

Über der Nonnenwiese 1 • 99428 Weimar
☎ +49 3643 8684-0 • 📠 +49 3643 8684-113
✉ kontakt@iab-weimar.de • 🌐 www.iab-weimar.de

SCHLUSSBERICHT I2441F001-SB0011-25

Projekt-Nr.: 2023 LFE 0011

FuE-Einrichtung: Institut für Angewandte Bauforschung Weimar gGmbH

Titel des Vorhabens: Sustainable PhenoAI – Entwicklung einer nachhaltigen KI zur Unterscheidung von Unkraut und Hauptkulturen durch Segmentierung

Kurztitel: **PhenoAI**

Projektlaufzeit: 01.09.2023 - 28.02.2025

Gefördert vom: Thüringer Ministerium für Infrastruktur und Landwirtschaft


Projektträger:




Seiten: 22

Anlagen: keine

Weimar, 25.06.2025



Dipl.-Ing. Robert Fetter
Institutsdirektor



Dr.-Ing. Justus Lipowsky
Leiter Forschungsbereich

Inhaltsverzeichnis

1	AP 1: Vorbereitung (September 2023)	3
2	AP 2 u. 3: Datenerfassung/ Datenbank (09/2023 – 11/2023; 02/2024 – 11/2024)	4
3	AP 4: Datenannotation (09/2023 – 02/2025)	5
4	AP 5: Augmentierung durch Generative Adversarial Networks (01/2024 – 05/2024)	8
5	AP 6: Synthetische Datensatzerweiterung (01/2024 – 05/2024)	9
5.1	Erstellung von 3D-Pflanzenmodellen durch Photogrammetrie	9
5.2	Aufbau realistischer Umgebungsmodelle	12
5.3	Nutzen und Ausblick	14
6	AP 7: KI-basierter Algorithmus (06/2023 – 06/2024)	14
6.1	Datenaufbereitung und Augmentierung	15
6.2	Trainingsprozesse und Metriken	15
6.3	Validierung und Ergebnisse	16
6.4	MLOps	16
6.4.1	Was ist MLOps?	17
6.4.2	Aufbau des MLOps-Systems in PhenoAI	17
6.4.3	Automatisierung und Skalierbarkeit	18
7	AP 8-10: Deployment und Test des Phenotyping-Algorithmus auf dem E-TERRY	18
7.1	Entwicklung und Integration (AP 8 u. 9)	18
7.2	Testaufbau und Validierung (AP 10)	18
8	AP 11: Öffentlichkeitsarbeit (12/2024 – 02/2025)	19
9	AP 12: Management u. Verwaltung (09/2024 – 02/2025)	20
9.1	Finanzmanagement und Abrechnungen	20
9.2	Projektkoordination und Schnittstellenmanagement	21
9.3	Controlling und Qualitätssicherung	21
	Abbildungsverzeichnis	22

1 AP 1: Vorbereitung (September 2023)

Im September 2023 begann das Projekt PhenoAI mit einer intensiven Vorbereitungsphase, die im Arbeitspaket 1 strukturiert umgesetzt wurde. Ziel war es, die organisatorischen, technischen und personellen Grundlagen für den Projektverlauf zu schaffen und alle Projektbeteiligten inhaltlich und strategisch aufeinander abzustimmen.

Ein zentrales Element dieser Phase war der Kick-off-Workshop, der gemeinsam mit allen Kooperationspartnern stattfand. Beteiligt waren unter anderem das Thüringer Landesamt für Landwirtschaft und Ländlichen Raum (TLLLR), der Biohof Scharf, das IAB – Institut für Angewandte Bauforschung Weimar gGmbH, das Thüringer Agrarbildungszentrum (ThAB) sowie das Technologieunternehmen E-TERRY. Der Workshop diente nicht nur der Vorstellung der Projektziele und Meilensteine, sondern insbesondere dem interdisziplinären Austausch. Agronomen, Landwirte und Technikspezialisten diskutierten gemeinsam die technischen Herausforderungen und spezifischen Anforderungen der Feldrobotik im Kontext der Pflanzenphänotypisierung.




