufung der NDVI-Daten in Quartile zeigte, dass der nördlichste Bereich des Feldes im Juni durchweg niedrigere NDVI-Werte aufwies (Q1). (Mohr et al. 2023)

untersten Quartil (Q1) wies auch geringere Triticaleerträge auf und umgekehrt.

Deses räumliche Muster spiegelte sich auch in den Kornerträgen der Getreide wieder (Abbildung 3). Vergleicht man Abbildung 2 und Abbildung 3, so sieht man eine deutliche Korrelation der Quartilen der NDVI-Werte mit den Triticaleerträgen im Jahr 2021. Die nördliche Teilfläche mit NDVI-Werten im

Die Ergebnisse zur Messung des potenziellen Bodenabtrags mit einem Regensimulator und zur Simulation des aktuellen Bodenabtrags sind in Raza et al. 2022 und 2024 veröffentlicht.

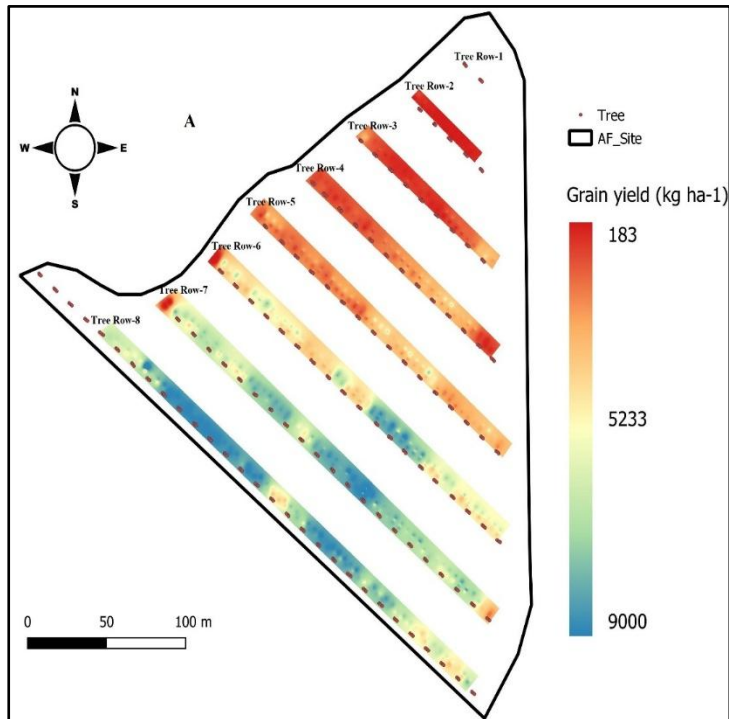


Abbildung 3: Räumliche Verteilung der Triticaleerträge im Agroforstsystem in Großmutz im Jahr 2021.

AP2.1.2 Monitoring der Biomasseproduktion und Biodiversität im Grünlandversuch Paulinenaue

Im Rahmen des DAKIS-Projekts wurden UAV-basierte Ansätze zur Schätzung der oberirdischen Biomasse (AGB) in einem 1,3 ha großen Grünlandschlag, der stark grundwasserbeeinflusst ist, in Paulinenaue in Brandenburg (52°41'28 „N, 12°44'16 “E) entwickelt. Die Fläche wurde in drei Streifen unterteilt, die verschiedene Schnittsysteme repräsentieren (Zwei-, Drei- und Vierschnittsysteme). In zwei Vegetationsperioden (2022 und 2023) wurden 648 Biomasseproben an neun Ernteterminen gesammelt, die mit Drohnenflügen mit einer DJI Phantom 4 Multispectral abgeglichen wurden. Ein Überblick über die Ernteterminen und die Anzahl der Proben pro Schnittsystem ist in Tabelle 2 dargestellt.

Die Drohnenbilder wurden verwendet, um strukturelle (Höhe des Kronendachs), spektrale (Vegetationsindizes) und texturelle (GLCM) Merkmale zu extrahieren. Diese wurden als Eingangsvariablen in Random Forest (RF) und Partial Least Squares (PLS) Regressionsmodellen verwendet. Es wurden sieben Merkmalskombinationen getestet: CH, VI, GLCM, CH+VI, CH+GLCM, VI+GLCM, und CH+VI+GLCM.

Schlussbericht

Tabelle 1: Übersicht der Termine, an denen Feldmessungen durchgeführt wurden, zusammen mit der entsprechenden Anzahl von Proben und Parzellen.

Year	Harvest date	Cutting systems frequency			Number of Biomass samples	Plots with Species survey
		Two-cut	Three-cut	Four-cut		
2022	18 May			X	36	18
	17 Jun	X	X	X	108	54
	03 Aug		X	X	72	36
	14 Sep	X	X	X	108	53
2023	16 May			X	36	35
	07 Jun	X	X		72	72
	21 Jun			X	36	18
	10 Aug		X	X	72	36
	20 Sep	X	X	X	108	54
Total number of samples per treatment		144	216	288	n_{total}= 648	

Die beste Modelleistung wurde mit der Kombination aus CH+VI+GLCM erzielt. Abbildung 4 zeigt die Verteilung der R²-Werte für verschiedene Modelle und Behandlungen. Für das System mit drei Schnitten erreichten die RF-Modelle einen R²-Wert von 0,87, und für gepoolte Daten über alle Behandlungen hinweg ergab die gleiche Merkmalskombination einen R²-Wert von 0,84. Die Vorhersagen spiegelten erfolgreich die saisonale Wachstumsdynamik und die Auswirkungen der Bewirtschaftung wider, wobei im

Zweischchnittsystem höhere Biomassewerte und bei häufigerem Schnitt niedrigere Werte beobachtet wurden.

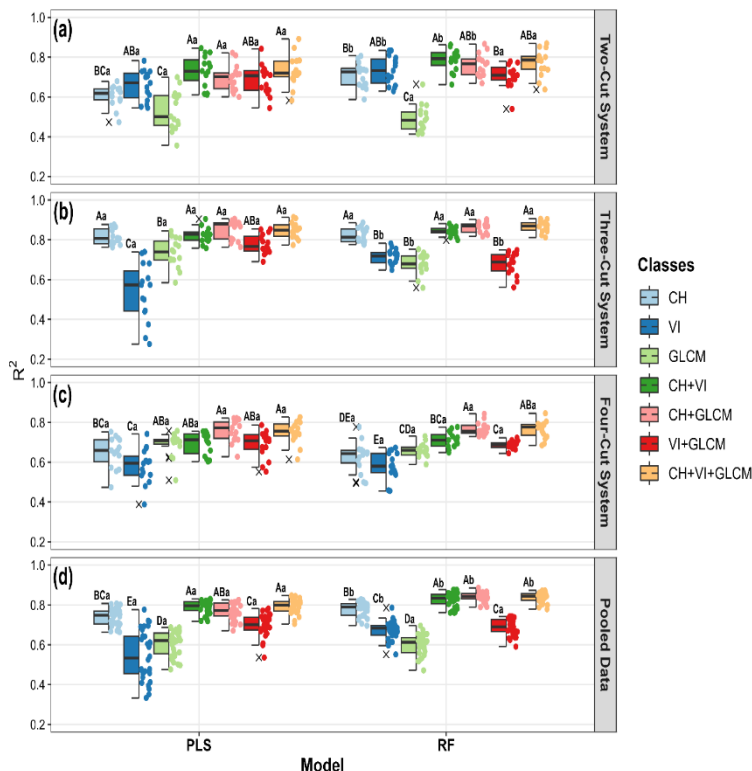


Abbildung 4: Box-Dot-Plots für das Bestimmtheitsmaß (R²) bei der Vorhersage der oberirdischen Biomasse (AGB) unter Verwendung von zwei verschiedenen Algorithmen des maschinellen Lernens: Partial Least Squares Regression (PLS) und Random Forest (RF). Die Modelle enthalten verschiedene Merkmalsklassen, einschließlich der Überschirmungshöhe (CH), der Vegetationsindizes (VI) und der Texturmerkmale (GLCM), die bei verschiedenen Grünlandbewirtschaftungsmethoden angewandt wurden: Zweischritt- (a), Dreischritt- (b) und Vierschnitt-Systeme (c) sowie eine gepoolte Datenanalyse, die alle Methoden kombiniert (d). Großbuchstaben vergleichen die Leistung der Merkmalsklassen innerhalb desselben Modells: gleiche Buchstaben bedeuten keine signifikanten Unterschiede, während unterschiedliche Buchstaben signifikante

