

Gefördert durch



Bundesministerium  
für Ernährung  
und Landwirtschaft

aufgrund eines Beschlusses  
des Deutschen Bundestages

Projektträger



Bundesanstalt für  
Landwirtschaft und Ernährung



**Fraunhofer**  
IAIS

FRAUNHOFER-INSTITUT FÜR INTELLIGENTE ANALYSE- UND INFORMATIONSSYSTEME IAIS

# **X-KIT: WHITEPAPER PFLANZENSCHUTZ**

Whitepaper des X-KIT Cluster Pflanzenschutz

# X-KIT: WHITEPAPER PFLANZENSCHUTZ

## X-KIT: Gaia-X und KI-Projekte: Transfer & Vernetzung

<b>Autor</b>	<b>Projekt</b>	<b>Institution</b>	<b>E-Mail</b>
Lorenz Wickert	X-KIT	Fraunhofer IAIS <sup>1</sup>	<a href="mailto:Lorenz.Wickert@iais.fraunhofer.de">Lorenz.Wickert@iais.fraunhofer.de</a>
Stefan Rilling	X-KIT	Fraunhofer IAIS <sup>1</sup>	<a href="mailto:Stefan.Rilling@iais.fraunhofer.de">Stefan.Rilling@iais.fraunhofer.de</a>
Wolfgang Jarausch	PhenoTruck	RLP AgroScience GmbH <sup>2</sup>	<a href="mailto:wolfgang.jarausch@agrosience.rlp.de">wolfgang.jarausch@agrosience.rlp.de</a>
Bonito Thielert	PhenoTruck	Fraunhofer IFF <sup>3</sup>	<a href="mailto:bonito.thielert@iff.fraunhofer.de">bonito.thielert@iff.fraunhofer.de</a>
Christoph v. Redwitz	BETTER-WEEDS	Julius Kühn-Institut <sup>4</sup>	<a href="mailto:christoph.redwitz@julius-kuehn.de">christoph.redwitz@julius-kuehn.de</a>
Michael Schirrmann	Weed-AI-Seek	Leibniz-Institut ATB <sup>5</sup>	<a href="mailto:mschirrmann@atb-potsdam.de">mschirrmann@atb-potsdam.de</a>
Oliver Schmittmann	WeedAI	ILT Universität Bonn <sup>6</sup>	<a href="mailto:o.schmittmann@uni-bonn.de">o.schmittmann@uni-bonn.de</a>
Patrick Zimmer	WeedAI	ILT Universität Bonn <sup>6</sup>	<a href="mailto:patrick.zimmer@uni-bonn.de">patrick.zimmer@uni-bonn.de</a>
Christoph F. Kämpfer	BETTER-WEEDS	Julius Kühn-Institut <sup>4</sup>	<a href="mailto:christoph.kaempfer@julius-kuehn.de">christoph.kaempfer@julius-kuehn.de</a>
Patrick Mäder	BETTER-WEEDS	TU Ilmenau <sup>7</sup>	<a href="mailto:patrick.maeder@tu-ilmenau.de">patrick.maeder@tu-ilmenau.de</a>
Martin Rabe	BETTER-WEEDS	TU Ilmenau <sup>7</sup>	<a href="mailto:martin.rabe@tu-ilmenau.de">martin.rabe@tu-ilmenau.de</a>
Jonas Hüther	BETTER-WEEDS	TU Ilmenau <sup>7</sup>	<a href="mailto:jonas.huether@tu-ilmenau.de">jonas.huether@tu-ilmenau.de</a>
Michael Niedermeier	Kldetect	FORWISS <sup>8</sup>	<a href="mailto:niedermeie@forwiss.uni-passau.de">niedermeie@forwiss.uni-passau.de</a>
Faryal Noori	Kldetect	FORWISS <sup>8</sup>	<a href="mailto:noori@forwiss.uni-passau.de">noori@forwiss.uni-passau.de</a>

<b>Institution</b>	<b>Adresse</b>	<b>URL</b>
1 Fraunhofer-Institut für Intelligente Analyse- und Informationssysteme IAIS	Schloss Birlinghoven 1 D-53757 Sankt Augustin	<a href="https://www.iais.fraunhofer.de/">https://www.iais.fraunhofer.de/</a>
2 RLP AgroScience GmbH	Breitenweg 71 D-67435 Neustadt/W.	<a href="http://www.agrosience.de">www.agrosience.de</a>
3 Fraunhofer Institut für Fabrikbetrieb und -automatisierung IFF	Sandtorstr. 22, D-39106 Magdeburg	<a href="http://www.iff.fraunhofer.de">http://www.iff.fraunhofer.de</a>
4 Julius Kühn-Institut (JKI), Bundesforschungsinstitut für Kulturpflanzen	Messeweg 11-12 D-38104 Braunschweig	<a href="http://www.julius-kuehn.de">www.julius-kuehn.de</a>
5 Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB)	Max-Eyth-Allee 100, D-14469 Potsdam	<a href="http://www.atb-potsdam.de">www.atb-potsdam.de</a>
6 Institut für Landtechnik Universität Bonn	Nußallee 5 D-53115 Bonn	<a href="http://www.landtechnik.uni-bonn.de">www.landtechnik.uni-bonn.de</a>
7 Technische Universität Ilmenau - Data-intensive Systems and Visualisation (dAI.SY)	Helmholtzplatz 5 (Zusebau) D-98693 Ilmenau	<a href="http://www.tu-ilmenau.de/daisy">www.tu-ilmenau.de/daisy</a>
8 FORWISS - Institut für Softwaresysteme in technischen Anwendungen der Informatik Universität Passau	Innstraße 43 D-94032 Passau	<a href="https://www.forwiss.uni-passau.de/de/">https://www.forwiss.uni-passau.de/de/</a>

Projektnummer: 28DK1VTC21

Datum: 16.10.2024

# Inhalt

<b>1</b>	<b>Einführung .....</b>	<b>4</b>
1.1	<i>X-KIT Cluster Pflanzenschutz.....</i>	4
1.2	<i>Problemstellung Pflanzenschutz.....</i>	4
1.3	<i>Warum KI?.....</i>	5
1.4	<i>Weiterer Aufbau des Whitepapers.....</i>	6
<b>2</b>	<b>Übersicht der Projekte .....</b>	<b>7</b>
2.1	<i>Projektbeschreibungen.....</i>	7
2.2	<i>Herausforderungen.....</i>	7
2.2.1	<i>Datengenerierung .....</i>	8
2.2.2	<i>Randbedingungen .....</i>	8
2.2.3	<i>Feature Engineering.....</i>	8
2.2.4	<i>Objekterkennung und Segmentierung .....</i>	8
2.2.5	<i>Interdisziplinarität.....</i>	9
<b>3</b>	<b>Lösungsansätze.....</b>	<b>11</b>
3.1	<i>Datenakquise und Sensorik.....</i>	11
3.1.1	<i>Auswahl von Sensorik und Aufnahmetechnik.....</i>	11
3.1.2	<i>Randbedingungen der Datenakquise.....</i>	12
3.1.3	<i>Modularisierung.....</i>	13
3.1.4	<i>Anwendungsfälle.....</i>	14
3.2	<i>Modellauswahl und Training .....</i>	15
3.2.1	<i>Machine Learning Workflow .....</i>	15
3.2.2	<i>Hyperspektraldatenanalyse.....</i>	17
3.2.3	<i>Randbedingungen des KI-Training: MLOps .....</i>	17
3.2.4	<i>Anwendungsfälle.....</i>	18
3.3	<i>Deployment und Integration.....</i>	21
3.3.1	<i>Edge Computing vs. Cloud Computing.....</i>	21
3.3.2	<i>Hardware .....</i>	22
<b>4</b>	<b>Fazit und Ausblick.....</b>	<b>24</b>
4.1	<i>Fazit und Ausblick für den Pflanzenschutz .....</i>	24
4.1.1	<i>Skalierung von Forschungsergebnissen in die Praxis.....</i>	24
4.1.2	<i>Wissenschaftliche Verwertung der Forschungsergebnisse.....</i>	25
4.2	<i>Fazit und Ausblick für KI-Projekte in der Landwirtschaft .....</i>	25
4.2.1	<i>Technisch und Fachlich.....</i>	25
4.2.2	<i>Organisatorisch.....</i>	28

# 1 Einführung

Das vorliegende Whitepaper ist im vom *Bundesministerium für Ernährung und Landwirtschaft (BMEL)* geförderten und der *Bundesanstalt für Landwirtschaft und Ernährung (BLE)* als Projektträger begleiteten Vernetzungs- und Transferprojekt X-KIT entstanden. Ziel des Projektes ist eine übergreifende Vernetzung und Unterstützung für die vom BMEL geförderten KI-Projekte zur Ernährungs- und Landwirtschaft sowie für den ländlichen Raum zu ermöglichen, sodass Synergieeffekte möglichst umfänglich genutzt und unkoordinierte Parallelentwicklungen und inkompatible Lösungen vermieden werden. Somit soll das Potenzial der Digitalisierung für die Ernährungs- und Landwirtschaft, gesundheitlichen Ernährung, sowie dem ländlichen Räumen bestmöglich ausgeschöpft werden. Zu diesem Zweck wurden in dem Projekt themenspezifische Cluster für eine gezieltere Vernetzung der Projekte und die Ermöglichung von Synergieeffekten aufgebaut. Der nachfolgende Bericht beschreibt die Projektergebnisse im fachlichen Cluster Pflanzenschutz.

## 1.1 X-KIT Cluster Pflanzenschutz

Im X-KIT Cluster Pflanzenschutz sind fünf Projekte vertreten, die im Folgenden vorgestellt werden: Durch die Integration von artspezifischen Eigenschaften in Managemententscheidungen wird im Projekt *BETTER-WEEDS* der Einsatz von Herbiziden auf kleinsten Teilflächen zwischen Nutzen und Schaden von Unkräutern abgewogen. Forschung zur Unkrauterkenennung im Anwendungsbereich Vertical Farming wird im Projekt *Kldetect* betrieben. Der *PhenoTruck*<sup>®</sup> ist ein mobiles Labor zur Erkennung von Schaderregern im Wein- und Obstbau, welches die Stärken von molekularen Verfahren, hyperspektrale Labormessungen und multispektrale Drohnenflüge direkt vor Ort am Feldrand kombiniert. Die Projekte *WeedAI* und *Weed-AI-Seek* entwickeln beide Lösungen zur Unkrauterkenennung via Drohne. Das Ziel von *WeedAI* ist dabei die Evaluation von Unkrautbekämpfungsmaßnahmen anhand von Drohnenbildern mit dem Ziel Prüfnormen für Geräte zur Unkrautbekämpfung zu entwickeln. Dahingegen werden Applikationskarten für das Herbizidmanagement in der Präzisionslandwirtschaft im Projekt *Weed-AI-Seek* erstellt. Eine detailliertere Vorstellung der Projekte erfolgt in Kapitel 2.

## 1.2 Problemstellung Pflanzenschutz

Effektiver Pflanzenschutz umfasst „eine Vielfalt von Maßnahmen und Aktivitäten, die alle ein Ziel verfolgen: Schäden an Kulturpflanzen zu verhindern oder zu mindern. Pflanzenschutz ist daher Voraussetzung und zugleich fester Bestandteil einer leistungsfähigen und nachhaltigen Pflanzen- und Lebensmittelherzeugung und Kulturlandschaft.“<sup>1</sup> Pflanzenschutzmaßnahmen werden für die meisten angebauten Pflanzen benötigt, denn; „Ob unter freiem Himmel oder im Gewächshaus: Pflanzen sind immer und überall gefährlichen Feinden ausgesetzt. Doch nicht nur Raupen, Käfer, Larven, Viren oder Pilzerkrankungen bedeuten eine Gefahr: Auch Unkräuter und Ungräser behindern vielfach das ungestörte Aufwachsen von Kulturpflanzen, da sie mit ihnen um Licht und Wasser konkurrieren.“<sup>2</sup> Dennoch bergen Pflanzenschutzmaßnahmen immer auch Risiken und sind potenziell schädlich für die Umwelt. Es ist daher wichtig, diese risikoreicher und nachhaltiger zu gestalten. Dieses Ziel hat auch der Nationale Aktionsplan zur nachhaltigen Anwendung von Pflanzenschutzmitteln<sup>3</sup>: Dessen Ziele sind das Reduzieren von Risiken, die

---

<sup>1</sup>[https://www.bmel.de/DE/themen/landwirtschaft/pflanzenbau/pflanzenschutz/pflanzenschutz\\_node.html](https://www.bmel.de/DE/themen/landwirtschaft/pflanzenbau/pflanzenschutz/pflanzenschutz_node.html)

<sup>2</sup><https://www.bauernverband.de/themendossiers/pflanzenschutz>

<sup>3</sup>[https://www.ble.de/SharedDocs/Downloads/DE/Landwirtschaft/Pflanzenschutz/FlyerNAP.pdf;jsessionid=713F6385E7CD9473B9A4F1F39049F2A3.internet002?\\_blob=publicationFile&v=2](https://www.ble.de/SharedDocs/Downloads/DE/Landwirtschaft/Pflanzenschutz/FlyerNAP.pdf;jsessionid=713F6385E7CD9473B9A4F1F39049F2A3.internet002?_blob=publicationFile&v=2)

durch die Anwendung von Pflanzenschutzmitteln für den Naturhaushalt entstehen können, das Senken von Rückstandshöchstgehaltsüberschreitungen in allen Produktgruppen einheimischer und importierten Lebensmitteln, das Begrenzen der Pflanzenschutzmittelanwendung, die Förderung der Einführung und Weiterentwicklung von Pflanzenschutzverfahren mit geringerem Pflanzenschutzmittel-Anwendungen sowie die Verbesserung der Information der Öffentlichkeit über Nutzen und Risiken des Pflanzenschutzes.

