

Gefördert durch



Bundesministerium
für Ernährung
und Landwirtschaft

aufgrund eines Beschlusses
des Deutschen Bundestages

Projektträger



Bundesanstalt für
Landwirtschaft und Ernährung



FRAUNHOFER-INSTITUT FÜR INTELLIGENTE ANALYSE- UND INFORMATIONSSYSTEME IAIS

X-KIT: WHITEPAPER COMPUTER VISION

Whitepaper des X-KIT Cluster Computer Vi-
sion

X-KIT: WHITEPAPER COMPUTER VISION

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

Autor	Projekt	Institution	E-Mail
Lorenz Wickert	X-KIT	Fraunhofer IAIS ¹	Lorenz.Wickert@iais.fraunhofer.de
Stefan Rilling	X-KIT	Fraunhofer IAIS ¹	Stefan.Rilling@iais.fraunhofer.de
Jens Dede	mAlnZaun	Universität Bremen ²	jd@comnets.uni-bremen.de
David Wewetzer	mAlnZaun	Universität Bremen ²	wewetzer@uni-bremen.de
Christoph v. Redwitz	BETTER-WEEDS	Julius Kühn-Institut ³	christoph.redwitz@julius-kuehn.de
Michael Schirrmann	Weed-AI-Seek	Leibniz-Institut ATB ⁴	mschirrmann@atb-potsdam.de
Maximilian Trescher	KAMI	dida Datenschmiede ⁵	maximilian.trescher@dida.do
Oliver Schmittmann	WeedAI	ILT Universität Bonn ⁶	o.schmittmann@uni-bonn.de
Patrick Zimmer	WeedAI	ILT Universität Bonn ⁶	patrick.zimmer@uni-bonn.de
Christoph F. Kämpfer	BETTER-WEEDS	Julius Kühn-Institut ³	christoph.kaempfer@julius-kuehn.de
Lena Herrmann	MoviQ	DFKI ⁷	lena.herrmann@dfki.de
Michael Niedermeier	Kldetect	FORWISS ⁸	niedermeie@forwiss.uni-passau.de
Faryal Noori	Kldetect	FORWISS ⁸	noori@forwiss.uni-passau.de
Patrick Mäder	BETTER-WEEDS	TU Ilmenau ⁹	patrick.maeder@tu-ilmenau.de
Martin Rabe	BETTER-WEEDS	TU Ilmenau ⁹	martin.rabe@tu-ilmenau.de
Jonas Hüther	BETTER-WEEDS	TU Ilmenau ⁹	jonas.huether@tu-ilmenau.de

Institution	Adresse	URL
1 Fraunhofer-Institut für Intelligente Analyse- und Informationssysteme IAIS	Schloss Birlinghoven 1 D-53757 Sankt Augustin	www.iais.fraunhofer.de/
2 Universität Bremen	Otto-Hahn-Allee NW1 D-28359 Bremen	www.uni-bremen.de/
3 Julius Kühn-Institut (JKI), Bundesforschungsanstalt für Kulturpflanzen	Messeweg 11-12 D-38104 Braunschweig	www.julius-kuehn.de
4 Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB)	Max-Eyth-Allee 100 D-14469 Potsdam	www.atb-potsdam.de
5 dida Datenschmiede GmbH	Hauptstraße 8, Meisenbach Höfe (Aufgang 3a) D-10827 Berlin	www.dida.do
6 Institut für Landtechnik Universität Bonn	Nußallee 5 D-53115 Bonn	www.landtechnik.uni-bonn.de
7 Deutsches Forschungszentrum für Künstliche Intelligenz GmbH	Hamburger Straße 24 D-49084 Osnabrück	www.dfki.de
8 FORWISS - Institut für Softwaresysteme in technischen Anwendungen der Informatik Universität Passau	Innstraße 43 D-94032 Passau	https://www.forwiss.uni-passau.de/de/
9 Technische Universität Ilmenau - Data-intensive Systems and Visualization (dAI.SY)	Helmholtzplatz 5 (Zusebau) D-98693 Ilmenau	www.tu-ilmenau.de/daisy

Projektnummer: 28DK1VTC21

Datum: 16.10.2024

Inhalt

1	Einführung	4
1.1	<i>X-KIT Cluster Computer Vision</i>	4
1.2	<i>Problemstellung Computer Vision</i>	4
1.3	<i>Warum KI?.....</i>	5
1.4	<i>Aufbau des Whitepapers.....</i>	6
2	Übersicht der Projekte	7
2.1	<i>Projektbeschreibungen.....</i>	7
2.2	<i>Herausforderungen.....</i>	8
2.2.1	<i>Datengenerierung</i>	8
2.2.2	<i>Randbedingungen</i>	8
2.2.3	<i>Feature Engineering.....</i>	9
2.2.4	<i>Objekterkennung und Segmentierung</i>	9
2.2.5	<i>Überführung in die Praxis</i>	10
2.2.6	<i>Interdisziplinarität.....</i>	10
2.2.7	<i>Projektplanung</i>	10
3	Lösungsansätze.....	12
3.1	<i>Datenakquise, Hardware/Aufnahme Sensorik, Synthetische Daten.....</i>	12
3.1.1	<i>Sensoren, Kameras und Datentypen</i>	12
3.1.2	<i>Datengenerierung und Datenvorverarbeitung</i>	13
3.1.3	<i>Fallstudie: Datengenerierung und Verarbeitung im Projekt KAMI.....</i>	17
3.2	<i>ML-Verfahren.....</i>	18
3.2.1	<i>Architekturen.....</i>	18
3.2.2	<i>Randbedingungen des KI-Training: MLOps</i>	19
3.2.3	<i>Fallstudie: MLOps in Movi-Q.....</i>	20
3.3	<i>Inferenz, Deployment, Übertragbarkeit, Generalisierung</i>	20
3.3.1	<i>Deployment von KI-Anwendungen</i>	21
3.3.2	<i>Fallstudie: Deployment als Produkt in mAlnZaun.....</i>	22
4	Fazit und Ausblick.....	24
4.1	<i>Fazit und Ausblick für Computer-Vision Projekte</i>	24
4.2	<i>Fazit und Ausblick für KI-Projekte in der Landwirtschaft</i>	24
4.2.1	<i>Technisch und Fachlich</i>	24
4.2.2	<i>Organisatorisch.....</i>	27

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 X-KIT themenspezifische Cluster für eine gezieltere Vernetzung der Projekte und die Ermöglichung von Synergieeffekten aufgebaut. Der nachfolgende Bericht beschreibt die Projektergebnisse im technischen Cluster Computer Vision. Der Begriff Computer Vision beschreibt Techniken des maschinellen Sehens, also der computerbasierten Verarbeitung von Bilddaten.

1.1 X-KIT Cluster Computer Vision

Im X-KIT Cluster Computer Vision sind acht 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. Ein ähnliches Ziel, das Messen des Unkrautdrucks hat das Projekt *BoniKI*. In der Domäne der Tierhaltung entwickelt das Projekt *KAMI* ein System zur Bestimmung der Atemfrequenz von Milchkühen. Forschung zur Unkrautererkennung im Anwendungsbereich Vertical Farming wird im Projekt *Kldetect* betrieben: Die entwickelte Anwendung beschäftigt sich mit der Erkennung von Unkräutern zur passgenauen Ansteuerung von Hackwerkzeugen. Der Schutz von Herden gegen Wölfe durch eine effektive Vergrämung dieser ist das Ziel des Projekts *mAlnZaun*. Einige Produktionsschritte weiter entwickelt das Projekt *Movi-Q* eine Anwendung zur Erkennung von Fehlstellen an Erzeugnissen der Landwirtschaft. Die letzten beiden betrachteten Projekte, *WeedAI* und *Weed-AI-Seek* entwickeln beide Lösungen zur Unkrautererkennung 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. Dagegen 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 Computer Vision

Der Begriff „Computer Vision“ beschreibt alle Aktivitäten und Verfahren zur Wahrnehmung, Auswertung und Analyse von Bildern im sichtbaren Spektrum. Während dies für den Menschen ein natürlicher Vorgang ist, ist diese „Wiederherstellung der dreidimensionalen Form und des Aussehens von Objekten in Bildmaterial“ für Maschinen alles andere als trivial. Auch mit dem aktuellen Stand der Technik „bleibt der Traum, dass ein Computer ein Bild so detailliert und kausal erklären kann wie ein zweijähriges Kind, unerreichbar“. Dies liegt daran, dass es sich um „ein inverses Problem handelt, bei dem wir versuchen einige Unbekannte mithilfe von unzureichenden Informationen wiederherzustellen“, wobei es „deutlich schwieriger ist die visuelle Welt in all ihrer

Komplexität zu modellieren als z.B. den Vokaltrakt, der gesprochene Worte produziert, zu modellieren“. Die Aufgabe, welche die Computer Vision lösen will, ist daher „die Welt, die wir auf einem oder mehreren Bildern sehen zu beschreiben und in ihren Eigenschaften, z.B. Form, Beleuchtung und Farbverteilung, zu rekonstruieren.“¹ Der aktuelle Stand der Technik in der Computer Vision ist die Verwendung von KI-Algorithmen zur Lösung von Computer Vision Problemen.