Schlussbericht

Unterschiede bedeuten. Kleinbuchstaben bewerten die Unterschiede zwischen den Modellen für jede Merkmalsklasse: identische Buchstaben bedeuten keine signifikanten Unterschiede, und unterschiedliche Buchstaben bedeuten signifikante Unterschiede (Bazzo et al. 2025)

Die Abbildung 5 zeigt beispielhaft Biomasse-Vorhersagekarten für ausgewählte Daten im Jahr 2022 bzw. 2023, die die räumlichen Muster der Biomasseakkumulation und des Nachwachsens veranschaulichen. Diese Ergebnisse bestätigen, dass aus UAVs gewonnene Daten die Echtzeitüberwachung der Biomasse und die Integration in digitale Entscheidungsunterstützungssysteme wie DAKIS unterstützen könnten.

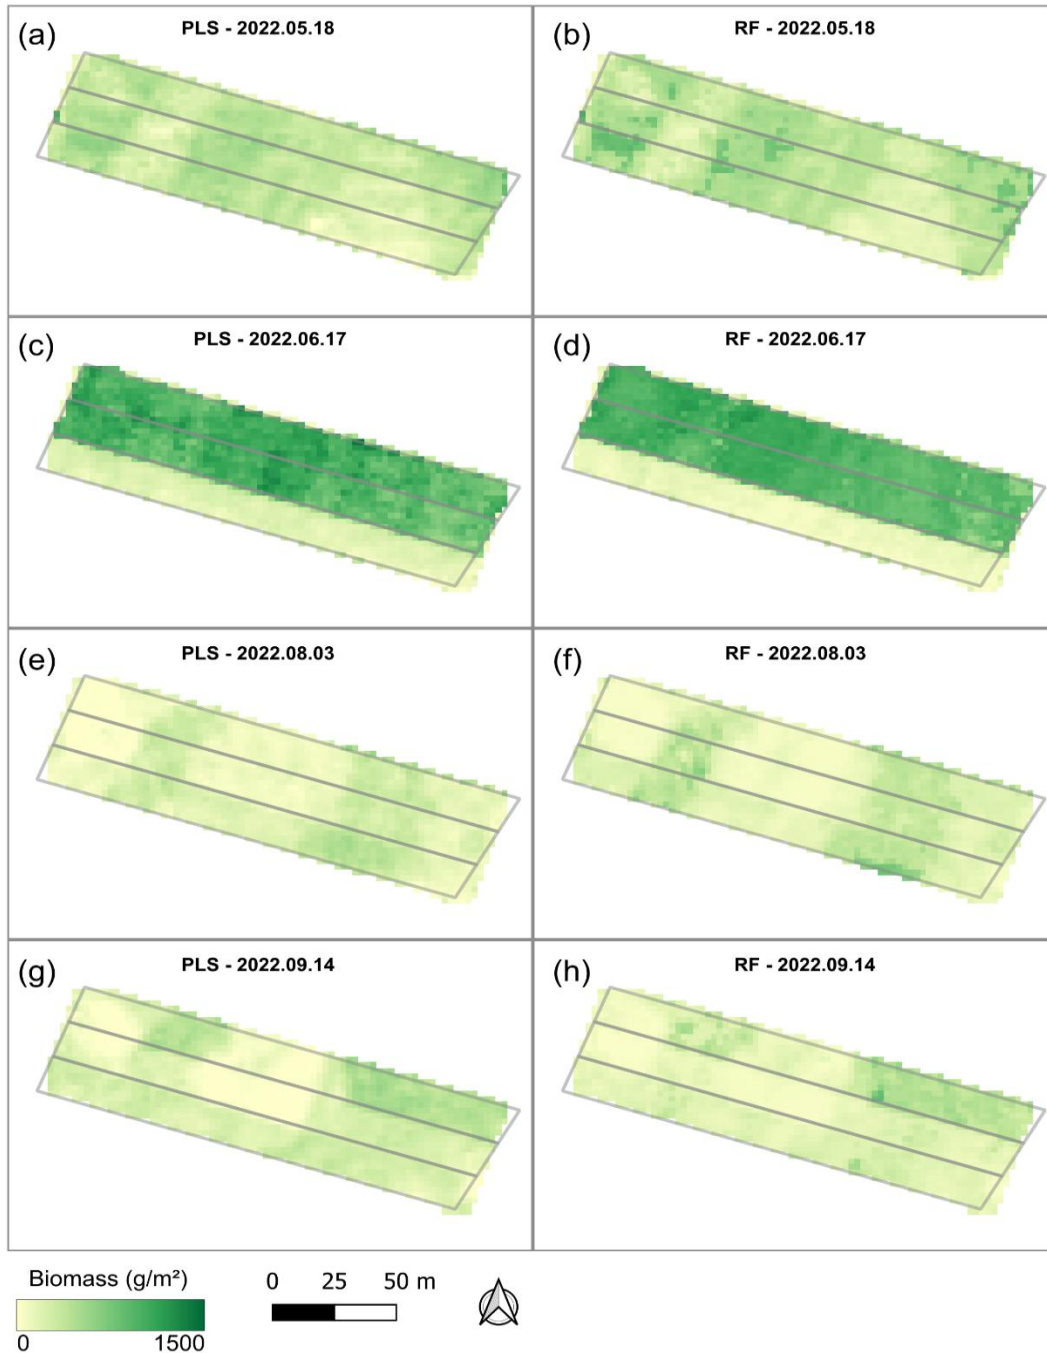


Abbildung 5: Karten der Verteilung der trockenen oberirdischen Biomasse für 2022 unter Verwendung der Integration von Bestandeshöhe (CH), Vegetationsindizes (VI) und Textur (GLCM) für Partial Least Squares

Schlussbericht

(PLS) und Random Forest (RF) Modelle. Die Biomassevorhersagen sind für vier Erhebungszeitpunkte dargestellt: (a, b) 18. Mai, (c, d) 17. Juni, (e, f) 3. August und (g, h) 14. September (Bazzo et al. 2025)

Der Artenreichtum von Pflanzen wurde anhand von UAV-Daten geschätzt, wobei derselbe methodische Rahmen wie bei der Biomasseschätzung verwendet wurde. Erhebungen zur Vegetationszusammensetzung wurden parallel zur Erfassung von UAV-Bildern während der Vegetationsperioden 2022 und 2023 durchgeführt (Abb. 6). Insgesamt wurden 376 Vegetationsparzellen in drei Schnittregimen (Zwei-, Drei- und Vierschnittsysteme) und sechs Vegetationszonen beprobt. Auf jeder Parzelle wurde die Gesamtzahl der Gefäßpflanzenarten pro Quadratmeter erfasst. Tabelle 1 gibt einen Überblick über die Beprobungszeitpunkte und die Anzahl der Parzellen pro Behandlung.