### 1.3 Warum KI?

Die Land- und Ernährungswirtschaft steht aktuell vor der Herausforderung unterschiedliche Nachhaltigkeitsziele wie ressourcenschonende Bewirtschaftung landwirtschaftlicher Nutzflächen, angemessene Umsetzung von Tierwohlstandards, transparente Wertschöpfungsketten oder Reduzierung negativer Umwelteffekte zu erreichen. Gleichzeitig rücken auch in der Landwirtschaft Themen wie Versorgungssicherheit, resiliente Lieferketten und effiziente Verteilung sowohl regional wie auch global produzierter Nahrungsmittel und für die Produktion notwendiger Ressourcen wieder verstärkt in den Vordergrund. Dem liegt neben dem Klimawandel zu Grunde, dass immer weniger Menschen Nahrungsmittel für immer mehr Menschen produzieren. Konsens besteht darin, dass die Digitalisierung in der Land- und Ernährungswirtschaft eine Schlüsselrolle für die Erreichung der Nachhaltigkeitsziele einnehmen kann, wobei für neu eingeführte Technologien grundlegend der Aufwand gegen den Ertrag der Technologie abgeschätzt werden muss. Unter diesem Gesichtspunkt bietet der Einsatz von KI-Technologien Potenziale für die Erreichung der gesteckten Ziele, wie sich in den Projekten des X-KIT Cluster Pflanzenschutz auf mannigfaltige Weise zeigt.

Primär kann durch den Einsatz von KI-Methoden ein hohes Automatisierungspotential von verschiedenen landwirtschaftlichen Tätigkeiten im Bereich Pflanzenschutz erreicht werden. So wird im Projekt *BETTER-WEEDS* ein automatisiertes Unkrauthebungsverfahren entwickelt, bei dem die Unkrautart und deren Eigenschaften berücksichtigt werden, um Landwirte in ihrer Entscheidungsfindung hinsichtlich der Unkrautkontrolle zu unterstützen. Auch das *PhenoTruck*<sup>®</sup> Labor ermöglicht die Automatisierung diverse Arbeitsschritte im Pflanzenschutz: Das System ermöglicht es Felder digital einzumessen, per Fernerkundung die Entwicklung von Pflanzen auf dem Feld digital zu monitoren, Risikobereiche für kritische Stressfaktoren zu identifizieren, das Bonitieren vor Ort mit digitalen Techniken zu unterstützen, Blattproben hyperspektral zu untersuchen und den Nachweis von spezifischen Krankheiten mittels molekularer Techniken zu erbringen. Auf diese Weise können Schaderreger schneller erkannt, Fachpersonal unterstützt und Gegenmaßnahmen schneller ergriffen werden. Im Projekt *WeedAI* wird die Automatisierung von Bonituren zur Bewertung von Unkrautbekämpfungsmaßnahmen anhand von Drohnenbildern verfolgt. Durch die Verwendung von KI sind deutlich umfassendere, qualitativ hochwertigere sowie objektive Untersuchungen und Aussagen möglich. Ziel ist sowohl den Erfolg von Strategien oder Maßnahmen zur Unkrautbekämpfung zu bewerten als auch die Prüfnormen für Geräte zur Unkrautbekämpfung zu entwickeln.

Aus dem primären Nutzen der angewandten KI-Methoden ergeben sich einige weitere Vorteile für die Endanwender. Mithilfe neuer Methoden lassen sich Zeit- und Kosteneinsparungen in der alltäglichen Arbeit erreichen. So wird eine deutliche Zeitersparnis bei der Feststellung der vorhandenen Verunkrautung eines Feldes als auch eine höhere räumliche Auflösung der Unkrautverteilung auf diesem im Projekt *BETTER-WEEDS* erreicht. Einen ähnlichen Ansatz verfolgt das Projekt *Weed-AI-Seek*, in dem eine Reduzierung der Kosten durch den selektiven und teilflächenspezifischen Einsatz von Pflanzenschutzmitteln auf Grundlage einer drohnenbasierten Onlinekartierung der Verunkrautung erzielt wird. Auch im Projekt *WeedAI* soll der Arbeitsaufwand der manuellen, stichprobenbasierten Versuchsbonitur minimiert werden, bei gleichzeitiger Verbesserung der Qualität. Herbizidversuche oder Techniktests beispielsweise bei der Geräteentwicklung können umfangreicher und schneller durchgeführt werden, was zu einem schnelleren

Erkenntnisgewinn oder einer schnelleren Technikverbesserung führt. Die Einsparungen von Pflanzenschutzmitteln kann auch im Projekt *Kldetect* erreicht werden, hier jedoch durch die Optimierung der mechanischen Beikrautregulierung. Der *PhenoTruck*<sup>®</sup> führt zu Kosten- und Zeitersparnissen, da sich (Quarantäne-)Schaderreger mit hyperspektraler Messtechnik und molekularer Diagnostik direkt am Feldrand erkennen und nachweisen lassen.

Neben diesen ökonomischen Nutzen bringt der Einsatz von KI auch Vorteile für Flora und Fauna. So ermöglicht es die Anwendung des Projektes *BETTER-WEEDS* das Risiko und Biodiversitäts-Potential von auftretenden Unkräutern besser zu kondensieren, wie auch die in *Weed-AI-Seek* entwickelten Anwendungen landwirtschaftliche Praxis effizienter und nachhaltiger gestalten. Die abschließende agronomische Auswertung in *WeedAI* ermöglicht eine Beurteilung des Pflanzenbestandes nach dem Schadschwellenprinzip (Kosten-Nutzenvergleich) und zusätzlich der Umweltleistung existierender Beikräuter.

Abschließend kann festgehalten werden, dass innovative Projekte, welche auf modernste Technologien setzen, die Entwicklung neuer Technologien und Lösungen (z.B. Fernerkundung) in der Landwirtschaft insgesamt fördern. Konkret bedeutet dies im Projekt *Kldetect*, dass durch die Schaffung einer Datenbasis, bestehend aus Graustufen-Bilder, aufgenommen im sichtbaren Wellenlängenbereich und SWIR-Kurzwelleninfrarotbildern Ressourcen zur Entwicklung neuer Technologien im Bereich der mechanischen Beikrautregulierung geschaffen werden.

## 1.4 Weiterer Aufbau des Whitepapers

Die hier angerissenen Fragen werden im weiteren Verlauf des Whitepapers detaillierter ausgeführt. In Kapitel 2 werden die involvierten Projekte beschrieben und die Kernherausforderungen der Projekte benannt. Kapitel 3 beschäftigt sich mit dem Ablauf eines Projektes in der landwirtschaftlichen Domäne Pflanzenschutz mit dem technischen Fokus KI. Hierbei werden Ansätze und Herausforderungen in jedem Projektschritt anhand der Erfahrungen der Projekte im X-KIT Cluster Pflanzenschutz diskutiert. Die sich aus diesen Erfahrungen ergebenden Erkenntnisse werden in Kapitel 4 in Schlussbetrachtungen und einem Ausblick zusammengeführt.

## 2 Übersicht der Projekte

Insgesamt fünf vom BMEL geförderte Projekte haben sich an den Arbeiten im X-KIT Cluster Pflanzenschutz beteiligt. Deren Gemeinsamkeit besteht in der Zielsetzung Nutzpflanzen in der landwirtschaftlichen Arbeit vor Schäden zu schützen. In Kapitel 2.1 beschreiben die Projekte ihr grundlegendes Projektziel. Schließlich werden die Herausforderungen, die sich während der praktischen Umsetzung der Projektziele ergeben haben, in Kapitel 2.2 vorgestellt.

### 2.1 Projektbeschreibungen

KI-gestützter Pflanzenschutz kann viele Formen annehmen und diverse Ansätze verfolgen. Dies verdeutlichen die im X-KIT Cluster Pflanzenschutz vertretenen Projekte. Nachfolgend die Selbstbeschreibungen der im Cluster vertretenen Projekte:

- **BETTER-WEEDS:** Es wird ein Work-Flow zur Erstellung von Unkrautmanagementkarten erarbeitet. Diese ermöglichen Entscheidungen für die Unkrautkontrolle auf Ackerflächen in Abwägung des ackerbaulichen Risikos und des Potentials für die Erhöhung der Biodiversität.
- **Kidetect:** Das Projekt *Kidetect* verfolgt das Ziel, Unkraut vor allem dort, wo es dicht gewachsen ist, präziser zu erkennen und zu entfernen. Auf Basis der gesammelten Bildinformationen werden dazu genaue 3D-Rekonstruktionen von Teilbereichen der Unkräuter erzeugt. Das ermöglicht es Hackgeräte auch in "grünen Teppichen" zielgerichtet zu steuern und damit das Unkraut selektiv zu entfernen.
- **PhenoTruck<sup>AI</sup>:** Den Zustand von großen Wein- und Obstbauanlagen zu monitoren ist notwendig, um Krankheitserreger und andere Stressfaktoren zu ermitteln und rechtzeitige Gegenmaßnahmen ergreifen zu können. Im Falle von Quarantäneschadern im Weinbau ist dies durch EU-Vorgaben sogar verpflichtend. Dieser Prozess soll im Rahmen des *PhenoTruck<sup>AI</sup>* Projektes von einer bisher ausschließlich visuellen Bonitur durch geschulte Fachkräfte mit digitalen und automatisierten Methoden unterstützt werden. Zusätzlich soll der Nachweis von spezifischen (Quarantäne-)Schadern direkt am Feldrand ermöglicht und damit die Möglichkeiten der visuellen Bonitur erweitert werden.
- **WeedAI:** Das Projekt verfolgt das Ziel der Entwicklung eines automatisierten Bewertungssystems für Unkrautbehandlungsmethoden. Hochaufgelöste Vegetationskarten auf Einzelpflanzen- und Artniveau dienen als Basis für die Beurteilung unterschiedlicher Bekämpfungsmaßnahmen. Umfassend untersucht werden eine sensorgeführte Hackmaschine sowie Herbizidanwendung, sowohl im Versuchswesen als auch in der landwirtschaftlichen Praxis. Weiter soll *WeedAI* dazu dienen, Prüfnormen für die Entwicklung moderner Pflanzenschutztechnik zu erweitern.
- **Weed-AI-Seek:** Das Ziel des Projekts ist es, durch die Kombination von KI-Technologie und UAV-Plattformen ein verlässliches und hochgenaues Monitoring der artenspezifischen Unkrautsituation auf landwirtschaftlichen Flächen zu ermöglichen, um eine selektive und teilflächenspezifische Anwendung von Pflanzenschutzmitteln zu ermöglichen. Dabei setzt das Projekt auf eine automatisierte Erkennung der Unkrautpflanzen während des Drohnenfluges in niedriger Flughöhe über das Feld. Dabei setzt das Projekt auf eine automatisierte Erkennung der Unkrautpflanzen während des Drohnenfluges in niedriger Flughöhe über das Feld durch Edge Computing auf der Drohne.

### 2.2 Herausforderungen

In den Projekten des Cluster Pflanzenschutz kam es zu einigen übergreifenden Herausforderungen, die einer Vielzahl von Projekten begegneten. Im Folgenden werden diese

Herausforderungen beschrieben. Eine Zusammenfassung der Projektherausforderungen findet sich in Tabelle 1.

### 2.2.1 Datengenerierung

Um KI-Verfahren für den Pflanzenschutz zu entwickeln, wird eine große Menge an Daten zum Trainieren, Validieren und Testen der zu entwickelnden und entwickelten Modellen benötigt. Da moderne, auf Machine Learning (ML) basierende KI-Verfahren ohne Daten nicht entwickelt werden können ist diese Herausforderung zentral für Erfolg oder Misserfolg eines Projektes. Die Akquise von Daten zum Training von Modellen für den Pflanzenschutz ist nicht trivial. Exemplarisch muss im Projekt *Weed-AI-Seek* das Problem der unstrukturierten Sensordaten (Luftbilddaufnahmen) gelöst und die Bilderkennung auf der Drohne automatisiert werden. Dahingegen mussten im Projekt *Kldetect* die zu analysierenden Beikräuter erst in Vertical Farming Umgebungen angepflanzt werden. Das Problem der Annotation der Ausgangsdaten wird vom Projekt *WeedAI* beschrieben: Hierbei kommt es auch durch eine breitgefächerte Datengrundlage zu einem erhöhten Aufwand, weshalb u.a. die Entwicklung und Anwendung von Weak Learning Methoden<sup>4</sup> untersucht wird.