Bild 1: Nvidia AGX Orin Developer Kit




Bild 2: Unterseite des AGX Orin Entwickler-Kits

Im Rahmen dieser Abstimmung wurde außerdem die Hardwareauswahl getroffen. Dabei fiel die Entscheidung auf bewährte und leistungsfähige Komponenten, die für den Einsatz im Freiland geeignet sind. Für die Bildaufnahme wurde die ZED 2I-Kamera ausgewählt, eine stereoskopische RGBD-Kamera mit hoher Tiefenschärfe. Als Recheneinheit entschied man sich für das Jetson Orin AGX Board (Bild 1: Nvidia AGX Orin Developer Kit), das speziell für KI-Anwendungen im Edge-Computing-Bereich konzipiert ist. Als mobile Plattform wurde der modulare E-TERRY-Roboter (Bild 3: E-Terry Roboter) vorgesehen, der bereits über eine ROS2-kompatible Architektur verfügt und sich flexibel an verschiedene Einsatzzwecke anpassen lässt.



Bild 3: E-Terry Roboter

Parallel dazu wurde der personelle Aufbau des Projektteams vorangetrieben. Zur Unterstützung der technischen und operativen Tätigkeiten wurde ein Werkstudent eingestellt. Er übernahm Aufgaben im Bereich der Systemintegration, unterstützte bei der Erfassung erster Testdaten und half bei der Einrichtung der Hardware im Feld. Insgesamt bildete AP 1 den soliden Grundstein für den praktischen Projektstart und ermöglichte durch sorgfältige Planung und Abstimmung einen reibungslosen Übergang in die nächsten Arbeitspakete.

2 AP 2 u. 3: Datenerfassung/ Datenbank (09/2023 – 11/2023; 02/2024 – 11/2024)

Das Arbeitspaket 2 konzentrierte sich auf die systematische Erfassung hochwertiger Bilddaten unter realen Feldbedingungen (Bild 4: Von Ollendorf gesammeltes Bild mit seiner Beschriftung). Diese Daten stellen die Grundlage für sämtliche nachgelagerten Arbeitsschritte wie Annotation, Modelltraining und Validierung dar. In einem mehrstufigen Ansatz wurden sowohl technische Komponenten aufgebaut als auch praktische Erhebungen in verschiedenen Agrarumgebungen durchgeführt.

Ein zentrales Element war der Aufbau eines Kamera-Dollies, einer mobilen Plattform zur manuellen Bilddatenerhebung. Der Dolly wurde mit einer ZED 2I RGBD-Kamera, einer Go-Pro für zusätzliche Videoaufnahmen sowie einem leistungsstarken Laptop zur Datenspeicherung ausgestattet.

Durch die manuelle Steuerung auf dem Feld konnte der Dolly flexibel eingesetzt werden und erlaubte detaillierte Aufnahmen einzelner Pflanzen aus verschiedenen Perspektiven sowie unter unterschiedlichen Umweltbedingungen.

Parallel dazu wurde ein strukturierter Erfassungs- und Tracking-Plan entwickelt. Ziel war es, eine lückenlose Dokumentation der aufgenommenen Szenen sicherzustellen, inklusive Zeitstempel, Feldkoordinaten, Wachstumsstadien und Wetterbedingungen. Die Bilddaten wurden systematisch katalogisiert, um sie später gezielt für Trainings- und Testzwecke nutzen zu können.

Ab Anfang 2024 wurde die Datenerhebung zusätzlich auf die autonome Robotikplattform E-TERRY ausgeweitet. Der Roboter ermöglichte eine kontinuierliche, automatisierte Aufnahme von Pflanzendaten auf längeren Fahrstrecken und stellte eine wertvolle Ergänzung zum Dolly-System dar. So konnten nicht nur punktuelle Aufnahmen gemacht, sondern auch längere Vegetationsverläufe erfasst werden.

Die Felder des Biohofs Scharf und der Fachhochschule (FH) dienten als primäre Versuchsumgebungen. Ergänzend wurden externe, offene Datensätze in die Analyse aufgenommen – unter anderem der renommierte Zuckerrübensatz der Universität Bonn, der als Benchmark zur Vergleichbarkeit der KI-Ergebnisse diente.



Bild 4: Von Ollendorf gesammeltes Bild mit seiner Beschriftung

Durch die Kombination verschiedener Quellen, Perspektiven und Techniken entstand eine umfangreiche, vielfältige und qualitativ hochwertige Datenbasis, die als tragfähiges Fundament für die weiteren Arbeitspakete fungiert.