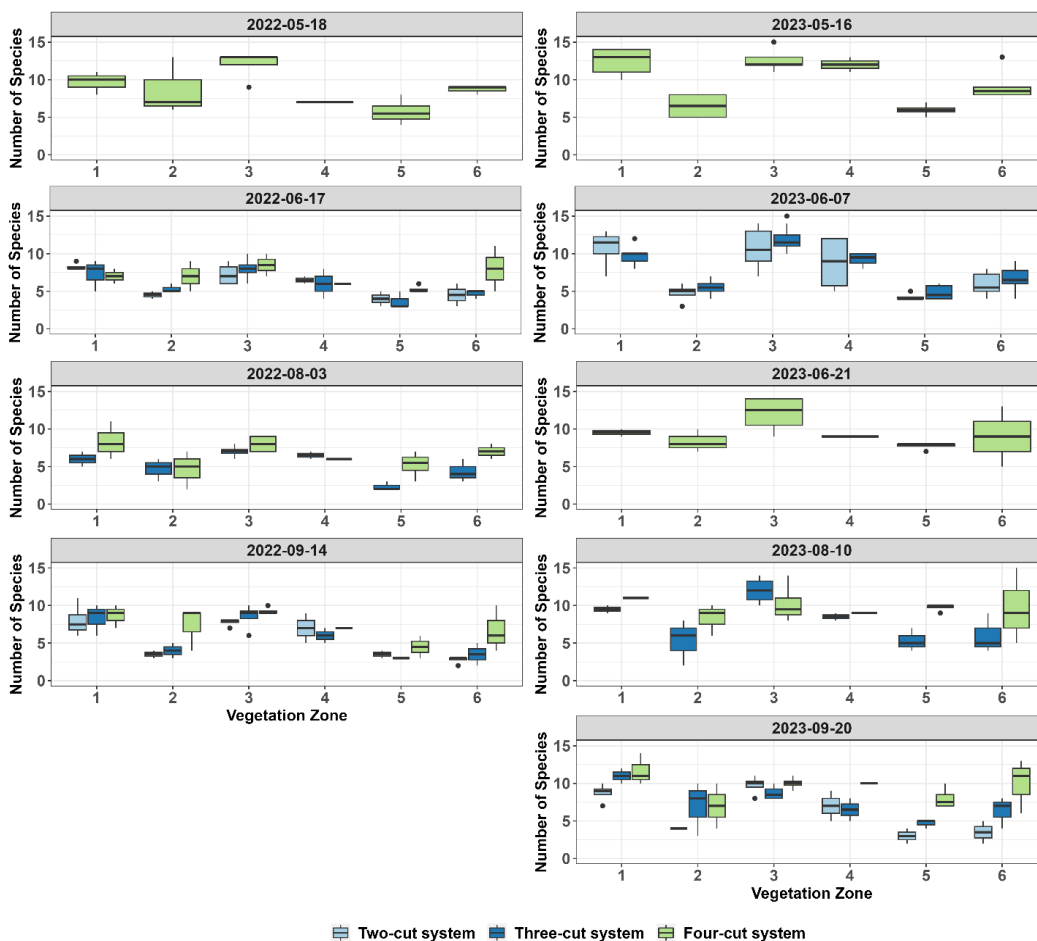


Abbildung 6: Gemessener Artenreichtum in den verschiedenen Schnittsystemen innerhalb von sechs Vegetationszonen in den Jahren 2022 und 2023 (Bazzo et al. 2024)

Abbildung 6 zeigt die Verteilung der beobachteten Artenvielfalt über die Vegetationszonen. Die Werte der beobachteten Artenvielfalt reichten von 3,0 bis 12,8 Arten pro Parzelle, wobei die höchsten Werte durchweg in den Vegetationszonen 1 und 6 gefunden wurden.

Abbildung 7 zeigt räumliche Karten der vorhergesagten Reichhaltigkeit für fünf UAV-Erfassungsdaten im Jahr 2023 unter Verwendung von CH+VI+GLCM-Modellen. Die vorhergesagten räumlichen Muster stimmen mit den beobachteten überein, die in Abbildung 5 dargestellt sind.

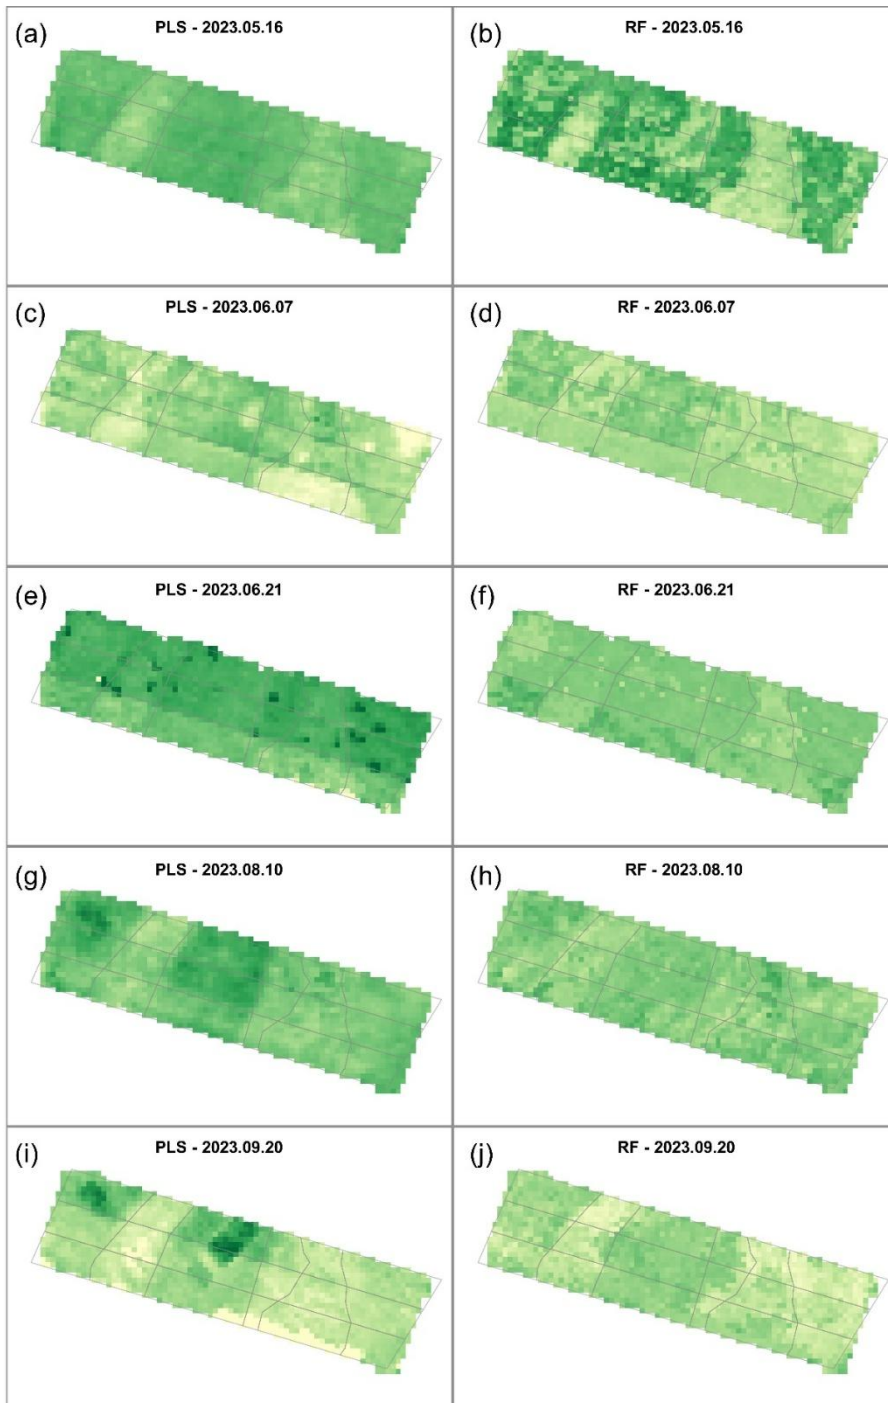


Abbildung 7: Karten des Artenreichtums für 2023 unter Verwendung der Integration von CH-, VI- und GLCM-Merkmalen für Random-Forest- (RF) und Partial-Least-Squares- (PLS) Modelle über fünf Erhebungszeitpunkte: (a, b) 16. Mai, (c, d) 7. Juni, (e, f) 21. Juni, (g, h) 10. August und (i, j) 20. September (Bazzo et al. 2024)

Diese Ergebnisse bestätigen das Potenzial der UAV-gestützten Überwachung zur Erfassung feiner räumlicher und zeitlicher Variationen des Pflanzenartenreichtums und tragen zur Bewertung der biologischen Vielfalt im Rahmen von DAKIS bei.