### 2.2.2 Randbedingungen

Die Datengenerierung für KI-Projekte in der landwirtschaftlichen Domäne wird bei Projekten im Pflanzenschutz zusätzlich durch für diesen spezifische, die Datengenerierung verkomplizierende, Randbedingungen bei der Arbeit auf dem Feld erschwert: Im *PhenoTruck*<sup>®</sup> besteht die Schwierigkeit darin, den gewünschten hohen Automatisierungsgrad und die möglichst leistungsstarke Prozessierung direkt am Feldrand zu realisieren. Exemplarisch für das Problem der Unkrautererkennung auf Feldern notiert das Projekt *Weed-AI-Seek* hingegen Herausforderungen bei der Automatisierung der Bilderkennung auf der Drohne, bei der Modelloptimierung und bei der Hardwareintegration. Das Problem der Datenqualität wird im Projekt *WeedAI* angegangen. Im Projekt wird die höchstmögliche Präzision bei gleichzeitiger Praxisnähe angestrebt, was neue Anforderungen an die Datenakquise stellt.

### 2.2.3 Feature Engineering

Nach der Akquirierung der Daten müssen diese in eine Form gebracht werden, so dass die KI diese zur Analyse für die spezifischen Projektziele verwenden kann. Dieser Schritt wird als Feature Engineering bezeichnet. Feature Engineering ist vor allem für die Projekte, welche aus Drohnenbildern Aussagen über Pflanzen auf einem Feld herausziehen, eine Hauptherausforderung. Im Projekt *Weed-AI-Seek* stellt sich das Problem der unstrukturierten Sensordaten (Luftbilddaufnahmen): Diese müssen verarbeitet werden, um die hochpräzise Kartierung von Unkräutern im Flug mit der Drohne zu ermöglichen.

### 2.2.4 Objekterkennung und Segmentierung

KI allein garantiert noch keine Verbesserung des Pflanzenschutzes in der Landwirtschaft. Für jeden Anwendungsfall muss geprüft werden, welche Art von KI-Algorithmen für das zu lösende Problem am geeignetsten sind. Um hier einen Ansatz zu finden, muss zuerst die Frage, wobei die KI den Menschen unterstützen soll, beantwortet werden. In den betrachteten Projekten kristallisieren sich zwei Tätigkeitstypen, die durch die KI verbessert werden können, heraus: Die Objekterkennung, also die Lokalisierung und

---

<sup>4</sup> Weak Learning ist ein Ansatz im maschinellen Lernen, bei dem das Modell nur geringfügig besser als zufälliges Raten abschneidet. Durch die Kombination von verschiedenen Weak Learnern können dabei zufriedenstellend Ergebnisse erreicht werden.

Klassifizierung von Objekten und das räumliche, pixelgenaue Finden, also die Segmentierung von Objekten.

Die Objekterkennung ermöglicht dabei fachliche Informationen aus Bildern zu extrahieren, indem vorher spezifizierte Objekte auf einem Bild gefunden und mit einem Rahmen versehen werden. Die Objekterkennung kann bei der landwirtschaftlichen Entscheidungsfindung helfen. Dies stellt sich auch mit Hilfe von KI-Methodiken als nicht-triviales Unterfangen heraus: So konstatiert das Projekt *BETTER-WEEDS*, dass die artspezifische Unkrautererkennung im frühen Wachstumsstadium der Pflanzen auf einer großen Ackerfläche bislang noch nicht gelöst ist. Dieses Problem soll im Projekt durch den Einsatz von UAVs in Kombination mit diskreten Bildaufnahmen sowie Interpolationsmethoden gelöst werden. Damit soll die Verteilung der Pflanzenarten auf der Fläche bestimmt werden. Ähnliches berichtet das Projekt *Weed-AI-Seek*: Hier stellen Zielobjekte (Unkrautpflanzen), welche automatisiert erkannt werden sollen und im Vergleich zum Luftbild sehr klein sind und von anderen Pflanzen überlappt werden können, eine Herausforderung dar. Zur Lösung des Problems wurden Attention<sup>5</sup>-mechanismen verwendet. Eine weitere Herausforderung kann dabei wie im Projekt *Kldetect* die zielgerichtete Verwendung komplexer Sensorik, zum Beispiel SWIR<sup>6</sup>-Kameras, sein.

Segmentierungsverfahren sind nah mit Objekterkennungsverfahren verwandt, unterscheiden sich jedoch in Details. Während in der Objekterkennung vorher spezifizierte Klassen von Objekten auf Bildern gefunden werden sollen, versucht die Segmentierung verschiedene Objekte auf einem Bild pixelgenau zu segmentieren. Dabei können diese in verschiedene Klassen klassifiziert werden, dies ist aber nicht unbedingt notwendig. So ergeben sich zwei Anwendungsfälle: Im ersten Fall werden Objekte auf einem Bild segmentiert, die daraufhin einzeln klassifiziert werden können. Im zweiten Fall ist bekannt, dass sich auf einem Bild ein bestimmter Typ von Objekt befindet. Diese Objekte sollen daraufhin mithilfe von Segmentierungsverfahren gefunden werden. Auch Segmentierungsverfahren sind nicht trivial. Das Projekt *Weed-AI-Seek* berichtet: „Die Zielobjekte (Unkrautpflanzen), welche automatisiert erkannt werden sollen und im Vergleich zum Luftbild sehr klein sind, stellen eine Herausforderung dar“.

### 2.2.5 Interdisziplinarität

Über allen Projekten zur Anwendung von KI-basierten Verfahren für den landwirtschaftlichen Pflanzenschutz schwebt die Herausforderung, dass die Projekte zwangsläufig ein hohes Maß an Interdisziplinarität erfordern. Die spezifischen Problemstellungen im Pflanzenschutz, die Datengenerierung mit hard- wie softwareseitigen Herausforderungen, die fachliche korrekte Annotation von Bilddaten, das Training von passenden KI-Modellen sowie die Bereitstellung der entwickelten Techniken im landwirtschaftlichen Alltag erfordern alle für sich spezialisiertes Expertenwissen. Projektpartner mit Kenntnissen in den verschiedenen Domänen müssen zusammenkommen, eine gemeinsame Sprache finden und ihre Arbeitsabläufe aufeinander abstimmen. Exemplarisch hierfür berichtet das Projekt *Weed-AI-Seek*: „Das Projekt ist ein interdisziplinäres Vorhaben, welches Expertise aus der Landwirtschaft, der Ingenieurwissenschaft und der Datenwissenschaft erfordert“. Weiterhin kann nicht vorausgesetzt werden, dass fachspezifische Grundlagen und Kenntnisse bei den jeweils fachfremden Partnern vorhanden bzw. im richtigen Kontext verstanden werden.

---

<sup>5</sup> Attention in Machine Learning bezeichnet einen Mechanismus, der es Modellen ermöglicht, sich auf wichtige Teile der Eingabedaten zu konzentrieren, indem er den relevanten Informationen mehr Gewicht verleiht.

<sup>6</sup> SWIR-Kameras arbeiten auf kurzweiliger Infrarotstrahlung (Short Wavelength Infrared).

Tabelle 1: Überblick über die wichtigsten Projektherausforderungen

	Datengenerierung	Randbedingungen	Feature Engineering	Objekterkennung	Segmentierung	Interdisziplinarität
<b>BETTER-WEEDS</b>	X			X	X	X
<b>Kldetect</b>	X		X	X		X
<b>PhenoTrack<sup>AI</sup></b>	X	X			X	
<b>WeedAI</b>	X	X		X	X	X
<b>Weed-AI-Seek</b>	X	X	X	X		X

## 3 Lösungsansätze

In der Clusterarbeit wurden verschiedene Themen entlang den Entwicklungsprozess in einem KI-basierten Projekt in der Domäne Pflanzenschutz diskutiert. Die Clusterarbeit in dem in Kapitel 1.1 vorgestellten Cluster bestand aus Präsenz- und Online-Workshops, in denen die im Folgenden beschriebenen Themen erarbeitet und diskutiert wurden. Dabei stellten die im Cluster organisierten Projekte ihre eigenen Arbeiten vor oder diskutierten ein die Gesamtheit betreffendes Thema nach einem Input-Vortrag.

### 3.1 Datenakquise und Sensorik

Die Datenakquise bezieht sich auf die Erfassung und Sammlung von Informationen über verschiedene Aspekte des landwirtschaftlichen Betriebs, wie Bodenbeschaffenheit, Wetterbedingungen, Pflanzenwachstum und Tiergesundheit. Sensorik ermöglicht die kontinuierliche Messung und Überwachung dieser Parameter. Durch die Kombination von Datenakquise und Sensorik mit KI-Technologien können Landwirte präzise Analysen durchführen, Muster erkennen und Vorhersagen treffen, um ihre landwirtschaftlichen Prozesse zu optimieren.

#### 3.1.1 Auswahl von Sensorik und Aufnahmetechnik

Vor der eigentlichen Datengenerierung müssen in KI-Forschungsprojekten im Bereich Pflanzenschutz zwei grundlegende Fragen beantwortet werden: Welcher (Bild-)Datentyp eignet sich am besten, um die gegebene Forschungsfrage zu beantworten und wie können diese akquiriert werden? Hierbei müssen verschiedenen Stellschrauben beachtet werden:

Die Wahl der Sensorik hängt stark vom Ziel der Anwendung ab. Dabei spielen Parameter wie Auflösung, Rauschen, Aufnahmebedingungen, Flächenleistung pro Zeiteinheit und Langlebigkeit eine Rolle. Je nach Anwendungsziel werden entweder hochauflösende Bilder für eine detaillierte Erkennung, zum Beispiel von Schädlingen auf Blattebene, oder grobauflösende Bilder, zum Beispiel zur Erkennung von Krankheitsclustern benötigt. Die Wahl des Sensortyps ist ebenfalls abhängig von den Projektanforderungen: So werden RGB-Kameras vor allem für die Automatisierung optischer Erkennung eingesetzt, während Spektalkameras die Erkennung von Krankheiten ermöglichen. Ein weiterer möglicher Sensortyp sind SWIR-, bzw. Infrarotkameras. Die Verwendung von SWIR-Kameras ermöglicht die Erarbeitung von Grundlagenwissen, durch z.B. die Verwendung von spezifischen Filtern. Zudem müssen die Kosten der ausgewählten Sensoren berücksichtigt und an die wirtschaftlichen Rahmenbedingungen des Projektes angepasst werden.

Bei der Auswahl des Kamerasystems müssen neben dem verwendeten Sensor auch die Aufnahmebedingungen im Projekt mitgedacht werden: Aufnahmen können entweder im freien Feld oder in Laborumgebungen erfolgen, je nach den spezifischen Anforderungen und Zielen der Anwendung. Die konkrete Aufnahmeumgebung bestimmt dabei, welchen Robustheitsanforderungen ein Kamerasystem entsprechen muss: So wird bei Aufnahmen im Feld besonderer Wert auf die Langlebigkeit der Kameras gelegt, um sicherzustellen, dass sie den Anforderungen im Feld standhalten können.

Für die Aufnahme von Bildmaterial auf Feldern ist der State-of-the-Art die Verwendung von Unmanned Aerial Vehicle (UAVs), auch bekannt als Drohnen. Diese Drohnen werden mit hochwertiger Kameratechnik ausgestattet, um qualitativ hochwertige Bilder aufnehmen zu können. Die aufgenommenen Daten werden georeferenziert, um genaue räumliche Informationen zu erhalten. Bei der Konfiguration der Drohnen sind verschiedene Aspekte abzuwägen, wie z.B. Art der Kamera (festverbaut vs. Wechselsystem)

schwenkbare Kameras, Anzahl der Rotoren, redundante Systeme zum sicheren Betrieb, Akkuleistung, verwendete Groundstation Software oder automatisierte Georeferenzierung der Bilder. Wie stark der Bedarf an individuellen Features auf der Drohne ist bestimmt dabei die Wahl zwischen einem fertigen kommerziellen System oder einem selbstgebaute System. So musste ein Projekt eine eigenentwickelte Drohne verwenden, da zum Anschaffungszeitpunkt keine kommerzielle Drohne mit schwenkbaren Kameras und RTK-Technologie auf dem Markt verfügbar war. Selbstgebaute oder angepasste Drohnen bedeuten hierbei einen erheblichen technischen wie auch finanziellen Mehraufwand.

Auch die Konfiguration der Drohnenflüge muss geplant werden. So wird die Flughöhe der Drohne in der Regel auf eine Mindesthöhe von 13 Metern eingestellt, um störende Effekte durch den Abwind der Rotorblätter zu minimieren. Dabei bedeutet eine höhere größere Flächenleistung, jedoch auch eine reduzierte Bodenauflösung. Im Projekt *BETTER-WEEDS* wurde eine Flughöhe von 5 m über Grund als Kompromiss gewählt.

Die von Drohnen aufgenommenen Bilder können dabei eine Auflösung von unter einem Millimeter erreichen. Welche Auflösung für ein konkretes Projekt notwendig ist, muss dabei immer von Anwendungsfall, zum Beispiel der frühzeitigen Erkennung von Unkraut, abhängig gemacht werden. Eine weitere Stellschraube bei Drohnenflügen ist die Robustheit der Drohne: Hier muss geklärt werden, welchen Bedingungen die Drohne bei Aufnahmen ausgesetzt ist. Schlussendlich gilt auch bei der Drohne, dass die Kosten für diese wirtschaftlich vertretbar sein müssen.