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 Computer Vision auf mannigfaltige Weise zeigt.

Primär kann durch den Einsatz von KI-Methoden ein hohes Automatisierungspotential von verschiedenen landwirtschaftlichen Tätigkeiten gehoben 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. Im Projekt *BoniKI* wird ein Verfahren zur automatisierte Bonitur erarbeitet. Dieses verspricht die Bonitur im Vergleich zur manuellen Bonitur transparenter, nachhaltiger und effizienter zu gestalten. 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. Auch die automatischen Bonituren des Projekts *BoniKI* erlauben es objektive Bonituren gesamtflächig mit weniger Personal- und Zeitaufwand durchzuführen. 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. Ähnlich soll im Projekt *WeedAI* der Arbeitsaufwand der manuellen, stichproben-

¹ Alle Zitate in diesem Abschnitt sind von den Autoren ins Deutsche übersetzt und entnommen aus: Szeliski, R. (2022). *Computer vision: algorithms and applications*. Springer Nature.

basierten 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. Im Projekt *KAMI* hingegen werden Arbeiterleichterung und Kostenersparnisse aufgrund geringerer Tierverluste bei den betrachteten Milchkühen durch die Ermöglichung von frühzeitigem Gegensteuern bei Hitzestress durch Kühlungsmechanismen (Lüftung, Kuhduschen etc.) erreicht.

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. Auch die in *Weed-AI-Seek* entwickelten Anwendungen helfen, landwirtschaftliche Praxis effizienter und nachhaltiger zu gestalten. Die abschließende agronomische Auswertung in *WeedAI* ermöglicht eine Beurteilung des Pflanzenbestandes nach dem Schadschwellenprinzip (Kosten-Nutzenvergleich) und zusätzlich der Umweltleistung noch existierender Beikräuter. Die automatisierte Messung der Atemfrequenz von Milchkühen im Projekt *KAMI* ermöglicht es zudem objektive Tierwohleigenkontrollen besser durchzuführen, wobei eine tierindividuelle Erfassung der Atmungsfrequenz als Frühindikator für Stress, Schmerzen und Hitzestress genutzt werden kann. Auch Weidetiere können besser geschützt werden. So entwickelt das Projekt *mAlnZaun* ein System, welches die Anzahl der Übergriffe durch Wölfe reduzieren kann.

Final lässt sich sagen, 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. Auch die im Projekt *mAlnZaun* entwickelten Modelle zur Wolfserkennung können in weiteren Domänen und Projekten verwendet werden.

1.4 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 Computer Vision Projektes in der Landwirtschaftsdomäne. Hierbei werden Ansätze und Herausforderungen in jedem Projektschritt anhand der Erfahrungen der X-KIT Computer Vision Projekte diskutiert. Die sich aus diesen Erfahrungen ergebenden Erkenntnisse werden in Kapitel 4 in Schlussbetrachtungen und einem Ausblick zusammengeführt.

2 Übersicht der Projekte

Insgesamt acht vom BMEL geförderten Projekte haben sich an den Arbeiten im X-KIT Cluster Computer Vision beteiligt. Deren Gemeinsamkeit besteht in der Arbeit mit Bild-daten aus dem visuellen Spektrum mit dem Ziel landwirtschaftliche Prozesse effektiver und einfacher zu gestalten. In Kapitel 2.1 beschreiben die Projekte ihr grundlegendes Projektziel. Schließlich werden die Herausforderungen, die sich während der prakti-schen Umsetzung der Projektziele ergeben haben, in Kapitel 2.2 vorgestellt.

2.1 Projektbeschreibungen

Techniken der Computer Vision können in vielen Anwendungsbereichen in der Land-wirtschaft eingesetzt werden. Dies verdeutlichen die im X-KIT Cluster Computer Vision vertretenen Projekte. Nachfolgend die Selbstbeschreibungen der im Cluster vertretenen Projekte:

- **BETTER WEEDS:** Es wird ein Work-Flow zur Erstellung von Unkrautmanagement-karten erarbeitet. Diese ermöglichen Entscheidungen für die Unkrautkontrolle auf Ackerflächen in Abwägung des ackerbaulichen Risikos und des Potentials für die Erhöhung der Biodiversität.
- **BoniKI:** Ziel des Projektes ist es mittels UAS-Daten und moderner KI-Verfahren eine neue Methode für die einfache, verlässliche und flexible Bonitur von großen Feldbeständen zu entwickeln. Dabei soll eine robuste Erkennung in herausfor-dernden Szenen möglich sein. Zu diesen Herausforderungen zählen insbesondere die Überdeckung von einzelnen Pflanzenbestandteilen und die physiologischen Unterschiede aufgrund der Sortenvarianz. Mit Hilfe dieses Bonitursystems soll spe-zielles Domänenwissen, das bisher nur erfahrene Landwirte nutzen konnten, auch unerfahrenen Anwendern zur Verfügung gestellt werden.
- **KAMI:** Entwicklung eines Prototyps zur automatisierten, bildbasierten und indivi-duellen Erfassung der Atmungsfrequenz von Kühen.
- **Kldetect:** Das Projekt Kldetect 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 "grü-nen Teppichen" zielgerichtet zu steuern und damit das Unkraut selektiv zu entfer-nen.
- **mAlnZaun:** Das Ziel des Projektes ist die Erkennung von Wölfen in freier Wild-bahn. Wird ein Wolf in der Nähe einer Nutztierweide erkannt, sollen am Perimeter adaptive Stimuli den Wolf vergrämen.
- **Movi-Q:** Ein robuster KI-Algorithmus soll zur optischen Qualitätserkennung unter-schiedlicher Lebensmittel entwickelt werden. Dafür soll eine mobile Einheit zur schnellen Erzeugung von Trainingsdaten zur anschließenden Trainingsphase des KI-Algorithmus geschaffen werden.
- **WeedAI:** Das Projekt verfolgt das Ziel der Entwicklung eines automatisierten Be-wertungssystems für Unkrautbehandlungsmethoden. Hochaufgelöste Vegetati-onskarten 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 ermö-glichen, um eine selektive und teilflächenspezifische Anwendung von Pflanzen-

schutzmitteln 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 Computer Vision 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

Eine große Herausforderung in den genannten Projekten des Cluster Computer Vision ist die Akquise von Daten zum Trainieren, Validieren und Testen der zu entwickelnden und entwickelten Modellen. 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. So war es konkret in *KAMI* eine Herausforderung Kameraaufnahmen mit gut erkennbarer Atmung zu generieren und zeitgleich eine Aufnahmeposition zu finden in der eine möglichst große Anzahl an Tieren im Stall pro Tag erfasst wird. Im Projekt *Kldetect* mussten dahingegen die Beikräuter, die im Projekt analysiert werden, erst in Vertical Farming Umgebungen angepflanzt werden. Dahingegen wurde im Projekt *Movi-Q* ein mobiles Förderband mit Datenpipeline einschließlich Datenvorverarbeitung der Wellenlängenbänder einer hyperspektralen Kamera (HSI-Kamera) entwickelt. 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 Methoden¹ untersucht wird. Für viele Projekte sprechend fasst das Projekt *Weed-AI-Seek* zusammen, dass ML-basierte Projekte intensive Datenbereitstellung durch Experten (Annotation), Modelloptimierung und Hardwareintegration erfordern.