3 AP 4: Datenannotation (09/2023 – 02/2025)

Die präzise und konsistente Annotation von Bilddaten ist ein zentraler Bestandteil KI-gestützter Bildverarbeitung im Pflanzenbau. In Arbeitspaket 4 wurden alle notwendigen Maßnahmen zur Erstellung hochwertiger Trainingsdaten für das semantische Segmentierungsnetzwerk des Projekts PhenoAI umgesetzt. Der Fokus lag auf der Auswahl, Anpassung und Anwendung geeigneter Annotationstools sowie der strukturierten Datenintegration in die zentrale Projektinfrastruktur.

Zu Beginn des Arbeitspakets wurde eine umfassende Marktanalyse öffentlich verfügbarer Annotationstools durchgeführt. Ziel war es, ein Tool zu identifizieren, das sowohl funktional leistungsstark als auch flexibel anpassbar ist. In die Evaluierung flossen zahlreiche Systeme ein, darunter LabelBox, Roboflow, Super Annotate, V7 Labs, Encord, Labelerr sowie das Open-Source-Tool CVAT (Computer Vision Annotation Tool). Nach sorgfältigem Vergleich wurde CVAT als Hauptplattform ausgewählt, da es sich durch eine robuste Benutzeroberfläche, breite Formatunterstützung und umfangreiche Anpassungsmöglichkeiten auszeichnet.



Bild 5: Präzise Erkennung von Segment Anything (SAM)

Um die Effizienz bei der Annotation zu steigern und gleichzeitig eine gleichbleibend hohe Qualität sicherzustellen, wurde das Tool zusätzlich durch die Integration von Segment Anything (SAM) (Bild 5: Präzise Erkennung von Segment Anything (SAM)) erweitert. SAM ist ein KI-basiertes System zur automatischen Segmentierung beliebiger Objekte im Bild. Im Rahmen des Projekts PhenoAI wurde es so eingebunden, dass es als vorschlagsbasiertes Hilfsmittel für menschliche Annotatoren agiert. Das bedeutet, dass die KI zunächst eine Rohsegmentierung erzeugt, die dann vom Annotator nur noch überprüft und ggf. angepasst werden muss.

Darüber hinaus wurde CVAT projektspezifisch angepasst (Bild 6: UI von CVAT), um die speziellen Anforderungen des Einsatzbereichs Landwirtschaft zu erfüllen. So wurden unter anderem Funktionalitäten zur separaten Markierung von Stängeln und Blattstrukturen entwickelt, die insbesondere für die Unterscheidung von Kulturpflanzen und Beikräutern essenziell sind. Auch der Umgang mit überlappenden Pflanzen sowie das Management umfangreicher Bildmengen wurden optimiert.




Bild 6: UI von CVAT

Die eigentliche Annotation der Bilddaten erfolgte auf Grundlage von Aufnahmen aus den Feldstandorten Erfurt, Herbsleben und Ollendorf. Dabei wurden pro Bild mehrere Zielpflanzen und Beikräuter mit polygonalen Masken versehen. Zusätzlich wurde für jede Pflanze der Stängelbereich separat markiert. Diese differenzierte Kennzeichnung ermöglichte es dem späteren KI-Modell, die Pflanzenelemente nicht nur zu erkennen, sondern auch strukturell zu interpretieren – ein wesentlicher Vorteil bei Anwendungen wie automatisiertem Jäten oder gezielter Düngung.

Besonderes Augenmerk wurde auf die Konsistenz und Systematik der Labeldaten gelegt. Alle Dateien wurden mit standardisierten Namenskonventionen versehen, die Zeitstempel, Standort und Wachstumsstadium beinhalten. So lassen sich gezielte Abfragen im Trainingsprozess durchführen, z. B. nur Bilder aus einem bestimmten Monat oder Entwicklungsstadium.

Nach Abschluss der Annotation wurden sämtliche Daten in die zentrale Projekt-Datenbank überführt. Hierbei kam wiederum das bereits in AP3 etablierte DVC-System zum Einsatz, das die Versionierung der Datensätze und deren Zuordnung zu spezifischen Modellen und Trainingsläufen ermöglicht.