Schlussbericht

AP2.1.3 Monitoring der Biomasseproduktion und der faunistischen und floristischen Biodiversität im Grünlandversuch Wandlitz

Bei dem zweiten Grünlandstandort, der von TP5 im Rahmen des DAKIS-Projekts zum luft- und bodengestütztes Monitoring im AP2.1 ausgewählt worden war, handelt es, im Gegensatz zum Standort Paulinenaue, um einen zum größten Teil grundwasserfernen Standort. Dort sollte zum einen der Zusammenhang zwischen einen oder mehreren Bodenparametern und dem Grastrockenmasseertrag sowie der floristischen Biodiversität untersucht werden. Außerdem wurden an diesem Standort akustische Sensoren installiert, um die Möglichkeiten von Bioakustik zur Abschätzung der Auswirkung von Schnitthäufigkeit auf die faunistische Diversität zu erkunden.

Die ausgewählte Fläche (Abb. 8) befindet sich auf einem Praxisbetrieb in Brandenburg, hat eine Größe von 4,48 ha und weist gemäß der Bodenbelastungskarte (BBK) zwei unterschiedliche Biotoptypen auf. Zum einen den Biotoptyp 05150 (Intensivgrünland) und im südöstlichen Bereich den Typ 0513101 (Grünlandbrache feuchter Standorte). Die umgebenden Biotope sind: Ackerland im Westen, Buchenwald im Norden, Feuchtgrünlandbrache mit Baumgruppen im Osten und Süden. Die südliche Grenze des Gebietes wird durch den Schönwade-Graben also einem Gewässer gebildet. Der südöstliche Bereich ist im Vergleich zum Rest des Geländes leicht abgesenkt (ca. 1 m) und besteht aus einem überwiegend feuchten, organischen Boden, während in den übrigen Bereichen lehmig-sandige Böden dominieren. In einigen Bereichen beträgt der Sandanteil bis zu 95 %, in anderen der Tonanteil bis zu 20 %. Auf der Fläche wurden 38 Parzellen abgegrenzt, auf denen bis zu 3 Teilparzellen mit unterschiedlichen Schnittintervallen (1-3 Schnittnutzung) angelegt wurden. Dort wurden vor jedem Schnitt Vegetationsparameter wie Biomasse, Höhe oder Artenzusammensetzung erfasst. Außerdem wurden zwei Grundwasserpegellogger installiert.

Auf neun Parzellen wurden Sensorknoten installiert (Abb. 8, blaues Dreieck). An diesen Knoten wurden u.a Luftfeuchtigkeit, Temperatur und Lichteinstrahlung gemessen und sie sind dank einer Solarzelle energetisch autark. Die Daten von diesen neun Knoten werden drahtlos an ein größeres Gateway (Abb. 8, rotes Sechseck) übertragen. Dieses sammelt die Daten und überträgt sie dann drahtlos an den DAKIS Server. An vier dieser Sensorknoten wurden auch Mikrofonlogger zur bioakustischen Aufzeichnung installiert (Abb. 8, M_1 bis M_4).




Abbildung 8: Versuchsstandort in Mühlent Beck mit Lage der Probepunkte und Sensorknoten

Die Übersicht über die Korrelationen (Abbildung 9) veranschaulicht die Signifikanz der Beziehung zweier Variablen zueinander, sowie der Richtung der Beziehung (positive (blau) oder negative (rot)). Abbildung 10 zeigt, dass keine Bodeneigenschaft, mit Ausnahme von Kohlenstoff „C“ ($r=0,44$) und Stickstoff „N“ ($r=0,46$) (Abbildung 9 A, B) die im ersten Schnitt positiv korrelieren, einen signifikanten Einfluss auf die Artenzahl hat. Im Gegensatz dazu bestehen bei der Trockenmasse (Abbildung 9 A, B, D, „TM_g“) signifikante Einflüsse, die je nach Schnitt und Bodentiefe mit verschiedenen Bodeneigenschaften korrelieren. Die Eigenschaften des Bodenprofils weisen im ersten Schnitt mehr signifikante Korrelationen mit der Trockenmasseproduktion auf, als die Eigenschaften des ersten Horizontes. So sind neben der einzigen negativ korrelierenden Variable Kies („Gravel“- $0,59$) und dem positiv korrelierenden Kohlenstoff „C“ ($r=0,43$) bzw. Stickstoff „N“ ($r=0,44$) noch der pH-Wert („PH1m“) ($r=0,38$) und der Schluffgehalt im Bodenprofil („Schluffprofil“) ($r= 0,50$) signifikant und korrelieren ebenfalls positiv (Abbildung 9 A, B).

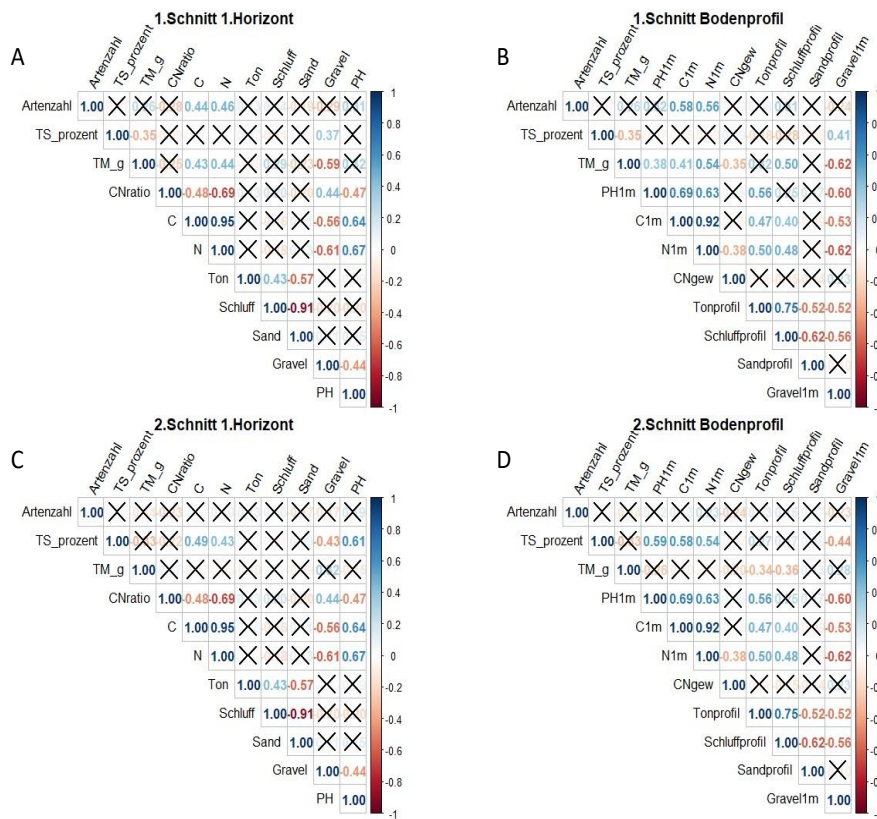


Abbildung 9: Korrelationen zwischen Bodeneigenschaften im 1. Bodenhorizont (A und C) und im gesamten Bodenprofil (1m Tiefe, B und D) sowie mit der floristischen Biodiversität und der Graströckemasse (g/m²). Farbe = Richtung des Zusammenhangs (Blau=positive Korrelation, Rot=negative Korrelation); Zahlen: 1 = starke Korrelation, 0= keine Korrelation, durchgestrichene Felder = p>0,05 = Korrelation nicht signifikant.