2.2.2 Randbedingungen

Die in fast allen Computer Vision Projekten vorhandenen Herausforderungen in der Datengenerierung werden in der landwirtschaftlichen Domäne durch für diese spezifische, die Datengenerierung verkomplizierende, Randbedingungen bei der Arbeit auf dem Feld oder im Stall erschwert. So beschreibt das *KAMI*-Projekt, dass das Gesamtsetup im Stall herausfordernd ist, da es nur ein begrenztes Internetdatenvolumen zum Übertragen der Daten gibt sowie das der hohe Staubgehalt, die Auswahl an Kamerapositionen im Stall zusätzlich limitiert. Ähnliche Fragestellungen beschäftigen das Projekt *mAlnZaun* bei der Erkennung von Wölfen zur Vergrämung dieser: Wie kann ein Wolf in allen möglichen Situationen erkannt werden: Am Tag, in der Nacht, bei Regen und Schnee etc.? Auch in *Movi-Q* waren Anpassungen an die Projektdomäne notwendig: Die entwickelten Techniken mussten an Anforderungen und Bedingungen der

¹ 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

Lebensmittelindustrie angepasst werden, da der Demonstrator in der direkten Produktionsumgebung zum Einsatz kommt. Exemplarisch für das Problem der Unkrautererkennung auf Felder 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 der Ausgangsdaten 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 Akquise der Daten müssen diese häufig noch in eine Form gebracht werden, so dass die KI die Ausgangsdaten 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 die Pflanzen auf einem Feld ableiten, relevant. So beschreibt das Projekt *BETTER WEEDS* die Inkorporation und Kondensation von Pflanzeigenschaften in eine Flächenkarte für agronomisches Risiko bzw. Potential für Biodiversität als neu. Im Projekt *BoniKI* stellt sich eine ähnliche Herausforderung, und zwar die klassischen Boniturparameter in Parameter umzudenken, welche mit Hilfe von KI-Verfahren und UAV-Daten ermittelt werden können. Aus einer anderen Perspektive betrachtet das Projekt *Weed-AI-Seek* das Problem des Feature Engineerings. Dort muss das Problem der unstrukturierten Sensordaten (Luftbilddaufnahmen) gelöst werden, um die hochpräzise Kartierung von Unkräutern im Flug mit der Drohne zu ermöglichen. Im Projekt *Movi-Q* mussten dahingegen Features so gewählt werden, dass die entwickelten Modelle für verschiedene Lebensmittel eingesetzt werden können.

2.2.4 Objekterkennung und Segmentierung

Nachdem eine Datenbasis geschaffen wurde, können die eigentlichen Aufgaben, die mit Hilfe von KI-basierten Computer Vision Ansätzen gelöst werden sollen, angegangen werden. Diese lassen sich grob in zwei Kategorien aufteilen: Die *Objekterkennung* sowie die *Segmentierung*, d.h. das Finden der räumlichen Verortung eines Objekts in einem Bild.

Die Objekterkennung ermöglicht dabei fachliche Informationen zu extrahieren, welche z.B.: bei der landwirtschaftlichen Entscheidungsfindung helfen können. Dies stellt sich auch mit Hilfe von KI-Methodiken als nicht-triviales Unterfangen heraus. Dies fängt schon bei der zielgerichteten Verwendung spezieller Sensorik, (z.B. SWIR-Kameras) an, wie das Projekt *Kldetect* berichtet. So konstatiert das Projekt *BETTER-WEEDS* das 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 Attentionsmechanismen verwendet. Auch für das Projekt *mAlnZaun* ist die Frage der Erkennung und Klassifizierung zentral: „Die Herausforderungen liegen bei diesem Projekt in der KI: Wie kann hier zuverlässig ein Wolf erkannt werden?“

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. So stellt sich im Projekt *BoniKI* das Problem, dass bei dichtem Bewuchs die Trennung der einzelnen Pflanzeninstanzen aufgrund von sich überlappenden Pflanzen eine Herausforderung darstellt.

2.2.5 Überführung in die Praxis

An das Training der Computer Vision Modelle und deren Deployment anschließend folgt die Eingliederung der entwickelten Technologien in den landwirtschaftlichen Arbeitsablauf. Hierfür ist es notwendig Handlungsempfehlungen, wie die entwickelte Technologie anzuwenden ist, was ihre Vorteile und welche die versteckten Fallstricke sind, zu formulieren. Diese sind unerlässlich für die nachhaltige Verwendung der entwickelten Technologie. Im Falle des Projektes *mAlnZaun* stellt sich etwa die Frage wie die Vergrämuungsmaßnahmen definiert werden: Welche Stärke, Frequenz und Reichweite funktionieren bei Wölfen? Und wann treten hier Gewöhnungseffekte ein?

2.2.6 Interdisziplinarität

Über allen Projekten zur Anwendung von KI-basierten Computer Vision Methoden in der landwirtschaftlichen Domäne schwebt die Herausforderung, dass die Projekte zwangsläufig ein hohes Maß an Interdisziplinarität erfordern. Die landwirtschaftlichen Problemstellungen, die Datengenerierung, Hard- und softwareseitig, das Training von passenden CV-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“.

2.2.7 Projektplanung

Eine weitere, alle Projekte betreffende, Herausforderung liegt in der Planung von durch Fördermittel realisierten Projekten. Häufig gibt es nach der Begutachtung der Projektanträge nur wenig inhaltliche Rückmeldungen zu den Anträgen, ob erfolgreich oder nicht. Dadurch kann es vorkommen, dass auf altbekannte Ansätze bei Technik, Algorithmen und Konfigurationen zurückgegriffen wird, die in der Vergangenheit häufig verwendet wurden und Erfolg bei Fördermittelanträgen brachten. Dies kann dazu führen, dass das komplette innovative Potential eines Projektes nicht ausgeschöpft werden kann. Abgelehnte Projekte können ihre Chancen zur Optimierung dadurch nicht vollständig nutzen.

Handlungsempfehlung: Lösungsansätze für diese Herausforderung wären zum einen eine intensivere Zusammenarbeit mit verschiedenen Fachgruppen in den antragstellenden Institutionen und zum anderen ein mehr auf inhaltliche Fragestellungen fokussierter Dialog mit den Fördermittelgebern bei abgelehnten Förderanträgen. Ein Vorbild könnte das Verfahren bei abgelehnten EU-Förderanträgen, bei denen eine detaillierte Begründung der Ablehnungsentscheidung vorgelegt wird, sein. Ein solches Verfahren müsste rechtssicher implementiert werden, was mit größeren Aufwänden auf Seiten des Projektträgers verbunden ist. Die Möglichkeit, sich telefonisch über die Gründe für die Ablehnung eines Projektantrags bei der BLE zu informieren, besteht schon heute und wird intensiv genutzt.

Tabelle 1: Überblick über die wichtigsten Projektherausforderungen

Projekte	Datengenerierung	Randbedingungen	Feature-Engineering	Objekterkennung	Segmentierung	Praxis	Interdisziplinarität
BETTER-WEEDS			x	x			
BoniKI			x		x		
KAMI	x	x					
Kldetect	x		x	x			x
mAlnZaun		x		x		x	
Movi-Q	x	x	x				
Weed-AI	x	x		x	x	x	x
Weed-AI-Seek	x	x	x	x			x

3 Lösungsansätze

In der Clusterarbeit wurden verschiedene Themen entlang den Entwicklungsprozess in einem KI-basierten Projekt in der technischen Domäne Computer Vision 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, Hardware/Aufnahme Sensorik, Synthetische Daten

Vor der Entwicklung der eigentlichen KI-Modelle in Computer Vision Projekten müssen Projektdaten, auf denen diese Modelle entwickelt werden, gesammelt werden. Der erste Schritt dahin ist die Auswahl des passenden Kamerasystems und der passenden Sensorik. Daraufhin werden Bilddaten mit dem gewählten Kamerasystem aufgenommen, vorverarbeitet und von Experten annotiert.

3.1.1 Sensoren, Kameras und Datentypen

Ein zentraler Aspekt eines jeden Computer Vision Projektes ist es, welche Art von Bilddaten analysiert und verarbeitet werden sollen. Unterschiedliche Daten- und Sensortypen ermöglichen es, verschiedene Informationen aus den aufgenommenen Bilddaten zu extrahieren. So eignen sich RGB-Daten zum Beispiel gut für eine Automatisierung des menschlichen Sehens während Dinge, die mit dem menschlichen Auge nicht wahrnehmbar sind, auf Hyperspektralkameras auffindbar sind. Relevant ist dabei auch das konkret ausgewählte physische Kamerasystem. Dessen Eigenschaften müssen auf die zu erfüllende Projektaufgabe wie auch die Aufnahmebedingungen im Projekt abgestimmt werden.