Die annotierten Datensätze – sowohl auf Basis realer Bilder als auch synthetisch erzeugter – bildeten die Trainingsgrundlage für das semantische Segmentierungsnetzwerk in AP7. Durch die hohe Qualität der Labels konnte eine präzise Differenzierung zwischen Pflanzenarten, Wuchsformen und Umgebungsbedingungen realisiert werden.

4 AP 5: Augmentierung durch Generative Adversarial Networks (01/2024 – 05/2024)

Im Rahmen des Arbeitspakets 5 wurde untersucht, ob sich Generative Adversarial Networks (GANs) zur automatisierten Erweiterung der Trainingsdatensätze im Projekt PhenoAI eignen. Ziel war es, durch synthetisch erzeugte Bilddaten die vorhandenen realen Trainingsbilder zu ergänzen und somit die allgemeine Leistungsfähigkeit und Generalisierbarkeit des KI-Modells zu verbessern.

Ursprünglich war der Einsatz von Conditional GANs (cGANs) vorgesehen, einer bewährten Methode zur kontrollierten Generierung von Bildinhalten. Während der Projektlaufzeit zeigte sich jedoch, dass modernere Architekturen wie StyleGAN eine deutlich höhere Bildqualität erzielen und als Nachfolger in vielen Anwendungsfeldern mittlerweile Standard sind. Daher wurde die Methodik entsprechend angepasst und die Experimente mit StyleGAN fortgeführt.

Für das Training des Generatormodells wurden reale Bilddaten von Zuckerrüben und Beikräutern genutzt, die zuvor im Rahmen von AP2 aufgenommen und in AP4 annotiert wurden. Ziel war es, auf Basis dieser realen Beispiele neue, fotorealistische Pflanzenbilder zu erzeugen, die sich nahtlos in den bestehenden Datensatz einfügen.

Die Ergebnisse zeigten, dass StyleGAN durchaus in der Lage war, visuell überzeugende Bilder zu generieren, die hinsichtlich Farbgebung, Struktur und Pflanzendichte realen Aufnahmen ähnelten. Es entstanden synthetische Bilder mit einer Vielzahl unterschiedlicher Wuchsformen, Beleuchtungssituationen und Pflanzentypen.

In einem nächsten Schritt wurde untersucht, ob die Kombination aus realen und synthetischen Trainingsdaten zu einer Verbesserung der Segmentierungsleistung des KI-Modells führt. Dafür wurden mehrere Trainingsszenarien aufgesetzt:

- Training ausschließlich mit realen Bildern (Baseline)
- Training ausschließlich mit GAN-generierten Bildern
- Training mit Mischverhältnissen (z. B. 1:1 und 1:2 real/synthetisch)

Die Ergebnisse dieser Trainingsreihen fielen ernüchternd aus. In keinem der Szenarien konnte eine messbare Verbesserung gegenüber dem alleinigen Einsatz realer Daten erzielt werden. Insbesondere die Performance bei der Segmentierung von Stängeln und feinen Pflanzenstrukturen blieb mit synthetischen Bildern deutlich hinter den Erwartungen zurück.

Als Fazit bleibt festzuhalten, dass die Generierung von Trainingsdaten mittels GANs im Kontext von PhenoAI aktuell keinen Mehrwert liefert. Die Bildqualität synthetischer Daten war zwar visuell ansprechend, reichte jedoch inhaltlich nicht aus, um die Lernleistung des Modells signifikant zu steigern. Die Erkenntnis aus AP5 fließt in die Gesamtstrategie des Projekts ein. Zukünftige Ansätze sollen auf realitätsnähere Verfahren wie NeRFs (Neural Radiance Fields) oder hybride Simulationsumgebungen setzen.

Dennoch war dieses Arbeitspaket ein wichtiger methodischer Zwischenschritt, um Potenziale und Grenzen der aktuellen Generativen KI im landwirtschaftlichen Anwendungsfeld auszuloten.

5 AP 6: Synthetische Datensatzerweiterung (01/2024 – 05/2024)

In diesem Arbeitspaket lag der Fokus auf der Erweiterung des Trainingsdatensatzes durch synthetisch erzeugte Bilder. Ziel war es, die KI-Modelle robuster gegenüber Variationen in Licht, Pflanzenform, Bodentyp und Wetterbedingungen zu machen – insbesondere für Szenarien, in denen reale Daten nur begrenzt verfügbar oder schwer zu erfassen sind. Dafür wurde eine datengetriebene Pipeline entwickelt, die auf Photogrammetrie, 3D-Modellierung und automatisierter Bildsynthese basiert.