**Handlungsempfehlung:** Alternativen zu Drohnen, um Daten in landwirtschaftlichen Feldversuchen aufzunehmen, zum Beispiel der Einsatz von Feld- oder Bodenroboter, von Leichtflugzeugen oder das Anbringen von Sensoren auf Landmaschinen bergen Potential für effektive Anwendungen. Um dieses zu heben, besteht weiterer Forschungs- und Entwicklungsbedarf.

Die in den Projekten verwendeten Sensormodalitäten und Verfahren umfassen:

- **RGB Daten:** Die Projekte *BETTER-WEEDS* und *Weed-AI-Seek* verwenden RGB-Daten, zur KI-basierten Unkrauterkenung.
- **Hyperspektrale Daten:** Das Projekt *PhenoTruck<sup>AI</sup>* nutzt hyperspektrale Daten, um detaillierte Informationen über Pflanzenmerkmale zu erhalten.
- **Molekularbiologische Analysen:** Im *PhenoTruck<sup>®</sup>* werden molekularbiologische Verfahren eingesetzt, um (Quarantäne-)schaderegner nachzuweisen.
- **Photogrammetrie:** Ebenso setzt das Projekt *PhenoTruck<sup>AI</sup>* Photogrammetrie ein, um Schadzustandskarten der Anbaugelände zu erstellen und zu analysieren.

In allen genannten Projekten kommen Drohnen (UAVs) als Sensorplattform zum Einsatz.

### 3.1.2 Randbedingungen der Datenakquise

Nachdem der Sensortyp zur Generierung der erforderlichen Daten definiert und die entsprechende Technik beschafft wurde, kann diese in der Anwendungsumgebung des Projektes verwendet werden, um Trainings- und Validierungsdaten für die zu entwickelnden KI-Anwendungen zu generieren. Diese Versuche auf dem Feld oder im Labor werfen einige sehr praktische Fragestellungen auf, die bei der Aufnahme von Daten als Randbedingungen mitbedacht werden müssen:

Bei Feldversuchen mit Drohnen muss je nach Flugzeit und Datenmenge die benötigte Anzahl von Akkus und Speicherkarten im Vorfeld abgeschätzt und mitgeführt werden. Dabei ist zu bedenken, dass speziell in der Herbstsaison bei niedrigen

Außentemperaturen die Akkuleistung schneller abnimmt. Falls Edge-Computing Anwendungen bei den Feldversuchen verwendet werden, müssen dafür entsprechend leistungsstarke Hardwarekomponenten evaluiert werden. Daran anschließend stellt sich die Frage der Übertragung, der Verarbeitung und die Speicherung der aufgenommenen Daten. Idealerweise geschieht dies im Rahmen eines automatisierten Deployment der entwickelten Softwaresysteme. Dieses aufzusetzen bedeutet weiteren Entwicklungsaufwand.

Ein weiterer Anwendungsfall im Pflanzenschutz ist die Entwicklung von Laborgebäuden für mobile Anwendungen, bei der es spezifische Herausforderungen zu berücksichtigen gilt. Zum einen müssen Mobilitätsanforderungen, das Laborgebäude effizient an verschiedene Standorte zu transportieren, erfüllt werden. Gleichzeitig müssen technische Anforderungen berücksichtigt werden, wie z. B. die Aufrechterhaltung einer konstanten Temperatur im Laborgebäude, der Stromverbrauch und die Abwärme. Die Randbedingungen für das Laborgebäude ergeben sich somit aus einer Kombination von Mobilitätsanforderungen und technischen Anforderungen.

Nach der Spezifizierung der verwendeten Technik kommt es in Pflanzenschutzprojekten zur Klärung von Detailfragen sowie zur Optimierung der Datenakquise-Workflows. Dabei treten im Hinblick auf verschiedene Anwendungsfälle unterschiedliche Herausforderungen auf. Zum Beispiel ist es im Kontext der Entwicklung einer mobilen Laboranwendung wichtig zu wissen, wie die Kühlung des Labors oder des LKWs aufgebaut ist, um die Temperaturkontrolle zu gewährleisten. Zudem muss die entwickelte Technik in ein geeignetes Transportfahrzeug passen, um einen reibungslosen Transport zu ermöglichen. Auch bei Versuchen mit Drohnen auf dem Feld stellen sich Detailfragen: Die richtige Temperierung der Akkus für Drohnen und die Lagerung der Akkus sind dort ebenfalls wichtige Fragen. Darüber hinaus ist es wichtig zu wissen, ab welchem Punkt die transportierte Technik als Gefahrgut eingestuft wird, um entsprechende Sicherheitsvorkehrungen zu treffen.

Generell ist die Robustheit der Technik für Einsätze im Feld ein Thema, welches nicht primär mit der Forschung rund um KI zusammenhängt, aber für deren erfolgreichen Einsatz bei den Endanwenderinnen und Endanwendern berücksichtigt werden muss. Oft sind komplexe Konstruktionen notwendig, um die eingesetzte Technik robust zu machen, ein Beispiel hierfür ist der Spritzwasserschutz für die Drohne und der darauf verbauten Sensorik. Kommerziell verfügbare Produkte erfüllen diese Anforderungen, bieten jedoch oft nicht vollumfänglich die benötigte Funktionalität, so dass hier wieder auf Eigenkonstruktionen zurückgegriffen werden muss. Daraus ergibt sich ein Spannungsfeld zwischen der Beantwortung von konkreten Forschungsfragen und dem Erreichen von hohen Technologiereifegraden.

### 3.1.3 Modularisierung

Ein vielversprechender Ansatz für den Umgang mit der Komplexität der Datenakquise ist die Modularisierung: Verschiedene Anwendungsfälle erfordern oft unterschiedliche Techniken und Sensoren. Das Ziel der Modularisierung ist es, eine Plug-and-Play-Lösung zu schaffen, bei der die verschiedenen Komponenten nahtlos zusammenarbeiten können.

Für die Modularisierung der verschiedenen Komponenten der Datenakquise (Sensorik, Datenspeicherung, Vorverarbeitung, Laden der Daten) sind bestimmte Grundvoraussetzungen erforderlich. Dazu gehören definierte Schnittstellen, die eine einfache Integration der Module ermöglichen. Zudem sollten die einzelnen Komponenten abgeschlossen und individuell verfügbar sein, um Flexibilität und Anpassungsfähigkeit zu gewährleisten. Bei der Skalierung des Systems werden die einzelnen Module fachlich eingegrenzt werden, um spezifische Aufgaben zu erfüllen. Gleichzeitig sollten die Module räumlich begrenzt

und transportierbar sein, um die Mobilität eines Labors oder einer Drohnenanwendung zu gewährleisten. Um diese Herausforderungen zu bewältigen, können Software- und Hardwarelösungen mithilfe von Frameworks implementiert werden. Frameworks können selbst entwickelt werden oder auf fertigen Lösungen wie der Workflow-Automatisierungslösung Apache Airflow<sup>7</sup> aufbauen. Frameworks bieten eine Struktur und unterstützen die Entwicklung von modularen Systemen, die einfach erweiterbar und anpassbar sind.

### 3.1.4 Anwendungsfälle

In den folgenden Unterkapiteln werden die Anwendungsfälle der Projekte WeedAI und BETTER-WEEDS dargestellt.

#### 3.1.4.1 WeedAI

Im Folgenden wird der Datengenerierungsworkflow im Projekt *WeedAI* beschrieben. In diesem wird Field Scouting mittels Drohnen zur Bewertung von Unkrautbekämpfungsmaßnahmen im Zuckerrübenanbau erforscht. Dabei liegt der Fokus auf der Identifikation von Einzelpflanzen und deren Artniveau.

Die Datengrundlage bildeten vier Drohnenflüge an 15 unterschiedlichen Orten über 19 verschiedene Flächen mit einer Größe von jeweils 0,2 bis 0,6 Hektar, die zu verschiedenen Zeitpunkten durchgeführt wurden. Sowohl betriebsübliche als auch neu angelegte Testfelder wurden dabei überflogen. Die Befliegungen fanden in einer Höhe von 12 Metern statt, wobei eine Zenmuse P1 Kamera mit 35 mm bzw. 50 mm Objektiv<sup>8</sup> zum Einsatz kam. Vervollständigt wurde die Datengenerierung durch manuelle Bonituren, die mit Schätzrahmen auf dem Feld durchgeführt wurden, welche als Ground Truth Vergleich dienen. Das Endergebnis der Datengenerierung umfasste sehr diverse Daten, die unter anderem verschiedene Lichtverhältnisse, Pflanzenarten und Unkräuter widerspiegeln. Zum Trainieren von Instance Segmentation Modellen wurde eine repräsentative Auswahl an Bildern manuell pixel-genau annotiert.

Der gewünschte Output der Datenpipeline in *WeedAI* sind präzise, georeferenzierte und klassifizierte Detektionen aller Einzelpflanzen. Hierzu werden als erster Schritt die aufgenommenen, sich stark überlappenden Bilder zu einem Orthomosaik verarbeitet, eine georeferenzierte Draufsicht des aufgenommenen Feldes. Da die Qualität des Orthomosaiks schlechter ist als die der einzelnen Originalaufnahmen, werden letztere sowohl für die Datenannotation als auch für Modelltraining und -inferenz genutzt. Abschließend werden alle Detektionen mithilfe des dem Orthomosaik zugrundeliegenden Photogrammetrie-Modells auf die Feldoberfläche projiziert.

Der Ansatz, sich stark überlappenden Einzelbilder zu nutzen, hat einen entscheidenden Vorteil: Jede Pflanze ist mehrfach abgebildet und durch die damit verbundene Redundanz können einzelne Fehldetektionen und -klassifikationen der KI identifiziert und herausgefiltert werden. Hierdurch entsteht jedoch auch ein erheblicher Overhead bezüglich benötigter Rechenleistung, welcher trotz Nutzung hochmoderner und leistungsfähiger Hardware eine nennenswerte Herausforderung im Projekt darstellt.

---

<sup>7</sup> <https://airflow.apache.org/>

<sup>8</sup> <https://enterprise.dji.com/de/zenmuse-p1>

### 3.1.4.2 BETTER-WEEDS

Auch im Projekt *BETTER-WEEDS* wurden umfangreiche Feldversuche durchgeführt. Die Konfiguration der Versuche wird im Folgenden beschrieben:

Auf mehreren Versuchsflächen wurden Raster mit mindestens 40 Bonitурpunkten einge-messen. Diese waren dabei in der Kulturpflanzenreihe 10 m und zwischen den Kultur-pflanzenreihen 6 m voneinander entfernt. Auf den Versuchsflächen wurde Winterweizen bzw. in einem Fall Wintergerste angebaut. Auf der Teilfläche erfolgten im Herbst keine Herbizidbehandlungen oder andere Maßnahmen zur Unkrautkontrolle. Die Rasterpunkte auf den Versuchsflächen wurden zwei bis drei Mal pro Jahr automatisiert mit einem GPS-gesteuerten Quadrocopter Hexapilot<sup>9</sup> (4 Motoren / 6000g / 25-30 Minuten Flugzeit) mit RTK befliegen. An dem Quadrocopter war eine RGB-Kamera (Alpha 6000<sup>10</sup> mit 60mm Festbrennweite) montiert, welche an jedem Rasterpunkt automatisiert auslöste. Ein LI-DAR-Abstandssensor ermöglichte eine konstante Flughöhe. Parallel dazu fanden Hand-bonituren am Boden statt, um die Unkraut Arten und deren Dichte an den Rasterpunkten zu verifizieren. Die Bilder mit Hilfe eines Computer Vision Annotation Tools (CVAT) und EPPO-Codes<sup>11</sup> händisch annotiert.

## 3.2 Modellauswahl und Training

Die richtige Modellauswahl ist von großer Bedeutung, da sie einen direkten Einfluss auf die Leistung und Genauigkeit der KI-Anwendung hat. Unterschiedliche Modelle bieten unterschiedliche Fähigkeiten und Eigenschaften, je nachdem, ob es sich um Bilderkennung, Sprachverarbeitung, Vorhersage oder andere Aufgaben handelt. Die Wahl des richtigen Modells ist daher entscheidend, um die bestmöglichen Ergebnisse zu erzielen. Das Training des Modells beinhaltet die Verwendung von Trainingsdaten, um das Modell anzupassen und seine Fähigkeiten zu verbessern. Während des Trainingsprozesses werden die Gewichte und Parameter des Modells angepasst, um eine optimale Leistung zu erzielen. Dies erfordert oft große Mengen an Daten, um das Modell auf eine Vielzahl von Szenarien und Variationen vorzubereiten.

### 3.2.1 Machine Learning Workflow

Die Modellauswahl und das Training von KI-Modellen folgen meist einem ähnlichen Ablauf. Zuerst werden Trainingsdaten beschafft. Die Schwierigkeiten bei der Beschaffung sind in Kapitel 3.1 detailliert beschrieben. Wenn diese Daten vorliegen müssen in den meisten Fällen aus den Rohdaten Ground Truth Daten erstellt werden. Dies sind Daten, bei denen ein Experte die Rohdaten mit Labeln, die dem Trainingsziel der ML-Modelle entsprechen, versieht. Die Generierung von Ground Truth Daten erfolgt in der Regel durch Experten, da eine Annotierung durch Dienstleister aufgrund der hohen Annotations-Komplexität in der Domäne Pflanzenschutz oft nicht möglich ist.