3.1.1.1 Datentypen

In der Bildverarbeitung wird grundlegend mit von Kamerasensoren aufgezeichneten Daten gearbeitet. Der Möglichkeitsraum an Sensortypen von Kameras ist dabei groß und umfasst verschiedene Sensortypen wie Farbbildkameras, Spektralkameras, Tiefenbildkameras und Wärmebildkameras. Jeder dieser Sensortypen hat spezielle Eigenschaften, Vorteile und Herausforderung und erfordert ein spezielles Wissen bei der Analyse der produzierten Rohdaten.

Grundfragen, die sich bei der Auswahl einer geeigneten Kamera für ein Projekt stellen, sind die Auswahl des richtigen Sensortyps und die Kalibrierung eines Kamerasystems für die spezifische Aufgabe. Bei der Auswahl des richtigen Sensortyps besteht dabei häufig das Problem, dass in Projekten oft keine Erfahrung damit besteht, wie mit Datentypen umgegangen werden kann, die nicht dem RGB-Format entsprechen. Wenn ein anderer Sensortyp als RGB-Sensoren benötigt wird muss die Datenweiterverarbeitung häufig erst erlernt oder entwickelt werden.

Handlungsempfehlung: Die Auswahl des verwendeten Sensors und der Umgang mit unbekanntem Datentypen sollte schon bei der Projektplanung mit eingeplant werden.

Ein neben RGB-Sensoren häufig verwendeter Sensor- und Kamerateyp sind Multi- und Hyperspektralkameras, die Daten in Form von Datenwürfeln liefern. Eine Herausforderung besteht bei diesen darin, die relevanten Informationen auf dem Datenwürfel vor-

zufiltern, um die Datenmenge zu reduzieren und die Leistungsfähigkeit der Datenanalyse durch Neuronale Netzwerke zu gewährleisten. Zudem kann bei einer Vorfilterung der Daten der Rechenoverhead bei der Datenanalyse reduziert werden. Die Motivation hinter der Verwendung von Multi- und Hyperspektralkameras liegt in der Analyse des nicht-sichtbaren Lichtwellenbereichs und der Erkennung von tieferliegenden Fehlstellen, die mit bloßem Auge nicht erkennbar sind.

Ein weiterer Kameratyp sind Tiefenkameras. Diese ermöglichen es, eine dreidimensionale Darstellung einer Oberfläche zu erzeugen. Auch dieser Datentyp kann in der Weiterverarbeitung Schwierigkeiten verursachen: Tiefenkameras können Löcher in Bildern erzeugen, die mit Algorithmen gefüllt werden müssen.

Handlungsempfehlung: Bei der Verwendung von Tiefenkameras ist es wichtig, bekannte Herausforderungen zu beachten. Hierbei sollte ein Fokus auf den Umgang mit Löchern in von Tiefenkameras erzeugten Bildern gefunden werden.

3.1.1.2 Hardwareeigenschaften

Neben der grundlegenden Auswahl der Sensortypen für ein Bildverarbeitungsprojekt ist die Auswahl eines konkreten Kamerasystems elementar. Die Auswahl von Kamerasystemen kann jedoch eine Herausforderung darstellen: Oft stehen nur begrenzte Ressourcen bezüglich Zeit und Geld für eine umfassende Evaluation verschiedener Kamerasysteme zur Verfügung. Häufig können nur wenige Kameras getestet werden oder es ist gar nicht möglich, zur Auswahl stehende Kamerasysteme zu testen.

Dies ist suboptimal, da die Auswahl von Kamerasystemen nicht trivial ist: Es müssen projektspezifische Randbedingungen berücksichtigt werden. Diese hängen mit dem Ort, an dem die Kamera installiert werden wird, mit dem benötigten finanziellen wie auch arbeitstechnischen Aufwand bei der Verwendung des Kamerasystems, der Robustheit des Systems über einen längeren Zeitraum sowie die physikalischen Eigenschaften der Kamerasensoren wie deren Sensibilität, zusammen. Zum Beispiel weisen Thermalkameras auf der einen Seite ein hohes Signal-Rauschverhältnis, verfügen dafür aber über eine niedrige Auflösung auf, was für manche Projekte ein Problem werden kann. In dieser Art treten für die verschiedenen Sensortypen und Kamerasysteme spezifische Herausforderungen auf, die bei der Auswahl und Beschaffung beachtet werden müssen.

3.1.2 Datengenerierung und Datenvorverarbeitung

Im Anschluss an die Auswahl und die Beschaffung der in Bildverarbeitungsprojekten verwendeten Kamerasysteme werden diese verwendet, um eine Datengrundlage für das Training und die Evaluation von KI-Systemen zur Erfüllung des Projektzieles zu generieren. Die Schaffung einer Datengrundlage wird in zwei aufeinanderfolgenden Schritten durchgeführt: Im ersten Schritt werden Daten auf einem Experimentierfeld mithilfe der Kamerasysteme aufgenommen. Diese Daten bilden die Datengrundlage für die weitere Arbeit in den Projekten und müssen darauffolgend annotiert werden. Diese Annotationen bilden die Wissensgrundlagen, die verwendet werden, um Computer Vision KI-Systeme zu entwickeln.

3.1.2.1 Datengenerierung

In landwirtschaftlichen Forschungsprojekten mit Fokus auf KI-Bildverarbeitung werden Daten häufig auf landwirtschaftlichen Flächen, in der freien Natur, mit dynamischen Witterungsbedingungen aufgenommen. Dies resultiert in Aufnahmebedingungen für Kameras, die häufig nicht optimal sind: Es gibt nur ein begrenztes Zeitfenster, in dem Aufnahmen gemacht werden können und in diesem können die Witterungsbedingun-

gen, wie z.B. der Lichteinfall nicht genau vorhergesagt werden, was die Festlegung eines idealen Aufnahmezeitpunktes verkompliziert.

Dies kann aber auch ein Vorteil sein: Aufgrund der späteren Anwendung von fertig entwickelten KI-Systemen unter teils widrigen Bedingungen kann es von Nutzen sein, wenn die gemachten Aufnahmen, die die Datenbasis eines Projektes bilden, nicht perfekt oder ideal sind. Unperfekte Aufnahmen können im späteren Verlauf des KI-Trainings zu besser generalisierenden Modellen führen. Allerdings können sich möglicherweise Qualitätsmetriken der trainierten Modelle verschlechtern. Da diese, vor allem in der akademischen Welt, häufig zur Bewertung von Projektergebnissen herangezogen werden, können Förderprojekte in eine Zwickmühle kommen: Werden besser generalisierende Netze, die aber in absoluten Werten schlechtere Qualitätsmetriken liefern trainiert oder schlechter generalisierende Netze die dafür aber bessere Qualitätsmetriken, und damit oberflächlich bessere Projektergebnisse liefern?

Handlungsempfehlung: Um einen Anreiz für das Training von besser generalisierenden Neuronalen Netzen zu setzen empfiehlt es sich, Computer Vision Projekte stärker an der Anwendbarkeit im Betrieb und weniger an Kennzahlen aus KI-Trainings zu bewerten. Dies würde einen Anreiz bieten Datenmaterial zu generieren, welches die Realität genauer widerspiegelt.

Der tatsächliche Ablauf des Datenakquise-Prozesses ist idealerweise iterativ: Zunächst werden Daten gesammelt, auf denen erste Modelle trainiert werden. Anschließend werden aus der Analyse der Modelle Erkenntnisse für die Generierung neuer Daten gewonnen: Welche der ursprünglichen Bilder sind aussagekräftig, aus welchen ergibt sich wenig bis kein Erkenntnisgewinn? Mittels dieser Erkenntnisse können neue Bilder aufgenommen werden, welche aussagekräftigere Informationen liefern. In der Realität gibt es jedoch häufig eine Trennung zwischen dem Team, das für die Bildaufnahme zuständig ist, und dem Team, welches die KI-Modelle entwickelt. Das KI-Team arbeitet mit dem vorhandenen Datenmaterial und versucht, das Beste daraus zu machen. Dabei hat sich herausgestellt, dass eine starke Rückkopplung zwischen beiden Teams positive Auswirkungen auf das Ergebnis der entwickelten KI hat.

Handlungsempfehlung: Eine stärkere Kopplung von den die Daten aufnehmenden Projektpartnern und den Entwicklern der KI-Anwendungen ist wünschenswert, um Synergien für die Entwicklung von KI-Lösungen zu generieren. Hierbei empfiehlt sich eine iterative Vorgehensweise, bei der sich die Phase der Datenaufnahme sowie die Phase der KI-Entwicklung abwechseln.