5.1 Erstellung von 3D-Pflanzenmodellen durch Photogrammetrie

Zur Erstellung der 3D-Modelle kamen moderne Verfahren der Structure-from-Motion (SfM) zum Einsatz. Hierbei wurde die Open-Source-Software COLMAP verwendet, die es ermöglicht, aus mehreren Fotografien desselben Objekts – aufgenommen aus unterschiedlichen Perspektiven – ein dreidimensionales Modell zu rekonstruieren. Die Anwendung funktionierte folgendermaßen:

Pflanzen wurden mit mobilen Geräten aus verschiedenen Blickwinkeln fotografiert. COLMAP analysierte diese Bildreihen, identifizierte charakteristische Bildpunkte (z. B. Blattränder, Verzweigungen) und rekonstruierte die relative Bewegung der Kamera. Daraus entstand ein dreidimensionales Punktwolkenmodell der jeweiligen Pflanze, welches später als Grundlage für Meshes und Texturen diente.




Bild 7: Unkraut von Ollendorf 1




Bild 8: Unkraut von Ollendorf 2

Ergänzend wurden Apps wie Scaniverse und Luma AI verwendet, um schnell qualitativ hochwertige 3D-Scans im Feld zu erzeugen, insbesondere bei Beikräutern mit komplexer Blattstruktur. Zusätzlich wurde mit NeRF-Technologien (Neural Radiance Fields) experimentiert, um volumetrische Darstellungen zu integrieren. Diese Funktionen sind derzeit jedoch nur teilweise in die Hauptpipeline eingebunden.



Bild 9: Unkraut von Ollendorf 3



Bild 10: Unkraut von Ollendorf 4





Bild 11: 3D-Rekonstruktion von Pflanzenbildern

5.2 Aufbau realistischer Umgebungsmodelle

Neben Pflanzenmodellen wurden auch 3D-Modelle von Böden und Umgebungen erstellt. Dabei ging es insbesondere darum, reale Feldbedingungen wie Erdstruktur, Feuchtigkeit, Texturen und Lichtverhältnisse so nachzubilden, dass die erzeugten Szenen für das KI-Training realistisch und praxisnah wirken.

Um die Vielfalt der Szenen zu erhöhen, wurden zusätzliche Objekte und Modelle von externen Plattformen wie Gscatter eingebunden. So konnte z. B. zwischen verschiedenen Pflanzenstadien, Unkrautarten und Bodenbeschaffenheiten variiert werden, eine entscheidende Grundlage für eine hohe Generalisierungsfähigkeit des Modells.



Bild 12: Mit Blender erzeugte synthetische Bilder

Zur automatisierten Generierung der Trainingsbilder wurde eine Pipeline auf Basis der Open-Source-3D-Grafiksoftware Blender entwickelt. Mit Hilfe der darauf spezialisierten Bibliothek BlenderProc wurde die Szeneerstellung vollständig automatisiert. Folgende Schritte liefen in der Pipeline ab:

- Platzierung von Pflanzen- und Bodenmodellen in zufälliger, aber realistischer Anordnung
- Simulation unterschiedlicher Lichtverhältnisse (z. B. Sonne, Wolken, Streiflicht)
- Integration verschiedener Kamerawinkel und -höhen
- Automatisierte Erstellung von Ground-Truth-Labels für semantische Segmentierung (z. B. Objektmasken, Tiefenkarten)

Durch diese Pipeline konnten tausende synthetische Bilder (Bild 12: Mit Blender erzeugte synthetische Bilder) in kurzer Zeit erzeugt werden, jedes mit konsistenten, automatisch erzeugten Labels. Die synthetischen Daten wurden anschließend mit den realen Daten kombiniert und in das Trainingssystem integriert.



Bild 13: Bilder unterschiedlicher Lichtverhältnisse



Bild 14: Bilder verschiedener Bodenarten

5.3 Nutzen und Ausblick

Die synthetischen Trainingsdaten trugen wesentlich zur Verbesserung der Modellrobustheit bei. Insbesondere in Datensituationen mit wenig realem Bildmaterial, etwa bei frühen Wachstumsstadien oder schlechten Wetterbedingungen, zeigte sich ein klarer Vorteil. Die Pipeline ist zudem skalierbar und kann in zukünftigen Projektphasen schnell auf neue Pflanzenarten oder Umgebungen angepasst werden.