Ein praktisches Problem stellte beim Annotationsprozess die Einarbeitung von Experten, zum Beispiel Agrarwissenschaftler, in die ungewohnte und teils komplexe Annotationssoftware dar. Für die Annotation muss somit für eine ausreichende Schulung der Expertinnen und Experten sowie auch der Aufbau einer komfortablen Annotationsinfrastruktur hinsichtlich Hard- und Software gesorgt werden.

---

<sup>9</sup> <https://www.hexapilots.de/leitungsbau>

<sup>10</sup> <https://www.sony.de/electronics/wechselobjektivkameras/ilce-6000-body-kit>

<sup>11</sup> <https://www.eppo.int/>

Eine Alternative zur händischen Generierung von Ground Truth Daten wäre die Verwendung von öffentlich zugänglichen Forschungsdatensets. Diese sind häufig jedoch nicht vorhanden, beziehungsweise passen nicht zur Fragestellung des Projektes. Ein Problem liegt darin, dass standardisierte und in der Breite anerkannte Methoden und Plattformen annotierte Daten zu veröffentlichen nicht vorhanden, nicht bekannt oder noch im Aufbau sind.

**Handlungsempfehlung:** Es existieren bereits Plattformen zum Austausch von Forschungsdatensätzen, jedoch sind diese noch nicht durchgehend in der deutschen Forschungslandschaft bekannt. Um diese Wissenslücke zu schließen, wird empfohlen, schon existierende Plattformen für die wissenschaftliche Verwertung breiter bekannt zu machen. Zusätzlich wäre es wünschenswert, diese Plattformen im Sinne einer öffentlich-privaten Partnerschaft auszubauen. Dafür müssten es die Plattformen ermöglichen, dass privatwirtschaftliche Akteure ihre Daten für Forschungszwecke unter Wahrung ihrer Geschäftsinteressen teilen können. Die Entwicklung eines solchen Forschungsdatenmarktplatz ist wünschenswert.

Nach der Generierung von Trainingsdaten und den zugehörigen Labels können ML-Modelle trainiert werden. Das Ziel der Analyse im Bereich Pflanzenschutz kann aus der Detektion von Unkräutern oder Schädlingen, der Klassifizierung dieser und teilweise auch der Prädiktion des weiteren Verlaufs eines Schädlings- oder Krankheitsbefalls bestehen. Mögliche Methoden, die verwendet werden können, ist das Modellieren der Ausgangsdaten als Zeitreihen, ein mehrstufiger Analyseworkflow sowie Ansätze zur Balancierung von einem Datensatz. Techniken zur gleichmäßigen Balancierung<sup>12</sup> der Verteilung der Klassen in einem Datensatz sollten angewandt werden, wenn das Verhältnis der einzelnen Klassen in dem Datensatz, zum Beispiel das Nutzpflanzen- und Unkrautvorkommen auf zu analysierenden Feldern, große Schwankungen aufweist. Nicht balancierte Datensätze erschweren das Trainieren von ML-Modellen.

Bei der Auswahl der Modelle für die Lösung der gegebenen Aufgabe gibt es verschiedene Möglichkeiten. Einfachere, generische KI-Modelle ohne Kontextinformationen können verwendet werden, aber auch komplexere Modell mit individuell angepasster Architektur wie zum Beispiel zusätzlichen Attention-Mechanismen können verwendet werden. Ein Sonderfall sind Modelle die speziell für Edge-Hardware optimiert sind. Diese haben häufig, aufgrund von geringen Rechenressourcen auf Edge-Devices, spezielle Anforderungen an die Größe und Komplexität der verwendeten Modelle.

Ein weiteres, in den letzten Jahren an Relevanz gewinnendes Verfahren ist das Transfer-Learning. Dabei werden die trainierbaren Gewichte von ähnlichen Anwendungen verwendet, um den Trainingsprozess zu beschleunigen und die Leistung des Modells zu verbessern. Die Idee dahinter ist, dass ein Modell nicht komplett neu trainiert werden muss, sondern dass ein schon bestehendes Modell angepasst wird. Dadurch werden weniger Trainingsdaten benötigt und ein Modell kann schneller trainiert werden.

Zu beachten bei der Verwendung von Transfer Learning Verfahren ist jedoch, dass Modelle, die auf großen, stark generalisierenden Datensätzen trainiert wurden, oft auf Objekte, die nichts mit der eigentlichen Projektdomain zu tun haben, ausgerichtet sind. In der Computer Vision wird so zum Beispiel häufig auf ImageNet, in dem Bilder aus 1000 verschiedenen Objektkategorien enthalten sind, trainiert. Dies kann zu fehlerhaften Klassifikationen führen: In einem Projekt kam es zu dem Ergebnis, dass kleine Pflanzen

---

<sup>12</sup> Unter einem balancierten Datensatz versteht man im Maschinellen Lernen einen Datensatz, in dem alle Klassen mit ähnlichen Häufigkeiten vorkommen. Bei unbalancierten Datensätzen kann es vorkommen, dass die weniger repräsentierte Klasse schlechter von einem trainierten Modell erkannt wird.

fälschlicherweise als chinesische Schriftzeichen erkannt wurden. Im Bereich der Sprachverarbeitung kann es zu ähnlichen Artefakten in Large Language Models kommen.

### 3.2.2 Hyperspektraldatenanalyse

Eine im Pflanzenschutz häufig anzutreffende Technologie ist die Hyperspektralanalyse. Diese befasst sich mit der Verarbeitung und Auswertung von Daten, die in einem breiten Spektrum von Wellenlängen aufgenommen werden. Im Vergleich zu Multispektraldaten, die nur wenige Kanäle (z.B. 3 Kanäle bei RGB-Bildern) umfassen, bestehen Hyperspektraldaten aus mehreren hundert spektralen Kanälen. Hyperspektraldaten erlauben damit eine fundierte, wissenschaftliche Analyse der spektralen Eigenschaften von Messobjekten. Die Erkenntnisse können genutzt werden, um die Eignung von weniger-dimensionalen RGB- oder Multispektralsystemen für die Problemstellung zu untersuchen. Mit Hyperspektraldaten werden insbesondere pixelbasierte Analysen durchgeführt, da jeder Pixel ein gesamtes zu Klassifizierung verwertbares Spektrum enthält. Es können struktur-basierte Features zur Auswertung eingebunden werden.

Die Technik zur Aufnahme der Hyperspektraldaten ist sehr teuer und somit für den Endanwender nicht verfügbar. Ein möglicher Workflow, um dieses Problem zu lösen besteht aus einer initialen Analyse von Pflanzen mit Hyperspektralkameras in Bezug auf das Problem. Aus der Hyperspektralanalyse kann geschlossen werden, welche Wellenlängen des Spektrums relevant sind, um das gegebene Problem zu lösen. Basierend auf diesen Erkenntnissen kann eine finale Anwendung entwickelt werden, die auf einer individuell konfigurierten Multispektralkamera, die nur die relevanten Wellenlängen betrachtet, basiert.

Bei der Anwendung von Hyperspektraldaten sind einige Voraussetzungen zu beachten. Hyperspektralkameras sind sehr teuer und nur von geschultem Personal bedienbar. Zudem müssen die Aufnahmen unter kontrollierten Bedingungen und Lichtverhältnissen erfolgen. Die Verarbeitung und Analyse von Hyperspektraldaten ist aufwendig und erfordert Fachkenntnisse. Zudem sind die Datenmengen bei Hyperspektraldaten sehr groß, oft im Bereich von einem Gigabyte bis zu mehreren Terabyte. Somit eignet sich die Hyperspektralanalyse vor allem für spezialisierte Forschungseinrichtungen und Dienstleister.

Ein Anwendungsfall der Hyperspektralanalyse im Pflanzenschutz mit dem PhenoTruck<sup>AI</sup> Projekt ist die Erkennung von Stressfaktoren im Obst- und Weinbau. Hierbei ermöglicht es die Anwendung der Hyperspektralanalyse, verschiedene Stressfaktoren bei Pflanzen zu unterscheiden. Dabei werden hyperspektrale Variationen der aufgenommenen Hyperspektralbilder, die von den spezifischen Stressfaktoren und Umgebungsfaktoren abhängen, genutzt um mittels Machine Learning ein Vorselektieren von Pflanzenproben vorzunehmen. Ein gesicherter Nachweis von spezifischen (Quarantäne-) Schaderregern erfolgt mittels molekularbiologischer Analyse. Umgekehrt werden die Machine-Learning Modelle derart trainiert, dass sie die molekularbiologischen Ergebnisse bestmöglich vorhersagen und im Anwendungsfall nur in Einzelfällen auf die molekularbiologische Analyse zurückgegriffen werden muss. Bei dem Training der Modelle werden Lerndaten in einer Größe von einigen Terabyte verwendet.

### 3.2.3 Randbedingungen des KI-Training: MLOps

Neben den fachlichen Komponenten der KI-Entwicklung, also der Akquisition von Daten, dem Labelling, der Auswahl und dem Training von ML-Modellen sowie deren Evaluation ist die technische Verwaltung aller Arbeitsschritte für Pflanzenschutzprojekte relevant. Die Entwicklung von Projekten mit dem technischen Fokus KI ist meist hochkomplex. Verfahren des MLOps (Machine Learning Operations) bieten eine Möglichkeit, diese Komplexität zu beherrschen.

Eine zentrale Frage ist, wie große Artefakte wie Gewichte von KI-Modellen und deren Trainingsdatensätze versioniert werden können. Hier bieten sich Lösungsansätze wie MLFlow oder Weights and Biases an, die das Speichern von Metadaten und Binärartefakten ermöglichen. Mit diesen Softwarelösungen können trainierte Modelle verlässlich verwaltet und gespeichert werden. MLFlow bietet zudem eine kompatible Serving-Umgebung und die Möglichkeit, Konfigurationen zu managen, was das Testen von neuen Modellen erleichtert. Problematisch an Weights and Biases ist jedoch, dass dieses mittlerweile nur noch kommerziell angeboten wird.

Ein weiterer wichtiger Punkt ist die Versionierung von Datensätzen. Ein Tool, welches hier zum Einsatz kommen kann, ist DVC (Data Version Control). Das Tool versioniert Datensätze in Verbindung eines Git-Repositories, wobei die Versionen im Git vorgehalten werden und die tatsächlichen Daten in einem Bucket-Store, wie MinIO oder S3 gespeichert werden. Dabei ist zu beachten, dass DVC keine Diffs von Datensätzen generiert, das heißt, dass jeder Commit zu einem neuen Datensatz führt und viel Speicherplatz benötigt.

Eine weitere Schwierigkeit in der Entwicklung von KI-Anwendungen ist die Versionierung der verwendeten Tools und Softwarebibliotheken. Eine bewährte Lösung besteht darin, die Infrastruktur und Trainingsressourcen zentral zu verwalten, was jedoch auf Kosten der Flexibilität gehen kann. Hier gibt es keine allgemeingültige Lösung, da die technologische Entwicklung im Bereich MLOps sehr schnell voranschreitet und die optimale Lösung bei jedem Projekt neu gefunden werden muss.

Schließlich müssen auch Softwareupdates berücksichtigt werden. Hier bietet sich die Verwendung einer Docker-Umgebung auf einem Testserver (Staging) an. Auf diesem können Softwareupdates getestet werden, bevor sie an alle Nutzer verteilt werden. Wenn alles reibungslos funktioniert, können die Updates auf die gesamte Infrastruktur angewendet werden. Die Nutzung von Infrastructure-as-a-Service und das Vermeiden von Änderungen an einem laufenden System sind ebenfalls bewährte Praktiken. Es kann auch sinnvoll sein, einen Vollzeit-Systemadministrator für das Management dieser Updates einzusetzen.

Zudem ist es eine gute Praxis eine zentrale Recheninfrastruktur für Forschungsprojekte aufzubauen. Diese kann zum Beispiel mit Kubernetes<sup>13</sup> aufgebaut und verwaltet werden. Schwierigkeiten hierbei können Kubernetes-Updates, die Auswirkungen auf unterliegende Docker-Instanzen haben sowie der Mangel an Ressourcen für ein umfassendes Servermanagement sein.

### 3.2.4 Anwendungsfälle

Im Pflanzenschutz werden in der Regel zwei übergeordnete Use Cases bearbeitet: Die Erkennung von Schaderregern und anderen Stressfaktoren auf Pflanzen und die Erkennung von Unkraut. Exemplarisch für die Erkennung von Stressfaktoren bei Pflanzen steht das *PhenoTruck<sup>AI</sup>* Projekt und exemplarisch für die Erkennung von Unkräutern das *Weed-AI-Seek* Projekt.

#### 3.2.4.1 Erkennung von (Quarantäne-)Schaderregern: PhenoTruck<sup>AI</sup>

Im Rahmen des Projektes *PhenoTruck<sup>AI</sup>* wird ein spezialisierter Workflow zur Erkennung von Schadenserregern im Obst- und Weinbau entwickelt. Der *PhenoTruck<sup>®</sup>* dient als mobiles Labor, das unmittelbar am Feldrand zum Einsatz kommt und ermöglicht die Durchführung umfassender Analysen direkt vor Ort. Diese umfassen molekularbiologische

---

<sup>13</sup> <https://kubernetes.io/>

Laboruntersuchungen, hyperspektrale Laboruntersuchungen sowie multispektrale Drohnenbefliegungen.