Neben der Aufzeichnung von Bilddaten ist die Georeferenzierung sowie das Versehen dieser mit Metadaten von großer Bedeutung. Beispielhaft besteht der Datenakquise-Workflow bei der Erstellung von Managementkarten zur Unkrautverwaltung aus der visuellen Bewertung von Pflanzen auf dem Feld, dem Fotografieren der entsprechenden Pflanzen und der Annotation der generierten Bilddaten mit der visuellen Bewertung. Alle drei Informationsquellen müssen in der Geokomponente in Übereinstimmung gebracht werden. Dies erfordert die Normalisierung der Real Time Kinematic (RTK)-Signale und die Validierung der Daten durch optisches Monitoring bei der Erstellung der Ground Truth Annotationen. Als Hilfsmittel können zur genauen Absteckung des Feldes zum Beispiel Stäbe verwendet werden, während für die Berechnung von Abständen auf Bilddaten eine Karoplatte verwendet werden kann. Auch kreative Verfahren können eingesetzt werden: So wurden in einem Projekt Abschlagpins für Golfbälle als Boniturrahmen verwendet.

Zusätzlich zu den eher fachlich einzuordnenden Herausforderungen bei der Bilddatenakquise ergeben sich auch technische Herausforderungen. Es kann schnell zu Problemen mit der aufkommenden Datenmenge, der vorhandenen Speicherkapazität, der

Verarbeitungsdauer der aufgenommenen Daten und dem Transport der aufgenommenen Daten zu den KI-Teams kommen: Festplatten oder Speicherkarten können schnell voll werden und das Übertragen der Daten auf einen Server oder einen mobilen Rechner zur Vorverarbeitung der aufgenommenen Daten können viel Zeit in Anspruch nehmen. Es muss eine Abwägung getroffen werden, ob größere aufgenommene Flächen mit geringerer Auflösung aufgenommen werden oder ob kleinere Flächen mit einer höheren Auflösung aufgenommen werden.

Ein möglicher Ansatz für den Umgang mit großen Datenmengen sind MLOps-Methoden. MLOps versucht große Datenmengen automatisiert zu verarbeiten. Dabei werden Vorverarbeitungsschritte parallelisiert und Big Data Tools wie Hadoop, Spark oder Hyperloop eingesetzt.

Unabhängig von den verwendeten Techniken zur initialen Datenverarbeitung kann die Datenübertragung ein Problem darstellen, insbesondere in ländlichen Gebieten mit schlechter Internetverbindung. Eine schlechte Internetverbindung kann zu einer langen Übertragungszeit führen, wie auch zu hohen Kosten, wenn mobiles Internet in Anspruch genommen werden muss. Eine Notfalllösung kann die Verschickung von Festplatten per Post sein, jedoch sollten Ansätze für die Datenübertragung in ländlichen Gebieten gefunden werden.

Handlungsempfehlung: Die Datenübertragung im ländlichen Raum kann zu größeren Problemen für Projekte, die mit großen Datenmengen arbeiten, führen. Es empfiehlt sich, neue Lösungen für dieses Problem zu finden und die digitale Infrastruktur im ländlichen Raum auszubauen.

3.1.2.2 Annotation von Ground Truth Daten

Nach der erfolgreichen Datengenerierung müssen aus dem so generierten Grundstock an Daten Ground-Truth Daten zum Training von KI-Modellen erstellt werden. Dafür müssen die gewonnenen Aufnahmen annotiert werden.

Die Annotierung von Ground Truth-Daten beinhaltet verschiedene Grundfragen: So muss über die Art der Annotationen entschieden werden - Sollen geometrische Formen zur Objekterkennung auf Bilddaten annotiert werden oder müssen Objekte pixelgenau segmentiert werden?

In der Praxis wird die Annotierung häufig von wissenschaftlichen Hilfskräften manuell durchgeführt. Fachlich komplexere Annotierungen, wie z.B. die Annotierung der Atemfrequenzen von Kühen auf Videodaten, müssen jedoch von Experten durchgeführt werden. Für die Annotierung von Bilddaten existieren verschiedene Werkzeuge. Ein bekanntes und häufig verwendetes Open Source Tool ist das Computer Vision Annotation Tool (CVAT).

Die Validierung der menschlichen Annotationen mit Beobachtungen von Experten ist oft ein offenes Problem. Ein Ansatz besteht darin, die Annotation auf einem Foto mit den tatsächlichen Beobachtungen, zum Beispiel auf dem Feld, abzugleichen. Dabei kann die Verwendung von Boniturrahmen, um Drohnenbilder entsprechend zuzuschneiden und einen groben Zielrahmen festzulegen, helfen. Dies ermöglicht eine genauere Zuordnung von Beobachtungen auf dem Feld zu Annotationen auf Bilddaten. Es können auch andere Sensoren eingesetzt werden, die eine Annotation oder deren Validierung ermöglichen, wie z.B. ein Sensor zur Messung der Atemfrequenz von Kühen, der genutzt werden kann, um die menschliche Annotation der Atemfrequenz von Kühen auf einem Video technisch zu verifizieren.

Ein weiteres offenes Problem ist zudem die Automatisierung von Annotationsprozessen: Hierfür gibt es verschiedene Ansätze: Eine Möglichkeit besteht darin, Sensoren, Hardware und Software zu kombinieren, um ein Annotationssystem aufzubauen. Ein Beispiel dafür ist das im Projekt Movi-Q entwickelte Annotationsförderband zur Annotation von Lebensmitteln. Das Förderband bewegt die zu annotierenden Lebensmittel unter einer Kamera hindurch, und die aufgenommenen Bilder können mithilfe einer GUI direkt annotiert werden. Dies ermöglicht eine schnelle und halbautomatisierte Annotation. Allerdings ist die Entwicklung einer solchen Annotationsstraße sehr aufwendig bezüglich des benötigten Fachwissens, der benötigten Ressourcen sowie der benötigten Zeit und kann als eigenes Projektergebnis verstanden werden.

Weitere Ansätze zur Automatisierung umfassen Semi- und Self-Supervised Learning, Few-Shot Learning und Transfer Learning. Das Ziel dieser Ansätze ist es, weniger gelabelte Daten zu benötigen und den Annotationsaufwand zu reduzieren. So kann beispielsweise mit dem sogenannten Pseudolabelling, einer Technik aus dem Bereich Semi-Supervised Learning, ein auf ImageNet trainiertes Netzwerk anhand von ungelabelten Daten aus der gleichen Domäne einen Datensatz mit Pseudolabels versehen. Diese müssen dann von Menschen überprüft werden, was schneller geht als die komplette manuelle Annotation der aufgenommenen Bilder.

Ein anderer Ansatz, ein Neuronales Netz mit wenigen gelabelten Beispielen zu trainieren, ist das Few-Shot Learning¹. Hierbei wird ein Neuronales Netzwerk auf einer großen Menge ungelabelter Bilder darauf trainiert, Ähnlichkeiten und Unterschiede zwischen zwei Bildern zu erkennen. Das fertig trainierte Netz kann daraufhin neue Bilder mit einer kleinen Anzahl gelabelter Bilder vergleichen. Die Klassifizierung erfolgt dabei für die Klasse der gelabelten Beispielbilder, zu denen das Eingangsbild am ähnlichsten ist. In den letzten 1-2 Jahren wurden zudem mit Techniken des Self-Supervised Learning Erfolge erzielt. Hierbei lernen Machine Learning Modelle Aufgaben zu lösen, ohne dass dafür von Menschen generierte Labels benötigt werden. Diese Techniken könnten in den nächsten Jahren an großer Relevanz gewinnen.

Weitere Ansätze zur Automatisierung von Annotationsprozessen umfassen den Einsatz von synthetischen Daten und siamesischen Netzen sowie die Segmentierung. Der Einsatz von synthetischen Daten ist in der Agrardomäne noch nicht weit verbreitet. Ein Problem besteht darin, dass Ground Truth-Daten zur Validierung von synthetischen Daten nicht immer ausreichend vorhanden sind.