Auf der Versuchsfläche befindet sich ein Sensornetz mit neun Sensorknoten zur Aufzeichnung von Wetter- und Bodenfeuchtigkeitsdaten (Abbildung 10). In einem ersten Schritt wurden an vier dieser neun Sensorknoten Mikrofonlogger (Song Meter Mini, Wildlife Acoustics, Inc., USA) angebracht, die stündlich zwischen Sonnenaufgang und Sonnenuntergang für 10 Minuten akustische Signale in einem breiten Frequenzspektrum aufzeichnen und speichern. Die Knoten wurden so konzipiert, dass sie flexibel installiert und entfernt werden können, um ein reibungsloses Management zu ermöglichen. Insgesamt wurden mit den Mikrofonen zwischen Mai und September über 90 Gigabyte an Rohdaten gesammelt. Die Rohdaten wurden auf diese Weise auch für eine mögliche Weiterverwendung gespeichert, um beispielsweise bei Ausreißern die entsprechenden Tonaufnahmen abhören zu können oder um langfristig weitere

Untersuchungen, wie die Artenerkennung mittels künstlicher Intelligenz, durchführen zu können. Auf dieser Basis wurden 2024 Mikrofonlogger-Prototypen (Abbildung 11) entwickelt, auf die aus der Ferne zugegriffen werden konnte und die es ermöglichten, Aufzeichnungsauslöser mit Ereignissen im Sensornetzwerk zu verknüpfen (z.B. „Temperatur über 20°C“). Darüber hinaus wurden die Daten des Vorjahres anhand verschiedener bioakustischer Indizes analysiert, um festzustellen, ob es räumliche, zeitliche und Unterschiede zwischen den verschiedenen Indizes gibt.




Abbildung 10: Ein speziell vom DAKIS Verbundpartner IHP entwickelter Prototyp eines Mikrofon-Loggers. Basierend auf dem Song Meter Mini von Wildlife Accoustics. Weiterentwicklung in folgenden Punkten: Solarbetrieb statt Batterie, Halterung, Witterungsbeständigkeit, SIM-Karte und Netzzugang.

Es wurde festgestellt, dass es räumliche (zwischen Loggern), zeitliche (zwischen Monaten) und indexbasierte Unterschiede gibt (Abb. 12). Die Muster bestätigen, dass die Bioakustik auf der Grundlage eines Sensornetzwerks in der Lage ist Unterschiede in der faunistischen Biodiversität zwischen Teilflächen zu identifizieren. Sie sind ein Indiz dafür, dass die noch relativ unerforschten akustischen Indizes für das Verständnis der faunistischen Aktivität relevant sein können.




Abbildung 11: Zeitliche und räumliche Unterschiede in der Bioakustik, getrennt nach verschiedenen Biodiversitätsindizes im Jahr 2023. Das Signifikanzniveau gibt an, ob sich die entsprechenden Logger signifikant voneinander unterscheiden. Farben von rot: hochsignifikanter Unterschied ($p < 0,001$) bis gelb: kaum signifikant ($p < 0,05$) und grau: nicht signifikant ($p > 0,05$). Es fällt auf, dass es deutliche Unterschiede in den Mustern gibt, je nachdem, welcher Index verwendet wurde.

Schlussbericht

Abschließend wurde als Grundlage für die Abschätzung der Futterqualität der Grasbiomasse mittels Fernerkundung ein Übersichtspapier verfasst. Im Wesentlichen konnte gezeigt werden, dass in fast 2/3 der veröffentlichten Studien (insgesamt 32) für die Bestimmung des Stickstoffgehalts in der Grastroockenmasse multiple Regressionsmodellen herangezogen wurde (Abbildung 12). Die Qualität der Abschätzung durch Methoden des maschinellen Lernens (am Beispiel von r^2 und RMSE %) sind jedoch deutlich geringeren Schwankungen unterworfen und können daher als generell genauer bezeichnet werden.

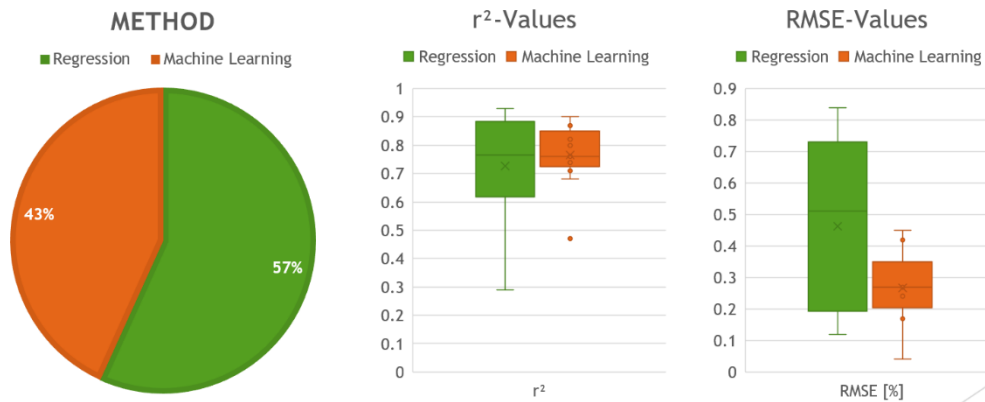


Abbildung 12: Links: Die Verteilung zwischen den für die Stickstoff (N)-Schätzung verwendeten Modellierungsmethoden. Mitte: Boxplots aller in den Studien identifizierten signifikanten r^2 -Werte der N-Schätzung (n: 21 und 14; Regression und maschinelles Lernen). Rechts: Boxplots aller signifikanten RMSE-Werte der N-Schätzung, die in den Studien identifiziert wurden (n: 16 und 13, Regression und maschinelles Lernen).

Bei der Schätzung des Rohproteins ergibt sich aus den in den veröffentlichten Studien gewählten Methoden ein noch deutlicheres Bild (Abb. 13). Fast 70 % der Ergebnisse wurden mit klassischen Regressionsmodellen erzielt (insgesamt 20 Arbeiten), wie multiple lineare Regressionen. Die Streuung der Genauigkeitsparameter r^2 und RMSE ist bei diesen Modellen deutlich größer als bei den Ansätzen des maschinellen Lernens. Im Gegensatz zur Schätzung des Stickstoffgehalts ist der r^2 -Mittelwert der Ergebnisse des maschinellen Lernens nun auch höher als bei Anwendung von Regressionsmodellen.




Abbildung 13: Links: Die Verteilung zwischen den für die Schätzung des Rohproteins (CP) verwendeten Modellierungsmethoden. Mitte: Boxplots aller in den Studien identifizierten signifikanten r^2 -Werte der CP-Schätzung (n: 14 und 7; Regression und maschinelles Lernen). Rechts: Boxplots

aller signifikanten RMSE-Werte der CP-Schätzung, die in den Studien identifiziert wurden (n: 11 und 6, Regression und maschinelles Lernen). Ein deutlicher Ausreißer (11,7 %), sowie nRMSE-Werte und RMSE als kg/ha wurden hier ausgeschlossen.