Es werden multispektrale Drohnenbefliegungen mit einer 5-kanaligen Kamera durchgeführt. Dabei wird ein RTK-Signal (Real Time Kinematik) genutzt, um hochpräzise Positionsdaten zu gewinnen. Mit den erfassten Multispektralbildern werden mittels einer Photogrammetrie-Pipeline automatisiert 3D-Punktwolken berechnet, mit welchen orthorektifizierte und georeferenzierte Karten erstellt werden. In einer ML-Pipeline wird auf diesen Karten eine Baumselektion vorgenommen, auf denen mittels speziellen Indizes der Gesundheitszustand bildlich dargestellt wird. Die so entstandene Karte wird als Risikokarte für die Auswahl der Blattprobenentnahme verwendet. Parallel dazu ermöglicht eine in PhenoTruck® entwickelte BoniturApp die visuellen Bonituren für die einzelnen Kultur-Pflanzen direkt auf dem Feld digital durchzuführen.

Die hyperspektrale Auswertung von einzelnen Blattproben wird durchgeführt, falls bei der multispektralen Drohnenbefliegung ein Risiko für einen Schaderreger vorliegt. Bei der hyperspektralen Analyse von Blattproben erfassen Zeilenkameras eine Aufnahme der Blattprobe bei dem jeder Pixel ein Spektrum darstellt. Die hochgenaue spektrale Aufnahme erlaubt eine wissenschaftliche Untersuchung der Reflektanzeigenschaften der Blattproben. Machine Learning Modelle werden trainiert und genutzt um eine Identifizierung von relevanten (Quarantäne-) Schaderregern, sowie die Differenzierung von weiteren Stressfaktoren zu ermöglichen. Für das Training der Modelle oder zum finalen Nachweis des Vorliegens eines Schaderregerbefalls an hyperspektral vorselektierten Blättern werden molekularbiologische Verfahren angewendet.

#### 3.2.4.2 Erkennung von Unkräutern: Weed-AI-Seek

Das *Weed-AI-Seek* Projekt zielt darauf ab, ein autonomes Drohnensystem zu entwickeln, das durch tieffliegende Drohnen-Erkundungsflüge Unkraut präzise erfasst und die so aufgenommenen Bilder auf der Drohne selbst analysiert. Mittels KI-gestützter Bildverarbeitung sollen Unkrautmuster auf landwirtschaftlichen Flächen erkannt und kartiert werden. Das langfristige Ziel ist es, durch die gesammelten Daten Muster im Unkrautwuchs zu identifizieren und diese Erkenntnisse für gezielte Unkrautbekämpfungsmaßnahmen sowie für die Beantwortung von Biodiversitätsfragestellungen zu nutzen.

Um dieses Ziel zu erreichen, wurden auf eigenen Testflächen unterschiedliche Bestellungen von Winterweizen gepflanzt und Realaufnahmen unter natürlichen Bedingungen bei Drohnenflügen erstellt. Die Datenaufnahme war stets von variablen Randbedingungen wie Wetter und Lichtverhältnissen abhängig. Bei den von der Drohne aufgenommenen Bildern kommt es zu Überlappungen von Einzelbildern.

Für die Annotierung der Daten wurde das Tool CVAT<sup>14</sup> verwendet, bei dem manuell Begrenzungsrahmen, auch Bounding Boxes genannt, auf dem digitalen Bild um die relevanten Pflanzen gezogen wurden. Da Objekterkennungsmodelle (YOLO-Framework), welche Pflanzen lokalisieren, zählen und auf Artebene unterscheiden sollen, mithilfe eines Supervised Learning Ansatz trainiert werden sollten, reichten Bounding Boxes als Ground-Truth Annotierungen aus. Für das Training von Selektionsmodellen hätten die Pflanzen pixelgetreu annotiert werden müssen.

Als Ergebnis des Annotationsverfahrens entstand ein stark unbalancierter Datensatz aufgrund der ungleichen Verteilung von Pflanzenarten auf den Testfeldern. Dies bedeutet, dass die Häufigkeit verschiedener Klassen, hier Pflanzenarten, innerhalb des Datensatzes

---

<sup>14</sup> <https://www.cvat.ai/>

stark variierte, was eine Herausforderung für die Entwicklung eines ausgewogenen und effektiven Machine Learning Modells darstellt.

Das verwendete YOLO-Framework ist eine state-of-the-art Architektur, stößt aber bei der Erkennung kleiner Objekte an Grenzen. Zudem können Schwierigkeiten wie Verdeckungen (Occlusion), unscharfe Bilder und ähnliche Probleme auftreten. Daher wurden, um die Effektivität der YOLO-Modelle zu verbessern, verschiedene Backbone-Netze getestet. Backbone-Netze sind die Bilderkennungsnetze, die hauptsächlich für die Erkennung von Merkmalen und Eigenschaften auf Bildern verantwortlich sind, vergleichbar mit Foundation Modellen im Bereich der Sprachverarbeitung. Hierbei musste besonders die Performance der Modelle gegen die Größe und Komplexität abgewogen werden, da die Modelle auf der Drohne laufen müssen, welche nur begrenzte Ressourcen hat.

Um die Erkennung von Unkräutern weiter zu optimieren, wurden individuelle Anpassungen an der YOLO-Architektur vorgenommen. Ein neuer Attention-Mechanismus ermöglicht es, den Fokus verstärkt auf Unkräuter zu legen, während ein Spatial Pyramidic Layer die Unterscheidung zwischen großen und kleinen Objekten verbessert. Das Projektergebnis zeigte, dass solche Anpassungen der Modellarchitektur einem Wechsel der Modellarchitektur in einigen Fällen vorzuziehen sind, da sie stets von konkreten Analyseergebnissen angetrieben sind. Gegen den Wechsel von Backbone-Modellen spricht auch, dass stärkere Backbone-Modelle höhere Anforderungen an die Rechenleistung stellen und somit für den Einsatz auf Edge-Devices weniger geeignet sein können.

### 3.2.4.3 Erkennung von Ackerbeikraut: BETTER-WEEDS

Das BETTER-WEEDS Projekt hat zum Ziel eine Erfassung von Ackerbeikräutern zu ermöglichen. Dies wird durch eine drohnengestützte Befliegung und anschließende Analyse der RGB-Bilder durch KI-Methoden ermöglicht. Die Vorgehensweise ist dabei in zwei Abschnitte geteilt: (1) Erkundungsflug und (2) Detailbefliegung. Der Erkundungsflug findet auf einer höheren Flugbahn statt um möglichst viel Fläche des Ackers abzudecken. Die erstellten RGB-Bilder werden off-site von einem Detektions-Modell analysiert, um eine Verteilung der Beikräuter auf dem Acker zu gewinnen. Basierend auf dieser Verteilungskarte können Hotspots erkannt werden, welche dann in einer zweiten automatisiert erstellten Befliegung mit höherer Frequenz angesteuert werden als die übrigen Bereiche des Feldes. In diesem Detailflug werden wiederum RGB-Bilder erstellt. Auf diesen Bildern werden wiederum die Ackerbeikräuter verortet und danach klassifiziert.

Um die beiden Ziele (Verortung und Klassifikation) zu erreichen, werden zwei verschiedene Modellarchitekturen verwendet. Diese werden in einer gemeinsamen Pipeline miteinander verbunden, um das Gesamtziel zu erreichen. Dabei wird für die Detektion (Verortung) ein YOLO-Netzwerk verwendet. Um eine optimale Anpassung an den Anwendungsfall der Erkennung von Ackerbeikräutern zu ermöglichen, wurde ein auf das Problem optimierter Datensatz erzeugt. Dieser besteht aus Aufnahmen (RGB-Bildern) der im Projekt betrachteten Zielarten. Diese Bilder sind auf Ackerflächen erstellt worden, um somit den Anwendungsfall präzise abzubilden. Mit diesem Datensatz wird das Modell trainiert. Um die benötigte Zeit zu minimieren, wird ein vortrainiertes Modell verwendet und nur mit notwendigen Änderungen versehen (Fine-Tuning). Die Ergebnisse des Modells werden gefiltert, weil Detektionsmodelle immer eine feste Anzahl an Ergebnissen erzeugt, wovon nur eine geringe Anzahl sinnvoll nutzbar sind.

Die detektierten Pflanzen werden im nächsten Schritt der Pipeline klassifiziert. Auch wenn moderne Detektionsmodelle eine integrierte Klassifikation ermöglichen, ist es vorteilhaft diese beiden Aufgaben zu trennen. Damit können beide Anwendungsfälle getrennt voneinander betrachtet und evaluiert werden. Für die Klassifikation wird eine angepasste Architektur aus Feature-Extractor und vollverbunden Schichten genutzt. Der Feature-Extractor kodiert dabei die relevanten Pflanzenmerkmale in eine

hochdimensionale Repräsentation. Anschließend wird mit den vollverbundenen Schichten daraus eine Pflanzenart abgeleitet. Der Feature-Extractor ist bereits auf die Kodierung von Pflanzenmerkmalen optimiert.

Zur Anpassung an den Anwendungsfall des Projektes, wird ein Modell aus vollverbundenen Schichten trainiert. Dabei wird ein Datensatz verwendet, welcher genau die Zielarten beinhaltet. Weiterhin wird in der Modell-Pipeline eine Vorverarbeitung der Bilder durchgeführt. Diese beinhalten ein Zuschneiden der Eingabebilder in ein Format, welches von dem YOLO-Modell benötigt wird. Als Nachverarbeitung wird eine Min-Max-Suppression durchgeführt, um unsichere Detektion zu filtern.

### 3.3 Deployment und Integration

Nach der erfolgreichen Entwicklung eines KI-Modells, welches ein Problem im Pflanzenschutz löst, folgt als finaler Schritt das Deployment, also das Verbauen eines KI-Modells in eine Anwendung zum Pflanzenschutz. Für diesen Schritt sind dieselben Herausforderungen, die sich auch bei der Generierung des initialen Trainingsmaterials stellen, relevant. Auch hier müssen die entwickelten Modelle in den Anwendungsbereich mit all seinen Randbedingungen gebracht werden. Zusätzlich zu den In Kapitel 3.1 beschriebenen Herausforderungen stellen sich einige, für das Deployment und die Integration in die Gesamtanwendung spezifische Herausforderungen, ein.

Grundsätzlich bezeichnet der Begriff "Deployment" den Prozess der systematischen Verteilung und Implementierung einer Softwareanwendung oder eines IT-Systems in einer produktiven Umgebung. Dieser Prozess umfasst die Planung, Konfiguration, Installation, Integration, Aktualisierung und Überprüfung der Anwendung oder des Systems, um sicherzustellen, dass es ordnungsgemäß funktioniert, die Anforderungen erfüllt und für die Benutzer verfügbar ist. Das Deployment erfolgt in der Regel nach umfangreichen Tests und Qualitätssicherungsverfahren, um einen reibungslosen Übergang in die produktive Umgebung zu gewährleisten.

#### 3.3.1 Edge Computing vs. Cloud Computing

In der Verarbeitung von datengetriebenen Anwendungen gibt es zwei grundlegende Ansätze: Das Cloud-Computing, bei dem die Daten in einer Cloud, also einem entfernt stehenden Rechnersystem, verarbeitet werden, und den Ansatz des Edge-Computing, bei dem die Daten auf lokalen Rechnern oder Geräten verarbeitet werden. Beide Ansätze lassen sich für Anwendungen im Pflanzenschutz einsetzen.

##### 3.3.1.1 Cloud Computing

Cloud-Computing bietet den Vorteil einer hohen Rechenleistung, da die Daten in der Cloud, also auf einem externen System mit meist starken Ressourcen, verarbeitet werden. Somit lassen sich deutlich rechenintensivere Anwendungen umsetzen. Es gibt jedoch auch einige Nachteile: Zum einen besteht die Notwendigkeit einer guten Internetverbindung, welche insbesondere in ländlichen Gebieten nicht immer gegeben ist. Zudem kommen bei einer Übertragung zu einer externen Cloud Aspekte des Datenschutzes zum Tragen.

Im Zusammenhang mit Chancen und Herausforderungen des Cloud-Computings lässt sich das Projekt *WeedAI* zur Bewertung von Unkrautbekämpfungsmethoden als anschauliches Beispiel heranziehen: Hierbei ist das Ziel, die Effektivität verschiedener Unkrautbekämpfungsmethoden zu beurteilen, indem Unkraut und Nutzpflanzen identifiziert, klassifiziert und deren Größe ermittelt werden. Die Ergebnisse der Analyse können anschließend in GIS-Systemen geladen und analysiert werden. Dies ermöglicht eine

detaillierte Auswertung darüber, wie viele Unkräuter bei unterschiedlichen Methoden der Unkrautbekämpfung beseitigt werden konnten.

Für das Deployment wird eine Cloud-basierte Lösung bevorzugt, da hier die Qualität der Gesamtbildbewertung im Vordergrund steht und nicht die Performanz vor Ort, wie es beim Edge Deployment der Fall wäre. Die Herausforderungen in Bezug auf die Datenmenge werden bei einem einzelnen Feld deutlich, welches Daten im Umfang von rund 60GB generiert. Das stellt nicht nur hohe Anforderungen an die Übertragungsraten bei der Datenaufnahme, sondern führt auch zu langen Berechnungszeiten für das Erstellen von Orthomosaiken, Modellvorhersagen und Post-Processing, welche nur in Cloud-basierten Lösungen realisiert werden können.