Siamesische Netze sind Architekturen, die weniger gelabelte Daten benötigen. Dabei wird eine Eingabe in zwei verschiedenen Ausprägungen eingegeben, um die Lernfähigkeit zu verbessern. Ein weiterer Ansatz ist die Verwendung von vortrainierten Netzen zur Objektsegmentierung. Diese können automatisiert neue Bilddaten vorsegmentieren. Diese müssen dann lediglich von einem Menschen angepasst werden. Erste Versuche hierzu wurden im Projekt Weed-AI mit vielversprechenden Ergebnissen bei der automatisierten Segmentierung von Unkraut durchgeführt.

Handlungsempfehlung: In der Agrardomäne sind Ansätze zum Training von Neuronalen Netzen mit weniger Trainingsdaten als im klassischen supervised learning sowie Ansätze zur Automatisierung von Annotationsprozessen noch nicht so weit verbreitet. Hier zeigt sich ein großer Forschungsbedarf.

¹ [https://en.wikipedia.org/wiki/One-shot_learning_\(computer_vision\)](https://en.wikipedia.org/wiki/One-shot_learning_(computer_vision))

3.1.3 Fallstudie: Datengenerierung und Verarbeitung im Projekt KAMI

Der Umgang mit großen Datensätzen, auch Big Data genannt, kann anhand von drei Variablen kategorisiert werden: Volume, Velocity und Variety. Volume bezieht sich dabei auf die Größe der Datensets, Velocity auf die Geschwindigkeit, mit der neue Daten generiert werden und Variety auf die Varianz bezüglich Syntax und Semantik der Daten.

Der Datenerzeugungs- und Verarbeitungsprozess im Rahmen des Projekts *KAMI* zeigt, wie sich diese Eigenschaften von Big Data auf die Arbeit in Computer Vision Projekten ausüben kann: Die erzeugten Datenmengen sind enorm, was einem hohem Volume entspricht, und haben eine hohe Velocity: Die Datenmengen wachsen schneller als sie über das Internet abtransportiert werden können. Die Vielfalt der Daten, die Variety, ergibt sich aus der Überwachung von Kühen im Stall mithilfe von Tiefenkameras, die RGB-Bilder samt Tiefeninformationen liefern. Diese Frames fallen als Bilddaten an, die einzeln gespeichert werden.

Der geschickte Umgang mit den anfallenden Daten ist dabei von einem praktischen Problem in landwirtschaftlichen Projekten gezeichnet: Der unzureichenden Internetverbindung über Mobilfunkmasten in ländlichen Regionen. Aufgrund der hohen Velocity der Daten, der Geschwindigkeit mit der Daten erzeugt werden, und den niedrigen Übertragungsraten mussten spezielle Maßnahmen ergriffen werden, um die Daten aus dem Stall zu den Forschenden zu bekommen: Hier wurde als technischer Ansatz die Technologie SyncThing gewählt, ergänzt durch ein "Turnschuhnetzwerk" – das physische Kopieren der Daten auf Festplatten und deren Transport mit Bus, Bahn oder Auto: Dies erforderte eine enge Absprache zwischen verschiedenen Projektpartnern.

Aufgrund der hohen Datenmenge kam es dabei zu weiteren praktisch-technischen Problemen. So wurde beobachtet, dass Ordnerstrukturen mit mehr als 10.000 Dateien schwer handhabbar sind und daher besser als Zip-Dateien archiviert werden sollten. Daraus ergab sich die Notwendigkeit, die Integrität der ankommenden Daten mittels Checksums zu überprüfen. Eine Alternative, um das Problem zu entschärfen wäre das Abspeichern der Bilder als Video mithilfe von Videocodecs. Dies könnte die Größe der zu speichernden Daten verringern.

Zusätzlich zu den von Sensoren aufgenommenen Daten wurden im Projekt *KAMI* Ground Truth Daten ermittelt. Vor allem diese Ground Truth Daten weisen, verglichen mit den eigentlichen Sensorwerten, eine hohe Variety auf. Die Ground Truth wurde mithilfe manueller Zählungen und durch zusätzliche LED-Sensoren erstellt. Vor allem die manuelle Zählung durch menschliche Experten ist nicht trivial: Um die Datenverarbeitung zu vereinheitlichen, ist es zwingend notwendig, dass die von Experten aufgenommenen Protokolle aus dem Stall in einem einheitlichen Format vorliegen, damit sie mit den aufgenommenen Sensorwerten in Übereinstimmung gebracht werden können.

Nachdem alle notwendigen Daten aus dem Stall übertragen sind, wurden diese mit Videobearbeitungstechniken weiterverarbeitet. Bei der Videoverarbeitung wurde eine selbstgebaute Python-Library entwickelt, die zwar aufwendig in der Erstellung war, aber sehr genau auf die spezifischen Aufgaben des Projekts abgestimmt ist. Die Verarbeitung erfolgt über eine Datenverarbeitungs-pipeline, die Caching, Wiederholbarkeit und Nachvollziehbarkeit ermöglicht. Hierbei stellt sich die offene Frage, ob es effiziente Alternativen zu solchen Pipelines gibt, die in ähnlicher Weise die spezifischen Bedürfnisse des Projekts erfüllen könnten.

Bei der Entwicklung von Datenpipelines ist abzuwägen, ob die notwendigen Module selbst geschrieben werden oder ob auf etabliert Tools zurückgegriffen wird. Hinsichtlich der Datenverarbeitung von großen Datenmengen können sich Big Data Tools wie

Apache Spark anbieten. Diese ermöglichen die Datenvorverarbeitung durch Parallelisierung zu beschleunigen, allerdings stellt sich die Frage nach dem Verhältnis vom initialen Aufwand, die Tools an den eigenen Use Case anzupassen und den darauf erreichten Optimierungen.

Zur Entwicklung von Verarbeitungspipelines kann Apache Airflow verwendet werden. Airflow ermöglicht die Erstellung von Verarbeitungspipelines und ein strukturiertes Arbeiten in Docker Containern, was die Wiederverwendbarkeit von Prozessen und die zeitgesteuerte Ausführung von Aufgaben erleichtert, was wiederum die Effizienz des Workflows steigern könnte. Diese Tools bieten Potenzial für die Optimierung der Datenverarbeitung, jedoch muss der Nutzen im Kontext der spezifischen Anforderungen des Projekts genau abgewogen werden.

Handlungsempfehlung: Im Projekt KAMI konnten die Probleme bei der Datenverarbeitung zu Projektbeginn nicht vorausgesehen werden. Es empfiehlt sich die Datenverarbeitung schon bei der Projektplanung mitzudenken und den Umgang mit Big Data (Velocity, Volume and Variety) im Blick zu behalten.

3.2 ML-Verfahren

Nach häufig ausgiebigen Datenbeschaffungsprozessen können in Computer Vision Projekten in der Landwirtschaft KI-Modelle trainiert werden. Dafür sind zwei Fragen fundamental: Welche Modelle und Techniken verwendet werden und wie die KI-Modelle verwaltet werden. Die erste Frage beschäftigt sich dabei mit den Ergebnissen der KI-Forschung der letzten Jahre, abgeleitet nach den Projektanforderungen während für die zweite Frage Methoden des Machine Learning Operations (MLOps) verwendet werden können.

3.2.1 Architekturen

In Computer Vision Projekten in der Landwirtschaft werden verschiedene ML-Architekturen eingesetzt. Das folgende Kapitel soll einen grundlegenden Überblick über die Modelllandschaft der KI-Verfahren im Gebiet Computer Vision liefern. Die Entscheidung, welches Modell in einem Projekt verwendet wird ist dabei höchst spezifisch und hängt von vielen Faktoren wie den Input-Daten, dem schon vorhandenen Wissen zu verschiedenen Mitteln, die zur Verfügung stehenden Rechenleistungen und der Aufgabe, die von den Modellen erfüllt werden soll, ab. Daher wird im Folgenden keine tiefergehende Empfehlung für oder gegen eine bestimmte Modellart gegeben.

Die am weitesten verbreiteten Architekturen sind (vortrainierte) Vision/Visual Transformers (ViT) sowie Convolutional Neural Networks (CNNs). CNNs sind die in den letzten Jahren am häufigsten verwendete Architektur für Bildverarbeitungsprobleme. Sie werden meistens zur Klassifizierung von Bildern oder zur Objekterkennung in Bildern verwendet. Außerdem können sie mit anderen Architekturen, zum Beispiel klassischen Machine Learning Modellen wie XGBoost oder mit Transformern kombiniert werden.