AP3.2 Simulation und Prognose von ertragsrelevanten Prozessen, Stoffflüssen und ÖSL

Im Teilprojekt TP3 (Optimierung der Anbau- und Betriebsplanung) hatte das Arbeitspaket AP3.2 (Echtzeitsimulation und Quantifizierung von ÖSL / Biodiversität) die Aufgabe, auf Ebene der durch DAKIS definierten Landschaftsfenster bzw. auf Ebene der Landkreise, in den sich die Landschaftsfenster befanden, model-basierte Aussagen über verschiedene Ökosystemleistungen (ÖSL) im Ackerbau zu treffen. Dazu wurde eine Modellsolution im SIMPLACE Modelling Framework (simpplace.net) entwickelt und auf regionaler Ebene angewendet, um die zeitliche und räumliche Dynamik von ausgewählten ÖSL wie Biomasseerträge, Kornerträge und Reduktion der Nitratauswaschung im Boden in möglichst hoher Auflösung zu simulieren. Abbildung 14 zeigt die Lage der DAKIS Landschaftsfenster in Brandenburg.

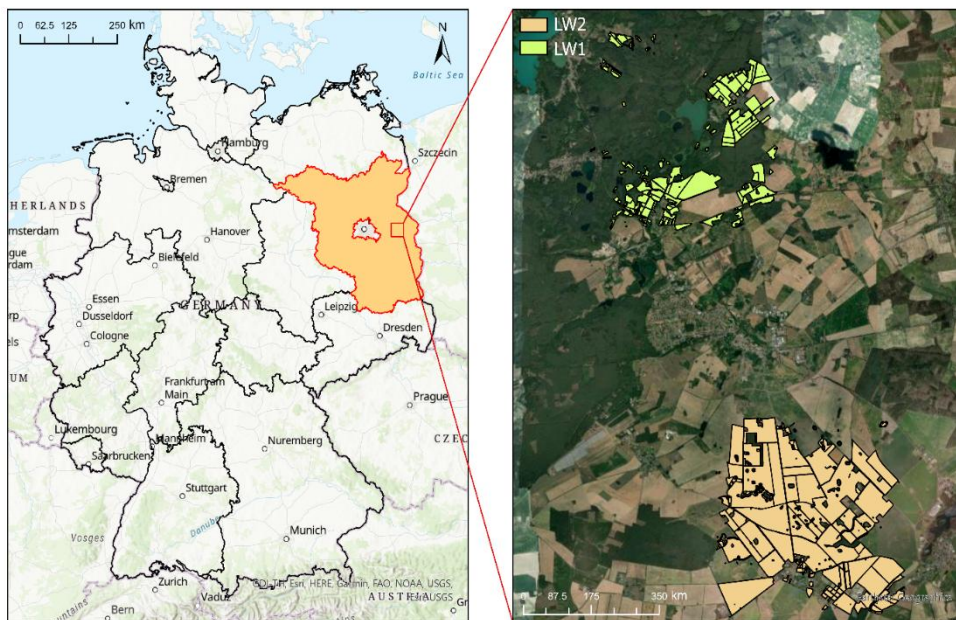


Abbildung 14: Lage der DAKIS Landschaftsfenster in Brandenburg in den Landkreisen Märkisch Oderland bzw. Oder-Spree

Die in Abbildung 15 dargestellten Karten zeigen die simulierten Kornerträge von Winterweizen für zwei kontrastierende Landschaftsfenster, LW1 und LW2, in der Region Brandenburg im Nordosten Deutschlands. In LW1 liegen die simulierten Weizenenerträge zwischen 3,4 und 4,4 t ha⁻¹ in einer komplexen und heterogenen Landschaft, die aus Mischwäldern, Feuchtgebieten und fragmentierten kleinen bis mittelgroßen landwirtschaftlichen Feldern besteht. Die Ertragsvariabilität in LW1 ist beträchtlich, wobei in der Nähe von Wäldern und Gewässern häufig lokale Produktivitätssteigerungen zu beobachten sind, die wahrscheinlich auf günstige mikroklimatische Einflüsse und eine verbesserte Verfügbarkeit von Bodenfeuchtigkeit zurückzuführen sind. Im Gegensatz dazu weist LW2 eine höhere und konstantere Ertragsspanne von 5,2 bis 6,2 t ha⁻¹ auf, was auf eine einheitlichere landwirtschaftliche Struktur mit großen, zusammenhängenden Feldern und minimaler Landschaftsfragmentierung sowie unterschiedliche Bodenverbreitung, zurückzuführen sein könnte. Die höhere Produktivität in LW2 ist wahrscheinlich auf eine verbesserte Bodenfruchtbarkeit, gleichmäßigere Feldbedingungen und intensivere Landbewirtschaftungsmethoden zurückzuführen.

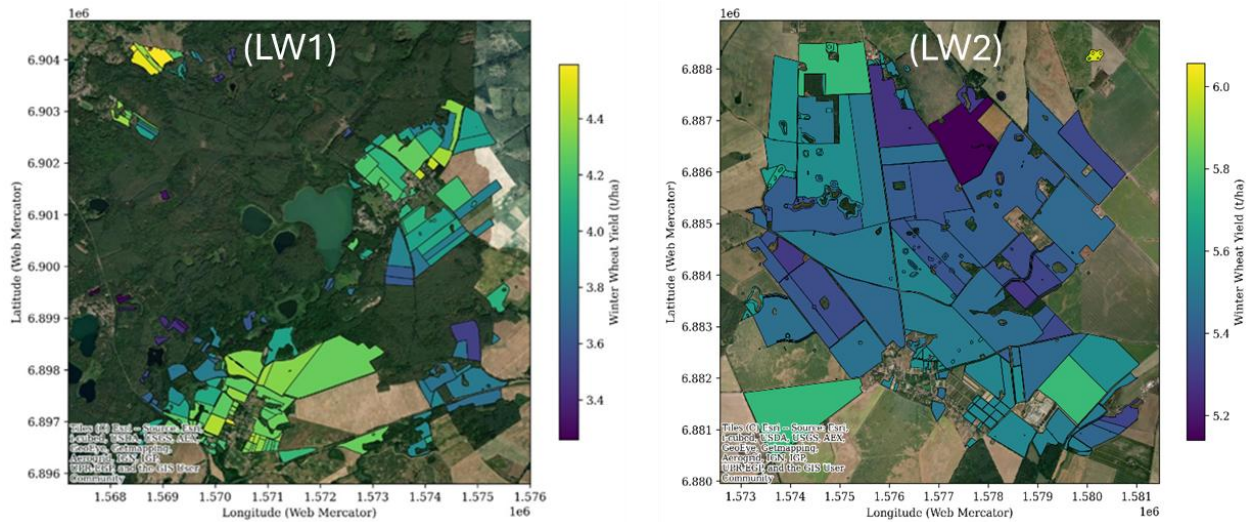


Abbildung 15: Simulierte Winterweizenträge ($t\ ha^{-1}$) für die zwei DAKIS Landschaftsfenster (LW1 und LW2) in Brandenburg: LW1 (links) und LW2 (rechts).