### 3.3.1.2 Edge Computing

Auch das Edge-Computing bietet verschiedene Chancen. Es gibt keine externen Abhängigkeiten, die Datensicherheit ist hoch, die Datenübertragung erfolgt schnell und der Stromverbrauch ist häufig geringer als beim Cloud Computing. Eine Modellhafte Analyse konnte 2019 zeigen, dass Edge-Computing-Architekturen 14% - 25% weniger Energie verbrauchen könnten als Cloud-Computing-Architekturen<sup>15</sup>. Dies liegt unter anderem an weniger ressourcenstarker Hardware, der Einsparung der Energie des Übertragungsnetz von Nutzer zu Cloud Provider und daran, dass nur Analyseergebnisse und keine Rohdaten übertragen werden müssen. Es gibt jedoch auch Herausforderungen: So müssen häufig Schnittstellen zwischen Anwendungen auf einem Edge-Device aufwendig implementiert werden, was zu einem hohen Konfigurationsaufwand führen kann. Zudem gibt es Limitierungen in Bezug auf die Rechenleistung der Edge-Geräte. Dies hat Auswirkungen auf die möglichen, einsetzbaren KI-Modelle, da diese an die Rechenleistung der Edge-Geräte angepasst werden müssen.

Exemplarisch für ein Edge-Deployment ist das *Weed-AI-Seek* Projekt: Das Projekt entwickelt ein autonomes Drohnensystem für die präzise Erfassung und Analyse von Unkraut durch tieffliegende Erkundungsflüge und verfolgt dabei einen Edge-Computing Ansatz.

Die Datenverarbeitung erfolgt direkt auf einem Integrationsboard der Drohne, das mit einer Sony-Kamera und einer Nvidia-Integrationslösung, einem Jetson Xavier Edge-Board<sup>16</sup> ausgestattet ist. Herausforderungen wie Überlappungen und Unschärfen, die bereits bei der Aufnahme der Trainingsdaten auftraten, müssen auch hier bewältigt werden. Die Drohnen operieren in einer Flughöhe von 1,5 bis 2 Metern und berechnen die Unkrautart sowie die Bildmittelkoordinaten, um die Daten dann an einen Computer weiterzuleiten.

Ein weiterführendes, neu aufgekommenes Konzept, welches die Vorteile beider Ansätze vereinen könnte, ist die Verwendung von Drohnen als Relaisstationen auf dem Feld. Dabei werden Daten zwischen Feldmaschinen, Drohnen und lokalen Rechnern ausgetauscht. Dieses Konzept ermöglicht eine effiziente Datenverarbeitung und -übertragung.

### 3.3.2 Hardware

Sowohl im Bereich des Edge-Computings wie auch des Cloud-Computings in der Landwirtschaft herrschen hohe Hardwareanforderungen.

---

<sup>15</sup> Ahvar, Ehsan; Orgerie, Anne-Cecile; Lebre, Adrien (2022): Estimating Energy Consumption of Cloud, Fog, and Edge Computing Infrastructures. In: *IEEE Trans. Sustain. Comput.* 7 (2), S. 277–288. DOI: 10.1109/TSUSC.2019.2905900.

<sup>16</sup> <https://www.nvidia.com/de-de/autonomous-machines/embedded-systems/jetson-xavier-nx/>

Im Falle des Edge-Computings stellen sich Hardwareanforderungen an das KI-Board, auf dem die trainierten Modelle eingesetzt werden, sowie an die Trägerhardware, meistens eine UAV. Die KI-Boards müssen genug Rechenleistung besitzen, um eine ausreichend schnelle Ausführung der trainierten Modelle zu gewährleisten, während die Trägerhardware den Rahmenbedingungen der Anwendung entsprechen muss. Im Falle einer Drohne kann das heißen, dass ein Akku ausreichend Energie für die gesamte Länge des Flugs liefert. Es lässt sich beobachten, dass bei KI-Boards rasante technische Weiterentwicklungen zu verzeichnen sind, aktuelle Modelle sind bis zu zehnmal schneller als zuvor genutzte Systeme.

Bei Cloud-basierten Anwendungen sind die Hauptherausforderungen immer größer werdenden State-of-the-Art KI-Modellen und der Verarbeitung von sehr großen Datenmengen. Vor allem Sprachmodelle und bildverarbeitende Modelle haben heute sehr viele Parameter und benötigen viele Ressourcen für Training und Inferenz. Zudem kann es vor allem bei der Verarbeitung von Bildern und Hyperspektraldaten schnell zu sehr großen Datenraten kommen, deren Verarbeitung entsprechende Hardware voraussetzt.

## 4 Fazit und Ausblick

### 4.1 Fazit und Ausblick für den Pflanzenschutz

Die zukünftige Anwendung von KI im Pflanzenschutz bietet verschiedene Entwicklungsrichtungen, in denen aktuelle Entwicklung zukünftig vertieft werden können. Ein wichtiger Aspekt ist die Entscheidungsunterstützung beim Einsatz von Pflanzenschutzmitteln. KI-Modelle können helfen, relevante Daten zu analysieren und Muster zu erkennen, um den optimalen Zeitpunkt und die geeignete Menge an Pflanzenschutzmitteln zu bestimmen. Dies ermöglicht eine präzisere und effizientere Anwendung von Pflanzenschutzmaßnahmen, was sowohl ökonomische als auch ökologische Vorteile bietet.

Darüber hinaus können KI-basierte Assistenzsysteme bei landwirtschaftlichen Entscheidungen eine große Rolle spielen. Durch die Integration von KI-Modellen können Landwirte bei der Auswahl von Pflanzensorten, der Planung von Anbauflächen und der Optimierung von Anbaupraktiken unterstützt werden. KI kann relevante Informationen liefern, um Risiken zu minimieren und Erträge zu maximieren.

Ein weiterer potenzieller Einsatzbereich besteht darin, Landwirtinnen und Landwirten Empfehlungen zu geben, indem KI-Modelle analysieren, welche Entscheidungen andere Landwirte mit ähnlichen Schädlingsbefällen oder bei ähnlichen Wetterbedingungen getroffen haben. Dies ermöglicht einen automatisierten Erfahrungsaustausch und kann zu besseren Entscheidungen führen. Der aktuelle Stand der Entscheidungssysteme im Pflanzenschutz basiert größtenteils auf klassischer Statistik. Zukünftig wird erwartet, dass KI-Modelle eine erweiterte Rolle spielen, um die Effektivität und Genauigkeit der Entscheidungsunterstützung zu verbessern. KI kann helfen, komplexe Zusammenhänge zu erkennen, nicht-lineare Muster zu analysieren und präzisere Vorhersagen zu treffen.

#### 4.1.1 Skalierung von Forschungsergebnissen in die Praxis

Eine Herausforderung, welche die Erschließung zukünftiger Anwendungsgebiete von KI-Techniken im Pflanzenschutz behindert ist, dass die Überführung von Forschungsergebnissen in die praktische Anwendung ein häufig komplexer und in Forschungsprojekten nicht vollzogener Schritt ist. Um Forschungsergebnisse auf die Ebene eines typischen landwirtschaftlichen Betriebs zu skalieren, sind jedoch eine Reihe von Überlegungen und Investitionen notwendig.

Wichtige offene Fragen in Bezug auf die Skalierung von Forschungsergebnissen in die Praxis beinhalten die Kosten-Nutzen-Analyse der entwickelten Anwendungen, die Anpassung an unterschiedliche Betriebsgrößen und -arten sowie die Akzeptanz und das Training des landwirtschaftlichen Bedienpersonals. Zudem muss geprüft werden, wie solche technologischen Lösungen in bestehende landwirtschaftliche Prozesse eingebettet werden können, um einen reibungslosen Übergang von der Forschung in die Praxis zu gewährleisten.

Beispielsweise entwickelt das Projekt *WeedAI* eine Methode zur Bewertung der Effizienz und Wirkung von neuen Unkrautbekämpfungsmethoden, -mitteln, und -maschinen, welche für den landwirtschaftlichen Sektor interessant sein könnte. Für das Überführen der Methode in die Praxis ist zu prüfen, inwiefern die technisch anspruchsvollen Methoden, wie sie im Forschungsprojekt verwendet wurden, auf die Praxis herunterskaliert werden können. Es gilt herauszufinden, welche Präzision der Sensorik und der Modelle tatsächlich benötigt werden und inwieweit diese im kommerziellen Rahmen umsetzbar sind.

### 4.1.2 Wissenschaftliche Verwertung der Forschungsergebnisse

Die Verwertung von Forschungsdatensätzen nach Ablauf der Projektlaufzeit ist ein weiterer wichtiger Aspekt für die Nachhaltigkeit und den wissenschaftlichen Fortschritt im Pflanzenschutz. Grundsätzlich steht im Raum, wie wissenschaftliche Forschungsdatensätze der Forschungsgemeinschaft zur Verfügung gestellt oder mit anderen Datensätzen zusammengeführt werden sollten, um umfangreichere Datenbanken zu schaffen und somit Synergien zu nutzen. Die Veröffentlichung großer Datensätze ist dabei ein angestrebtes Ziel, um die Transparenz und Reproduzierbarkeit von Forschungsergebnissen zu verbessern und weitere Forschungsvorhaben zu unterstützen. Erste Ansätze zur Veröffentlichung von Forschungsdatensätzen gibt es so schon an der Universität Bonn, welche bereits einige Datensätze aus Agrar-Forschungsprojekten veröffentlicht hat. Es bedarf jedoch weiterer Anstrengungen in die Entwicklung von Plattformen für das Forschungsdatenmanagement.

## 4.2 Fazit und Ausblick für KI-Projekte in der Landwirtschaft

Im Folgenden werden sowohl technische als auch organisatorische Resümees für KI-Forschungsprojekte in der Landwirtschaft diskutiert. Die technischen Schlussfolgerungen konzentrieren sich auf Themen wie Datenbeschaffung, die Überführung von Forschungsergebnissen in die Anwendung, Forschungslücken und zukünftige Entwicklungen in der KI. Die organisatorischen Schlussbetrachtungen behandeln Aspekte wie die Antragsphase, den Projektablauf, die Zusammenarbeit mit dem Fördermittelgeber und das begleitende Vernetzungs- und Transferprojekt.

### 4.2.1 Technisch und Fachlich

Die technischen Resümees behandeln verschiedene Aspekte von KI-Forschungsprojekten in der Landwirtschaft. Zunächst werden Empfehlungen zur Datenbeschaffung diskutiert, einschließlich Möglichkeiten wie Citizen Science und der Automatisierung der Datenbeschaffung. Anschließend werden Schlussfolgerungen zur Überführung von Forschungsergebnissen in die Anwendung vorgestellt, mit Vorschlägen zu einem strategischen Vorgehen zum Transfer von Forschungsergebnissen in die Anwendung. Des Weiteren werden Forschungslücken aufgezeigt, die in aktuellen Projekten bestehen und angegangen werden müssen. Schließlich werden Zukunftsthemen der KI in der Landwirtschaft behandelt, wie adaptive Netze, Datenverfügbarkeit, Sprachverarbeitung und die Vertrauenswürdigkeit von KI.

#### 4.2.1.1 Datenbeschaffung und Randbedingungen

Bei der Beschaffung von Daten für KI-Forschungsprojekte gibt es Aspekte, die in aktuellen Forschungsprojekten zu Herausforderungen geführt haben und für zukünftige Projekte bedacht werden sollten. Dabei ist anzumerken, dass die Projekte sich der Herausforderungen zu Projektbeginn nicht vollständig bewusst waren.

Häufig müssen für das Training von KI-Modellen Daten von Dritten unter bestimmten Randbedingungen beschafft werden. Die Randbedingungen der Datenbeschaffung haben dabei einen direkten Einfluss auf die Einsatzmöglichkeiten der entwickelten KI-Anwendungen. Bei der Beschaffung der Daten mit externen Dienstleistern ist zu beachten, dass eine genaue Spezifikation der benötigten Daten erforderlich ist. Daher ist es wichtig, bereits zu Beginn des Projektes über ein hohes Domainwissen zu verfügen. Dabei müssen die Randbedingungen für die Datenaufnahme frühzeitig geklärt werden. Diese Umstände können in der ersten Projektphase zu deutlichem Mehraufwand führen und müssen bei der Projektplanung mitgedacht werden.

Eine Chance für KI-basierte Forschungsprojekte ist die Zusammenarbeit mit öffentlichen Stellen und die Verwendung von öffentlichen Datensätzen. Im Rahmen des E-Government-Gesetzes sind öffentliche Stellen dazu angehalten, öffentliche Daten bereitzustellen. Es gibt jedoch noch einige Hindernisse, um das volle Potential von öffentlichen Daten zu nutzen: Zum einen fehlt es an einer standardisierten, technischen Plattform für das Teilen von öffentlichen Daten. Zum anderen kommt es häufig zu rechtlichen Problemen, vor allem im Bereich Datenschutz. Daher sollten Datenschutzfragen im Rahmen einer Bereitstellungsplattform geklärt werden. Der Aufbau einer zentralen Plattform und von standardisierten Prozessen zum Bezug öffentlicher Daten wird empfohlen. Kurzfristig wäre eine Unterstützung von Forschungsprojekten bei der Kommunikation mit staatlichen Stellen zur Beschaffung öffentlicher Daten durch die Fördermittelgeber hilfreich.