Der Einsatz von Transformern im Bildverarbeitungsbereich ist vor allem in den letzten Jahren stark gestiegen. Dabei werden im Großteil der Fälle vortrainierte Transformer, die daraufhin auf das gegebene Bildverarbeitungsproblem angepasst werden, verwendet. Ein beispielhafter Anwendungsfall ist die Schätzung von Entfernungen in RGB-Bildern. Dabei werden Transformer auf Videos trainiert und nutzen eine Regression ohne direktes Wissen über die reale Welt zur Bestimmung von Entfernungen auf einem Bild. Das Ergebnis ist eine Distanzkarte, die die Entfernung von der Kamera darstellt (Monodepth). Die Leistung von Transformern kann CNNs übertreffen, jedoch ist die Performancesteigerung in den meisten Fällen nicht sonderlich hoch.

Neben Visual Transformers und CNNs können mit einigen Anpassungen auch andere Architekturen im Bildverarbeitungsbereich eingesetzt werden. Eine mögliche Architektur ist XGBoost, die in Verbindung mit einem CNN wie zum Beispiel VGG16 verwendet werden kann, um Bilder zu analysieren. Dabei können vortrainierte CNN-Modelle verwendet werden, deren Klassifikationsschicht als Eingabe in das mit XGBoost erstellte Random Forest Modell dient. Dies bietet den Vorteil, dass mit einer geringen Datenmenge gearbeitet werden kann und weniger Trainingsiterationen erforderlich sind. Die Anwendung findet beispielsweise in der Verarbeitung von Satellitenbildern statt.

Zudem gibt es weitere Verfahren zur Analyse von Bildern, die nicht auf Machine Learning Techniken basieren. Ein Beispiel für eine solche Technik sind statistische Formmodelle (Statistical Shape Models, SSM). Diese zeichnen sich durch hohe Erklärbarkeit, sowie eine einfachere Handhabung verglichen mit ML-Modelle aus. SSMs können zur Bildverarbeitung wie auch zur Datenaugmentation für CNNs und andere Datentypen, genutzt werden. Die Idee dahinter ist, die Eingangsdaten als 3D-Modelle zu modellieren, welche im nächsten Schritt zur Manipulation der Ausgangsdaten und Generierung neuer Daten verwendet werden können.

3.2.2 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 Computer Vision Projekte 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 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.

3.2.3 Fallstudie: MLOps in Movi-Q

Wie zuvor beschrieben, wird im Projekt Movi-Q ein mobiler Prototyp entwickelt, welcher über KI-basierte Algorithmen Fehlstellen an Lebensmittelprodukten erkennt. Das Edge-Device, welches im mobilen Prototypen integriert ist, ist aus Softwaresicht modular aufgebaut. Es beinhaltet ein Modul für die Aufnahme und das Sammeln der Daten, ein Modul für den KI-Inference Server, sowie eine Schnittstelle zur Ansteuerung eines Roboters. Insgesamt werden die Daten von vier verschiedenen Kamerasystemen auf dem Edge-Device verarbeitet, wodurch eine reibungslose Interprozesskommunikation und eine Performance im Near Real Time gewährleistet werden muss. Weitere Herausforderungen sind eine kontinuierliche Übertragung der Daten zu einer externen Recheneinheit, sowie die Bereitstellung neu trainierter KI-Modelle.

Am DFKI selbst wurde in den vergangenen Jahren daran gearbeitet eine MLOps Infrastruktur zu integrieren, um langfristig die Entwicklung von KI-Modellen effizienter zu gestalten. Die vorhandene Infrastruktur wurde folglich auch in Movi-Q verwendet und in Teilen anhand der Projektarbeit weiterentwickelt. Basis der MLOps Infrastruktur stellt ein Kubernetes Cluster dar, auf welchem benötigte Tools installiert und bereitgestellt wurden. Für die Entwicklung der KI-Modelle im Rahmen des Projekts wurde eine automatisierte Pipeline durch das Workflow Management Tool Apache Airflow aufgebaut.

Diese Pipeline beinhaltet die Datenvorverarbeitung, das Modell Training, sowie das Bereitstellen einer neuen Modell Version. Der gesamte Prozess kann neu ausgeführt werden, sobald neue Daten über den Prototypen aufgezeichnet und übermittelt wurden.

Die Entwicklung hinsichtlich MLOps in Movi-Q spiegeln einen allgemeinen Trend wider, der auf eine stärkere Zusammenarbeit und die Verlagerung von Prozessen in die Cloud hinausläuft, wodurch Synergien geschaffen und die Effizienz gesteigert wird.

3.3 Inferenz, Deployment, Übertragbarkeit, Generalisierung

Finalisiert wird ein Computer Vision Projekt in der Landwirtschaft durch das Deployment der erfolgreich entwickelten und trainierten KI-Modelle in der Zielanwendung. Dafür wird eine Software, welche die Interaktion mit den trainierten Modellen ermöglicht, entwickelt und auf Hardware, welche in der Anwendungsdomäne integriert wird, installiert. Der Schritt des Deployments in landwirtschaftliche Anwendungen ist nicht trivial.

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 Deployment von KI-Anwendungen

Das Deployment von KI-Anwendungen nach dem Training eines Modells ist ein wichtiger Schritt, um die entwickelte KI in der Praxis einzusetzen. Dabei lassen sich Best Practices und Anwendungsmöglichkeiten aus Projekterfahrungen in X-KIT herausarbeiten.

Eine Methode zur Verwendung von Bildverarbeitungsmodellen, die in *Movi-Q* verwendet wurde ist, die Ausgabe des KI-Modells mit einer Reaktion einer Steuereinheit, z.B. der eines Roboters, zu verbinden. Dies ermöglicht den Bau von Anwendungen, die basierend auf dem Analyseergebnis eines KI-Modells situativ handeln können.

Die Implementierung eines solchen Systems kann durch die Verwendung von speziell angepassten AI-Edge-Geräten erreicht werden. Dabei werden die Modelle über Schnittstellen auf dem Edge-Gerät bereitgestellt. Wenn die Aktoren der Anwendung auf derselben Einheit wie die KI-Modelle integriert sind ermöglicht dieses Setup schnelle, reaktive Anwendungen. Eine auf diese Art in der Zielumgebung eingesetzte Anwendung kann um einen cloudbasierter Update-Zyklus ergänzt werden, über den das trainierte Modell auf dem neusten Stand gehalten werden kann.

Ein alternatives Deployment-Setup besteht darin, dass ein lokaler Computer die Inferenz durchführt und die Ausgabe über TCP/IP an die User Schnittstelle sendet. Dies kann beispielsweise mit dem Nvidia Jetson KI-Board implementiert werden, um eine bessere Kontrolle zu gewährleisten.

Ein Problem beim Deployment von KI-Modellen ist häufig das Verteilen von neu trainierten, besseren KI-Modellen in die eingesetzte Anwendung. Wenn KI-Modelle auf verschiedenen AI-Edge-Geräten installiert werden, kann dies jedoch eine Herausforderung darstellen, wenn das zugrunde liegende KI-Modell ausgetauscht werden muss. Hier bietet sich das erwähnte Cloud-Update Schema an, bei dem die Modelle in einer Cloud bereitgestellt werden und an alle Edge-Geräte automatisiert verteilt werden.

Ein Ansatz zur automatischen Bereitstellung ist die Verwendung von einer CI/CD-Umgebung wie GitLab, welche es ermöglicht Pipelines für das automatische Deployment zu definieren. Dabei werden die trainierten KI-Modelle vor ihrer Auslieferung auf die Genauigkeit der Analyseergebnisse auf einem Testdatensatz getestet.

Es gibt jedoch auch Herausforderungen und Probleme beim Deployment von KI-Anwendungen. So kann die Verwendung von kommerziellen Geräten, wie zum Beispiel von Siemens PLC Steuereinheiten für Inferenz und Aktoren auf demselben Gerät zu Problemen führen. Diese Maschinen haben häufig ein stark spezialisiertes Betriebssystem, welches möglicherweise keine Installation von Software von Drittanbietern zulässt. Dies kann zu Problemen beim Installieren der für die KI-Modelle benötigten Software führen. Doch selbst wenn die Installation von Fremdsoftware möglich ist, kann es durch verschiedene, zueinander konfliktäre Softwareversionen zu Problemen kommen. Hier empfiehlt sich eine Versionierung der Produktionsumgebungen von KI-Modellen, zum Beispiel durch die Verwendung von Virtualisierungssoftware wie Docker.