Ergänzend zu dieser Analyse zeigt Abbildung 16 langfristig simulierte Winterweizenträge (gemittelt über den Zeitraum 2000-2021) in den Landkreisen Märkisch-Oderland und Oder-Spree in Brandenburg. Die Ertragswerte reichen von etwa $3,2\ t\ ha^{-1}$ (dunkelviolet) bis $5,2\ t\ ha^{-1}$ (gelb), wobei jedes farbige Polygon eine einzelne landwirtschaftliche Parzelle darstellt. Die Karte deckt einen geografischen Bereich zwischen etwa $52,3^\circ$ und $52,8^\circ$ nördlicher Breite und $13,6^\circ$ bis $14,6^\circ$ östlicher Länge ab. Die räumliche Analyse zeigt ein deutliches Nord-Süd-Gefälle in der Produktivität, mit höheren Erträgen entlang der nördlichen Grenze - die mit den fruchtbaren Schwemmlandböden des Odertals zusammenfällt -, während niedrigere Erträge in den zentralen und südwestlichen Teilen der Region vorherrschen, wo sandige Böden und Moorlandschaften natürliche Grenzen für die Ernteleistung setzen. Diese räumlichen Muster unterstreichen den Einfluss der topografischen und edaphischen Heterogenität auf die regionale landwirtschaftliche Produktivität.

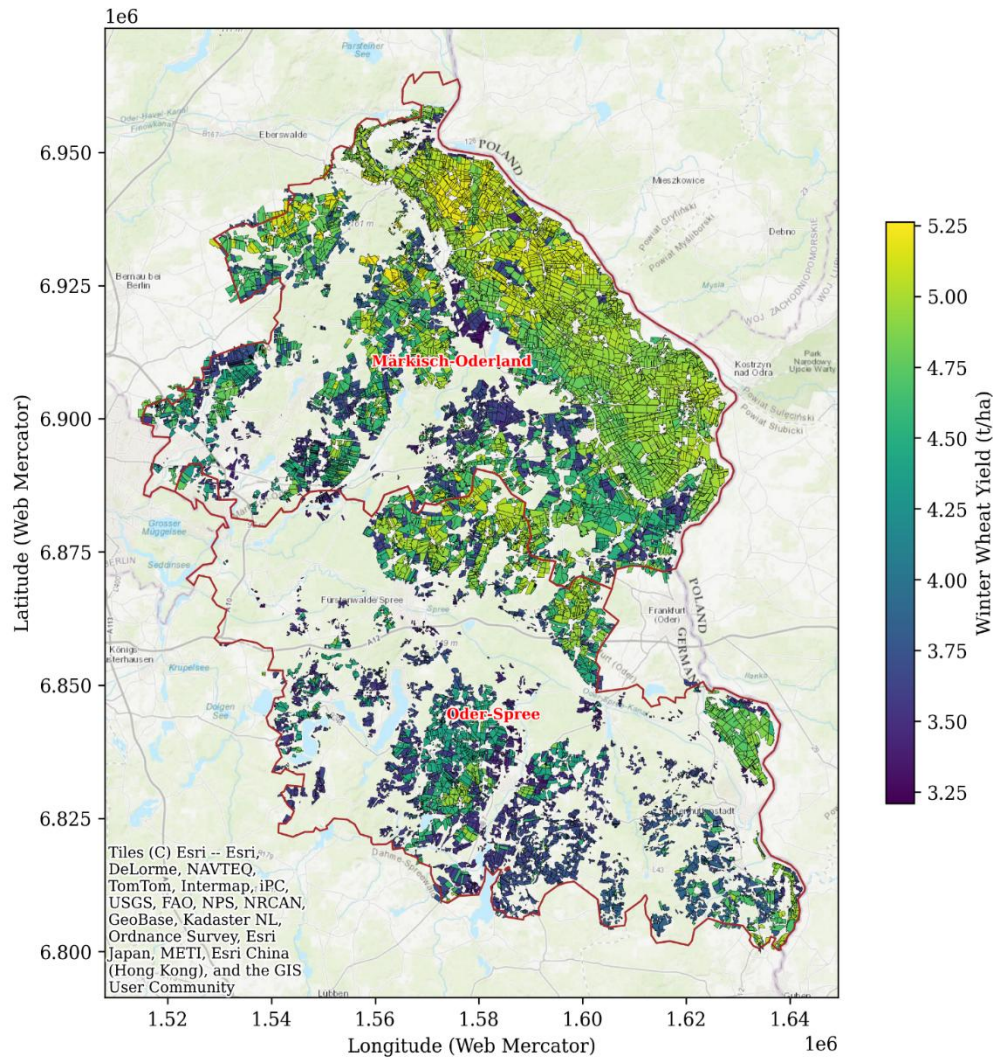


Abbildung 16:
Modellbasierte
schlagspezifische
Abschätzungsmittlere
Winterweizenerträge
(t ha⁻¹) über 22
Jahre (2000-2021) in
den Landkreisen
Märkisch-Oderland
und Oder-Spree

Tabelle 2: Zusammenhang der modell-basierten, mittleren Ökosystemleistungen (ÖSL) über einen Zeitraum von 22 Jahren (2000–2021), einschließlich der Standardabweichungen, für sechs Ackerkulturen Sommergerste, Silomais, Wintergerste, Winterraps, Winterweizen und Zuckerrüben über zwei Landkreise (Märkisch-Oderland (MOL) und Oder-Spree (LOS)) in Brandenburg.

District	Crop	Average Yield (DM) (t/ha)	STD	Average total Biomass (t/ha)	STD	Nitrate Leaching (kg/ha)	STD
LOS							
	Spring Barley	3,2	1,3	7,3	2,2	59,0	41,1
	Silage Maize	20,5	9,2	11,8	4,0	256,9	121,5
	Winter Barley	4,3	2,0	12,1	3,1	164,2	105,4
	Winter Rape	3,0	0,8	14,1	3,3	53,6	50
	Winter Wheat	4,0	1,4	11,7	2,9	117,5	60,9
	Sugarbeet	10,6	5,3	13,0	6,5	156,6	91,7
MOL							
	Spring Barley	3,6	1,4	8,3	2,2	54,6	40,2
	Silage Maize	22,3	9,6	12,9	3,9	245,0	176,7
	Winter Barley	4,6	2,0	12,9	3,2	150,2	158,2
	Winter Rape	3,1	0,8	14,8	3,6	49,4	67,1
	Winter Wheat	4,5	1,6	13,0	3,1	103,9	82,5
	Sugarbeet	12,7	5,2	15,7	6,3	129,2	96,3

2.2 Voraussichtlicher Nutzen und Fortschreibung des Verwertungsplans

Das zentrale Produkt des Projektes DAKIS ist ein digitales „Entscheidungsunterstützungssystem“ (EUS), welches auf Echtzeitinformationen von Sensoren und Modellen basiert und hierdurch eine diversifizierte und kleinskalige Landnutzung ermöglicht. ÖSL und Biodiversität bekommen durch das EUS einen ökonomischen Wert. Ferner schafft es Anreize für neue Kooperationen zwischen den Landwirten. Zu diesem Produkt hat die Universität Bonn über mehr als 5 Jahre durch intensive Erhebungen in Acker- und Grünlandgebieten sowie durch Erstellung eines prozess-basierten Simulationsmodells beigetragen, das in der Lage ist regionale raumzeitliche Veränderungen der Erträge verschiedener Kulturpflanzen sowie damit verbundener weiteren ÖSL zu quantifizieren. Die Methoden und Ergebnisse, die vom Verbundpartner Universität Bonn entwickelt wurden, sollen die Weiterentwicklung des EUS im Folgeprojekt DAKIS-Pro (DAKIS2) unterstützen.

2.3 Während des Vorhabens bekannt gewordener Fortschritt auf dem Gebiet des Vorhabens

Keiner

2.4 Erfolgte oder geplante Veröffentlichung der Ergebnisse

Die folgenden Tabellen fassen die Arbeiten zusammen, die auf den Ergebnissen dieses Vorhabens basieren, geordnet nach Arbeiten, die bereits veröffentlicht (Tabelle 4), in Begutachtung (Tabelle 5) oder in Vorbereitung (Tabelle 6) sind.