Zuletzt muss in der Antragsphase eine explizite Beschreibung der Datenbeschaffung und der späteren Veröffentlichung (Open Access) im Rahmen eines Forschungsdatenmanagementplan (FDMP) im Antrag vorgenommen werden. Hierbei sollte beachtet werden, dass die veröffentlichten Daten auch von dritten auffindbar sein sollen. Dies ermöglicht, dass die Projekte sich mit den oben genannten Herausforderungen auseinandersetzen und ausreichend Zeit und Geld für die Datenbeschaffung einplanen. Grundsätzlich sollte dabei beachtet werden, dass jede Domäne und jeder Anwendungsfall unterschiedliche Herausforderungen bei der Datenbeschaffung aufweist.

#### 4.2.1.2 Forschungsergebnisse in die Anwendung bringen

Zum Ende der Projektlaufzeit hat sich bei den betrachteten Projekten gezeigt, dass geplante Projektergebnisse in der Regel erreicht und in einer Laborumgebung umgesetzt werden konnten. Der Transfer der Projektergebnisse in die Forschung durch die Veröffentlichung von Forschungsergebnissen in wissenschaftlichen Artikeln konnte meistens umgesetzt werden. Allerdings besteht häufig ein offenes Problem bei der Überführung des Projektstands in eine fertige Anwendung, auch da ein zu hoher technischer Reifegrad häufig nicht förderfähig ist.

Um Forschungsergebnisse besser in die Anwendung zu bringen, sollte schon in der Antragsphase ein stärkerer Fokus auf Verwertungsmöglichkeiten im Rahmen des Verwertungsplans gelegt werden: Es gibt verschiedene wirtschaftliche sowie wissenschaftliche Verwertungsmöglichkeiten wie Patente, Ausgründungen als Spin-Offs oder die Lizenzierung von Forschungsergebnissen an Wirtschaftsunternehmen auf der einen Seite und wissenschaftliche Veröffentlichungen auf Konferenzen, die Veröffentlichung von Forschungsdatenset und freien KI-Modellen auf der anderen Seite. Es wird vorgeschlagen, aufbauend auf den Verwertungsplan, die geplanten Entwicklungen in der angewandten Forschung schon im Projektantrag auf Unique Selling Points, Interesse der Wirtschaft und wissenschaftliche Potentiale zu prüfen. So könnten im Rahmen der Verwertungspläne Business Model oder Value Proposition Canvas (nach Osterwalder) erstellt werden um Zielgruppen und Verwertungsmöglichkeiten von Projekten schon in der Antragsphase herauszuarbeiten. Ein Projekt hat für die Herausarbeitung der Verwertungsmöglichkeiten einen vom Fördermittelgeber geförderten Patentanwalt am Anfang des Projekts in Anspruch genommen, was erfolgreich war und daher weiterempfohlen wird. Insgesamt wurde in der Gesamtheit der in X-KIT vernetzten Projekte 10 Patente angemeldet, was als ein Schritt in die richtige Richtung gesehen werden kann.

Eine Idee bzw. Wunsch an Fördermittelgeber zur Förderung der Umsetzung von Forschungsergebnissen in die Anwendung besteht darin, dass der Projektträger einen Workshop mit dem Projekt und möglicherweise externen Partnern organisiert, um am Ende des Projekts ein wirtschaftliches Konzept zu definieren. Das Ziel ist es, einen strukturierten Ansatz unter Einbeziehung eines Dritten zu finden, wie die Projektergebnisse aus der Forschung in die Gesellschaft transferiert werden können. Ein solcher Workshop würde

sich explizit an Projekte richten, die ein ausreichendes TRL erreichen und damit veröffentlichungsfähige oder wirtschaftlich verwertbare Ergebnisse generiert haben.

#### 4.2.1.3 Optimierungspotentiale in den Projekten

Bei der Datenbeschaffung und der Überführung von Forschungsergebnissen in die Anwendung haben sich zudem einige Optimierungspotentiale in der Projektarbeit gezeigt. Dabei handelt es sich um Methoden, welche die Ergebnisse von Projekten effizienter gestalten können.

Bei der Datenbeschaffung für KI-Anwendungen in der Landwirtschaft ist die Einbeziehung von Citizen Science<sup>17</sup> ein noch wenig erforschtes Feld. Hier könnten neue Anwendungen, Datenquellen und Ideen gefunden und erschlossen werden. Bei der Aufnahme von Daten werden häufig manuelle Verfahren verwendet. Hier kann noch Optimierungspotenzial geborgen werden. Dabei muss angemerkt werden, dass Automatisierungsverfahren in der Datenaufnahme häufig eigene Projektergebnisse darstellen.

Ähnliche Probleme bestehen in der Automatisierung der entwickelten KI-Lösungen. Hierbei geht es darum, den Einsatz von KI-Systemen und Algorithmen zu automatisieren, um eine effiziente und zuverlässige Anwendung zu ermöglichen. Dies beinhaltet oft auch die Automatisierung der Datenaufnahme.

Um die Umsetzung der entwickelten Lösungen in die Anwendung zu verbessern, gibt es Forschungslücken, die angegangen werden müssen. Eine wichtige Herausforderung besteht in der Optimierung auf ökologische und ökonomische Umsetzbarkeit. Dabei spielen Faktoren wie Preis, Laufzeit, Erkennungsgüte, Stromverbrauch und die Nutzung erneuerbarer Energiequellen in der Anwendung eine Rolle. Es ist notwendig, die Effizienz sowohl in Bezug auf die Hardware als auch auf die Algorithmen zu steigern.

#### 4.2.1.4 Mittelfristige KI-Zukunftsthemen

Abschließend folgt ein kurzer Abriss über KI-Themen, die in den nächsten Jahren relevant werden können. Die stetig schnellen voranschreitenden Entwicklungen in der KI-Forschung werden auch für Projekte in der Landwirtschaft relevant werden.

Die Datenverfügbarkeit stellt eine wichtige Herausforderung dar. Es ist ratsam, Maßnahmen zur Anonymisierung von personenbezogenen Daten zu ergreifen und neue Datenquellen zu erschließen. Zudem sollten eine Aufbereitung und Bereinigung vorhandener Daten sowie die Anreicherung mit Metadaten erfolgen, um ungenutzte Potentiale zu erschließen. Hier zeigt sich die Wichtigkeit eines zentralen und strukturierten Forschungsdatenmanagement.

Um mit einer trotz allem geringen Datenverfügbarkeit umzugehen, bieten Adaptive beziehungsweise Selbstlernende Netze und Transfer Learning die Möglichkeit, KI-Modelle mit weniger Trainingsdaten zu trainieren. Es ist empfehlenswert, diese Techniken zu nutzen, um den Datenaufwand zu reduzieren und dennoch qualitativ hochwertige Modelle zu entwickeln.

---

<sup>17</sup> Citizen Science bezeichnet die Beteiligung von Bürgerinnen und Bürgern an wissenschaftlichen Forschungsprojekten, oft durch Datenerhebung, -analyse oder -interpretation. Dies ermöglicht es Wissenschaftlerinnen und Wissenschaftlern, auf eine breite Basis an Daten und Beobachtungen zuzugreifen und gleichzeitig das öffentliche Interesse und Verständnis für Wissenschaft zu fördern.

Im Bereich der Sprachverarbeitung und Large Language Models (LLMs) können Sprachmodelle für die Datenanalyse eingesetzt werden. Dies kann in landwirtschaftlichen Anwendungen das Monitoring, die Dokumentation, die Verwaltung und die Auswertung von Protokollen beinhalten. Ein vorstellbarer Anwendungsfall von LLMs ist die Digitalisierung von analogen Daten. Ein anderer Anwendungsfall kann sein, landwirtschaftliche Daten als Sequenzen zu modellieren, um LLMs und Transformer-Architekturen darauf anzuwenden.

Für die Anwendung von KI-Lösungen in der landwirtschaftlichen Praxis ist die Vertrauenswürdigkeit von KI ein entscheidender Aspekt. Es ist essenziell, die Erklärbarkeit von KI (xAI) sicherzustellen, um von der KI getroffene Entscheidungen für den Anwender nachvollziehbar zu machen. Hierbei geht es darum zu verstehen, warum die KI bestimmte Entscheidungen trifft oder Klassifikationen vornimmt. Insbesondere im Bereich der Landwirtschaft sollte dabei das Domänenwissen nicht vernachlässigt werden, sodass die Regeln und Gründe, warum die KI bestimmte Entscheidungen trifft, nachvollziehbar bleiben. Schlussendlich ist es wichtig ein gesellschaftliches Bewusstsein dafür zu schaffen, was KI leisten kann und was nicht.

## 4.2.2 Organisatorisch

Die organisatorischen Schlussbetrachtungen befassen sich mit unterschiedlichen Phasen des Projektverlaufs eines KI-Forschungsprojektes, sind jedoch auch auf Förderprojekte in anderen Domänen übertragbar. Für die Antragsphase wird die Zeitschiene eines Projekts diskutiert und Herausforderungen bei Aufstellungen und Hardwareanschaffungen sowie bei der Kommunikation mit dem Fördermittelgeber angesprochen. Zum Projektablauf und Projektvorgaben wird unter anderem das Problem neuer Anforderungen nach Projektbeginn besprochen. Abschließend wird das begleitenden Vernetzungs- und Transferprojekt hinsichtlich verschiedene Veranstaltungsformen, Clusterarbeit und der Wunsch nach mehr Informationsaustausch zwischen den Clustern diskutiert.

### 4.2.2.1 Antragsphase

Ein großes Problem für einige Projekte ist eine unklare Zeitschiene. Diese sollte zum einen bereits bei der Veröffentlichung der Ausschreibung definiert werden. Idealerweise sollten die Projekte zum anderen die Möglichkeit haben, den Startzeitpunkt eines Projektes nach dessen Bewilligung selbst festzulegen, wie es in EU-Projekten üblich ist. Ein Problem bei einem festen Starttermin besteht darin, dass die Zeit für die Einstellung neuer Mitarbeiterinnen und Mitarbeiter vor allem für forschende Einrichtungen unter den gegebenen Rahmenbedingungen in Deutschland (Wissenschaftszeitvertragsgesetz) oft nicht ausreicht, um Projektmitarbeiter einzustellen. Dies kann zu Verzögerungen und Leerlauf am Projektanfang führen und kostenneutrale Verlängerungen des Projekts am Projektende führen. Dadurch entsteht zusätzlicher bürokratischer Aufwand.

Auch bei der Planung von Dienstreisen ist es schwierig, eine genaue Aufschlüsselung dieser vor Projektbeginn vorzunehmen. Erfahrungsgemäß kommt es vor, dass es in Projekten zu zusätzlichen Dienstreisen kommen kann. Damit die Projekte flexibel auf neue Anforderungen reagieren können wird eine Programmpauschale bzw. ein Pufferbudget für Dienstreisen empfohlen.

### 4.2.2.2 Vernetzung und Transfer

Dass die Ausschreibung zu KI in der Landwirtschaft von einem Vernetzungs- und Transferprojekt begleitet wurde, ist von den an der Ausschreibung beteiligten Projekten als eine grundsätzlich gute Idee aufgenommen worden. Bei den im Projekt durchgeführten Veranstaltungsformen haben sich Präsenzveranstaltungen als besonders wertvoll und informativ sowie beliebter als Onlineveranstaltungen erwiesen. Diese können

Präsenzveranstaltungen zwar nicht vollständig ersetzen, sind jedoch in einigen Fällen notwendig, um den Aufwand, den die Projekte für das VuT-Projekt aufwenden mussten, zu reduzieren. Hier muss vor allem beachtet werden, dass die Aufwände für das VuT-Projekt nicht von der Projektförderung eingeplant werden. Onlineveranstaltungen funktionieren am besten, wenn die Teilnehmerinnen und Teilnehmer sich bereits persönlich kennengelernt haben als Ergänzung zu den Präsenzveranstaltungen. Die Nutzung von Online-Tools wie Miro oder Conceptboard hat sich bei Onlineveranstaltungen bewährt und bietet einen Mehrwert.

Bezüglich der Transferarbeit in den Clustern des VuT-Projektes wurde angemerkt, dass die Clusterarbeit in verschiedenen Clustern sich deutlich unterschiedlich gestaltete. Dabei wurde der Wunsch nach mehr Informationsaustausch zwischen den verschiedenen Clustern, um Ergebnisse und Fortschritte zu teilen, geäußert. Dies soll mehr Transparenz, Durchlässigkeit und Austausch zwischen den Clustern schaffen. In der aktuellen Form hatten einige Projekte das Gefühl spannende Transfer- und Vernetzungsmöglichkeiten durch die Entscheidung für einen bestimmten Cluster zu verpassen. Des Weiteren wäre es ideal eine Timeline über die gesamte Laufzeit des Vernetzungs- und Transfer-Projekts, die den Ablauf und die Aktivitäten in jedem Cluster zeigt. Das Feedback wurde vom Konsortium des VuT-Projektes aufgenommen und somit die Präsenzveranstaltungen, zu denen mehrere Cluster eingeladen waren, durchgeführt. Dies wurde als positiv von KI-Projekten wahrgenommen.