Eine weitere Herausforderung beim Deployment von KI-Systeme ist, dass KI-Inferenzen oft leistungsstarke Hardware erfordern, und die Hardware, auf der das Deployment erfolgen soll, daher über ausreichende Hardware-Ressourcen verfügen muss. Hier muss gegebenenfalls zwischen der Wirtschaftlichkeit und der Performanz der verwendeten Hardware abgewogen werden.

Generell empfiehlt es sich, den Aufwand für das Deployment, also die Arbeit mit der Hardware sowie die Konfiguration der Software so früh wie möglich in einem Projekt aufzuwenden. Je früher Vorbereitungen für das Deployment der zu entwickelnden KI-Systeme betrieben wird, desto einfacher ist das schlussendliche Deployment.

3.3.2 Fallstudie: Deployment als Produkt in mAlnZaun

Das Projekt *mAlnZaun* zielt darauf ab Weidetiere mithilfe eines intelligenten Systems aus Zaunpfählen mit Erkennungs- und Vergrämungssystemen vor Wolfsangriffen zu schützen. Die Sensorik der Zaunpfähle wird dabei vorkonfiguriert, die Erkennung von Wölfen ist KI-basiert.

Eine Kernherausforderung des Projektes ist die entwickelte Technologie so einzusetzen, dass diese als Produkt verwendet werden kann. Eine Schwierigkeit besteht darin, dass eine Datenübertragung auf dem Land oft nur eingeschränkt möglich ist, was eine Auswertung von durch die Sensoren aufgenommen Bildern in der Cloud verhindert. Daher sind die KI-Modelle auf Hardware auf den Zäunen selbst installiert und die entwickelte Technik arbeitet im operativen Betriebsmodus autark, sowohl in Bezug auf die Auswertung als auch auf die Stromversorgung. Während der Wartungsphasen, bei denen die Sensorpfähle zurück zum Landwirt gebracht werden, ist ein Internetzugang für Updates und Datenübertragungen notwendig. Während dieser Phasen können neu trainierte Modelle auf die Zaunpfähle eingesetzt werden.

Beim Betrieb auf der Weide müssen die mobilen Zaunpfähle ohne GPS auskommen und ihre Positionen durch das Abschätzen von Abständen zueinander über Signalstärken selbst bestimmen, da eine durchgängige GPS-Nutzung nicht energieeffizient wäre. Zudem speichern die Pfähle nur einen Teil der aufgenommenen Bilder, um eine schnelle Speicherplatzsättigung zu vermeiden.

Nach Nutzungsende werden die Sensoren zum Landwirt zurückgebracht, wo über Breitbandverbindungen Daten in die Cloud für das Retraining von Modellen und Updates übertragen werden. Das System ist so konzipiert, dass es mit minimaler Nutzerinteraktion auskommt und auch für Laien einfach bedienbar ist. Dabei soll eine Zero-Update-Zeit erreicht werden, indem die Zaunpfähle selbst erkennen, wann sie sich beim Landwirt befinden und sich aktualisieren können, als Vorstufe dazu erfolgt der Wechsel zwischen Einsatz- und Update-Modus noch manuell per Knopfdruck.

Im Backend werden Modelle kontinuierlich mit neuen Daten neu trainiert und angepasst, wobei sowohl generalistische als auch ortsspezifische Modelle entwickelt werden. Diese Modelle stehen zum Download bereit und variieren je nach Einsatzgebiet (Alm, Gebirge, Küste) sowie nach den Ereignissen, die zur Trainingsdatenerweiterung beitragen. Um die Modelle neu zu trainieren oder anzupassen müssen die im Einsatz aufgenommenen Bilder gelabelt werden. Dabei werden beim Labeling für Object Detection neue Bounding Boxes für das Feintuning der Modelle erstellt, basierend auf Labels aus vorherigen Objekterkennungsmodellen oder durch Crowd-Sourcing, wenn die Genauigkeit, der von schon vorhandenen Objekterkennungsmodelle generierten Bounding Boxes, nicht ausreicht.

Die Modelle, die im *mAlnZaun*-Projekt implementiert wurden, sind unter Berücksichtigung der Zielhardware entworfen worden und basieren aktuell auf dem Yolo-Framework, wobei die Modellgröße zwischen 4MB und 180MB liegt. Hier muss zwischen Erkennungsgeschwindigkeit und Präzision abgewogen werden.

Die Entwicklung des *mAlnZaun*-Systems betonte von Beginn an die Produktentwicklung, mit dem Fokus auf Einsatzbarkeit, Robustheit und Wirtschaftlichkeit, basierend auf der Annahme einer bereits bestehenden Machbarkeit. Der Entwicklungsfokus lag

auf dem automatisierten, laienfreundlichen Deployment, um eine einfache und breite Anwendung der *mAlnZaun*-Technologie zu gewährleisten.

Lösungsansätze-----

Handlungsempfehlung: Das Projekt mAlnZaun zeigt exemplarisch, dass, um ein produktnahes Ergebnis zu erreichen, die Schritte dorthin schon zu Projektbeginn mitgedacht werden müssen.

4 Fazit und Ausblick

4.1 Fazit und Ausblick für Computer-Vision Projekte

Im Rahmen eines clusterübergreifenden Präsenztreffens am Fraunhofer IFF in Magdeburg wurde ein Workshop in Form eines World Cafés durchgeführt. Dort wurde diskutiert, wie die Projektergebnisse und -erkenntnisse für Plattformlösungen oder alternative Lösungen genutzt werden können und welche KI-Zukunftsthemen die Plattformlösungen der Zukunft auf welche Weise verändern werden.

Es wurde erörtert, wie eine klare Kommunikation über die Nutzung von Daten etabliert werden kann, die sowohl klare Konzepte umfasst als auch Informationen darüber bereitstellt, wo Daten veröffentlicht werden. Die Notwendigkeit, Veröffentlichungsrechte von Daten transparent zu machen, wurde betont, insbesondere vor dem Hintergrund, dass Datenveröffentlichungen allgemein in Forschungsprojekten aufgrund von Datenschutzvorschriften, wie der DSGVO, nicht immer möglich sind. Des Weiteren wurde die Problematik angesprochen, dass eine Veröffentlichung von Software aus geförderten Forschungsprojekten Wettbewerbsverzerrungen nach sich ziehen kann. Zudem kann es zu bürokratischen Hürden kommen, die beispielsweise die Veröffentlichung von Entwicklungen auf bestimmten Technology Readiness Levels (TRL) einschränken. Die Möglichkeit, Labeling-Toolchains direkt in Repositories zu teilen und nutzbar zu machen, wurde als eine potenzielle Lösung vorgestellt, ebenso wie die Option, diese Toolchains zu veröffentlichen.

Weiterhin wurden als KI-Zukunftsthemen Konzepte wie KI-Fusion (als Fortführung von Sensor Fusion), und die Erstellung von KI-generierten, sprachübergreifenden Ontologien, die UC-spezifisch sind und von großen Sprachmodellen verifizierte Antworten liefern, angesprochen. Diese könnten zur Erklärbarkeit von KI-Entscheidungen beitragen. Außerdem wurde die Nutzung von KI zur Erstellung synthetischer Daten und die Qualität dieser generativen Daten diskutiert, sowie die semantische Suche von Datensätzen als ein zukunftsweisendes Thema erkannt.

Auch wenn die im Workshop erarbeiteten Erkenntnisse ein breites Themenspektrum abdecken, besitzen sie für das Cluster Bildverarbeitung eine hohe Relevanz. So sind z.B. Fragen der Verfügbarkeit von Trainingsdaten oder synthetische Daten auch außerhalb von Plattformanwendungen in der Bildverarbeitung wichtige Themen.

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 Vorschlä-

gen 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 öffentlichen, auffindbaren Veröffentlichung (Open Access) im Rahmen eines Forschungsdatenmanagementplan (FDMP) im Antrag vorgenommen werden. Hierbei sollte beachtet werden, dass die veröffentlichten Daten auch von dritten, zum Beispiel im Rahmen einer zentralen Forschungsdateninfrastruktur, 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 aufweisen.

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 Science¹ 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.

¹ 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.

Um die Umsetzung der entwickelten Lösungen in die Anwendung zu verbessern, gibt es Forschungslücken, die angegangen werden müssen. Zum Beispiel besteht noch Forschungsbedarf in Bezug 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 schneller 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 Forschungsdatenmanagements.

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.

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 Projektmitarbeiterinnen und Projektmitarbeiter rechtzeitig 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.