Tabelle 3: Liste der veröffentlichten wissenschaftlicher Artikel durch die Universität Bonn im Rahmen des DAKIS Projektes

Nr.	Veröffentlichungen in Zeitschriften mit Peer-Review Prozess
1-	Bazzo, Clara Oliva Gonçalves, Bahareh Kamali, Dominik Behrend, Hubert Hueging, Inga Schleip, Paul Mosebach, Almut Haub, Axel Behrendt, Thomas Gaiser (2024): Assessing the Effect of Field Disturbances on Biomass Estimation in Grasslands using UAV-Derived Canopy Height Models. PFG – Journal of Photogrammetry Remote Sensing and Geoinformation Science 93:37–49. https://doi.org/10.1007/s41064-024-00322-x
2-	Bazzo, Clara Oliva Gonçalves, Bahareh Kamali, Murilo dos Santos Vianna, Dominik Behrend, Hubert Hueging, Inga Schleip, Paul Mosebach, Almut Haub, Axel Behrendt, Thomas Gaiser (2024): Integration of UAV-sensed features using machine learning methods to assess species richness in wet grassland ecosystems. Ecological Informatics (2024): 102813
3-	Bazzo, Clara Oliva Gonçalves, Bahareh Kamali, Christoph Hütt, Georg Bareth, Thomas Gaiser (2023): A Review of Estimation Methods for Aboveground Biomass in Grasslands Using UAV. Remote Sensing 15(3):639. https://doi.org/10.3390/rs15030639
4-	Mouratiadou, I., N. Lemke, C. Chen, A. Wartenberg, R. Bloch, M. Donat, T. Gaiser, et al. (2023): The Digital Agricultural Knowledge and Information System (DAKIS): Employing digitalisation to encourage diversified and multifunctional agricultural systems. Environmental Science and Ecotechnology, 16:100274. DOI: https://doi.org/10.1016/j.es.2023.100274
4-	Mohr, J.; Tewes, A.; Ahrends, H.; Gaiser, T. (2023): Assessing the Within-Field Heterogeneity Using Rapid-Eye NDVI Time Series Data. Agriculture 13:1029. https://doi.org/10.3390/agriculture13051029

Schlussbericht

- 5 Raza, A., H. Ahrends, M. Habib-Ur-Rahman and T. Gaiser (2021): Modeling Approaches to Assess Soil Erosion by Water at the Field Scale with Special Emphasis on Heterogeneity of Soils and Crops. *Land* 10 (4):422
- 6 Raza, A., M. d. S. Vianna, S. H. Ahmadi, M. Habib-ur-Rahman, T. Gaiser (2024): Comparison of predictive modeling approaches to estimate soil erosion under spatially heterogeneous field conditions. *Environmental Modelling & Software* 180: 106145
- 7 Raza, A., H. Ahrends, M. Habib-ur-Rahman, H. Hüging and T. Gaiser (2022): Using the Taguchi experimental design for assessing within-field variability of surface run-off and soil erosion risk. *Science of The Total Environment* 828:154567.
- 8 Rahman, M. H. u., H. E. Ahrends, A. Raza and T. Gaiser (2023): Current approaches for modeling ecosystem services and biodiversity in agroforestry systems: Challenges and ways forward. *Frontiers in Forests and Global Change* 5: 1032442. <https://doi.org/10.3389/ffgc.2022.1032442>.
- 9 Rahman, M. H. u., A. Raza, H. E. Ahrends, H. Hüging and T. Gaiser (2021): Impact of in-field soil heterogeneity on biomass and yield of winter triticale in an intensively cropped hummocky landscape under temperate climate conditions. *Precision Agriculture* 23: 912–938.

3 Literaturverzeichnis

- Bazzo, C.O.G. (2025) GRASSLAND ECOSYSTEM ASSESSMENTS: INTEGRATING UAV-DERIVED FEATURES FOR ABOVEGROUND BIOMASS ESTIMATION. *Information processing in Agriculture*. In Review
- Bazzo, C.O.G., B. Kamali, M. dos Santos Vianna, D. Behrend, H. Hueging, I. Schleip, T. Gaiser (2024): Integration of UAV-sensed features using machine learning methods to assess species richness in wet grassland ecosystems. *Ecological Informatics* 83:102813
- EPRS (2016): Precision agriculture and the future of farming in Europe. *Scientific Foresight Study*. European Parliamentary Research Service, Science and Technology Options Assessment. 42p. doi: 10.2861/020809
- Gandorfer, M., Hoffmann, C., El Benni, N., Cockburn, M., Anken, T., Floto, H. (Hg.) (2022): Informatik in der Land-, Forst- und Ernährungswirtschaft. Fokus: Was bedeutet Künstliche Intelligenz für Agrar- und Ernährungswirtschaft? : Referate der 42. GIL-Jahrestagung 21.- 22. Februar 2022, Agroscope, Tänikon, Ettenhausen, Schweiz (virtuell). Gesellschaft für Informatik; Gesellschaft für Informatik in der Land-, Forst- und Ernährungswirtschaft. Bonn: Gesellschaft für Informatik (GI-Edition. Proceedings, volume P-317). Online verfügbar unter <https://gil-net.de/wp-content/uploads/2022/02/GIL-Tagungsband2022.pdf>.
- Khanna, M., Chen, L., Basso, B., Cai, X., Field, J. L., Guan, K. et al. (2021): Redefining marginal land for bioenergy crop production. In: *GCB Bioenergy* 13 (10), S. 1590–1609. DOI: 10.1111/gcbb.12877.
- Mohr, J., A. Tewes, H. Ahrends and T. Gaiser (2023): Assessing the Within-Field Heterogeneity Using Rapid-Eye NDVI Time Series Data. *Agriculture* 13(5):1029
- Porter, M., Heppelmann, J. (2014): Wie smarte Produkte den Wettbewerb verändern. In: *Harvard Business manager* (12). Sonderdruck. 28p.
- Raza, A., M. d. S. Vianna, S. H. Ahmadi, M. Habib-ur-Rahman and T. Gaiser (2024): Comparison of predictive modeling approaches to estimate soil erosion under spatially heterogeneous field conditions. *Environmental Modelling & Software* 180: 106145
- Raza, A., H. Ahrends, M. Habib-ur-Rahman, H. Hüging and T. Gaiser (2022): Using the Taguchi experimental design for assessing within-field variability of surface run-off and soil erosion risk. *Science of The Total Environment* 828:154567.
- Techen A, Helming K. (2017): Pressures on soil functions from soil management in Germany. A foresight review. *Agron. Sustain. Dev.* 37:64. 29p. doi: 10.1007/s13593-017-0473-3.
- Von Löbbecke, M. & Krudewig, K.-H. (2015): Big Data, Landwirtschaft 4.0 & Precision Farming – wo geht die Reise hin?. Vortrag 365FarmNet.

Schlussbericht

- Weltzien, C. (2016): Digitale Landwirtschaft – oder warum Landwirtschaft 4.0 auch nur kleine Brötchen backt. In: Landtechnik 71 (2). pp. 66-68. doi: 10.15150/lt.2015.3123.
- Wegener, J.; Urso, L.-M.; von Hörsten, D.; Minßen, T.-F.; Gaus, C.-C. (2017): Developing new cropping systems – which innovative techniques are required? Landtechnik 72, 91-100
- Wolfert, S., Ge, L., Verdouw, C., Bogaardt, M.-J. (2017): Big Data in Smart Farming – A review. In: Agricultural Systems 153, S. 69–80. DOI: 10.1016/j.agsy.2017.01.023.