6 AP 7: KI-basierter Algorithmus (06/2023 – 06/2024)

Ein zentrales Ziel des Projekts PhenoAI war die Entwicklung eines leistungsfähigen KI-Modells zur semantischen Segmentierung von Pflanzenbildern. Dieses Modell sollte in der Lage sein, verschiedene Pflanzentypen – insbesondere Kulturpflanzen und Beikräuter – zuverlässig zu unterscheiden, ihre Stängel zu erkennen und ihre Positionen auf dem Feld präzise zu bestimmen. Das Arbeitspaket 7 widmete sich daher dem systematischen Aufbau, Training und der Validierung eines solchen KI-gestützten Phänotypisierungsalgorithmus.

Auswahl des Modelltyps und Architekturentscheidungen

Zu Beginn wurde geprüft, ob ein Instance-Segmentation-Modell oder ein Semantic-Segmentation-Modell besser für die Anforderungen geeignet ist. Nach ersten Versuchen wurde bewusst zugunsten der semantischen Segmentierung entschieden, primär wegen des geringeren Rechenaufwands und der ausreichenden Genauigkeit für die anvisierten Anwendungsfälle im landwirtschaftlichen Feldkontext.

Zur Auswahl standen mehrere bewährte Architekturen, darunter SegNet (University of Cambridge) und Mask2Former (Bild 15: AI-Algorithmus (Mask2Former)), entwickelt von Facebook AI. Letztere wurde als Basis gewählt, da sie moderne Ansätze für die Feature-Extraktion und Transformer-Module für die Segmentierung miteinander kombiniert. Im Projekt wurde Mask2Former maßgeblich erweitert und angepasst.

Ein separater Decoder-Zweig zur Stängelerkennung wurde ergänzt, um gezielt die vertikale Pflanzenausdehnung zu berücksichtigen.

Weitere Convolutional Layer wurden eingebaut, um die Unterscheidung zwischen verschiedenen Pflanzentypen zu verbessern.

Die Architektur wurde so angepasst, dass sie effizient auf dem Edge-Device Jetson Orin AGX betrieben werden kann.




Bild 15: AI-Algorithmus (Mask2Former)

6.1 Datenaufbereitung und Augmentierung

Die für das Modelltraining genutzten Datensätze bestanden aus annotierten realen Aufnahmen sowie synthetischen Bildern, die in AP4 und AP6 erzeugt wurden. Um die Generalisierungsfähigkeit des Modells zu steigern, wurden verschiedene Datenaugmentierungsstrategien angewendet:

- Rotation, Skalierung und Bildausschnittmodifikation
- Anpassung von Kontrast- und Farbprofilen
- Integration von Style-Transfer-Techniken, um synthetische Bilder realistischer wirken zu lassen

Die Datensätze wurden nach Wachstumsstadium, Standort und Jahreszeit sortiert, um gezielt trainingspezifische Subsets verwenden zu können.

6.2 Trainingsprozesse und Metriken

Das Modelltraining erfolgte iterativ in mehreren Zyklen. Zur Überwachung des Fortschritts wurde die Online-Plattform Weights & Biases (WandB)(Bild 16: Überwachung der Metriken über Gewichte und Biases) verwendet. Dort wurden alle Hyperparameter, Metriken und Trainingsverläufe dokumentiert. Die wichtigsten Stellschrauben für die Optimierung waren:

- Lernrate
- Batch-Größe
- Anzahl der Trainings-Epochen



Bild 16: Überwachung der Metriken über Gewichte und Biases

Zur Leistungsbewertung wurden standardisierte Evaluierungsmetriken (Bild 17: Erkennung von Unkraut mit einer Genauigkeit von bis zu 86 %) herangezogen:

Intersection over Union (IoU) für Flächengenauigkeit

Precision und Recall zur Bewertung von Fehlerklassen

Mean Average Precision (mAP) zur Gesamtbewertung der Segmentierung




Bild 17: Erkennung von Unkraut mit einer Genauigkeit von bis zu 86 %

6.3 Validierung und Ergebnisse

Das trainierte Modell wurde umfangreich gegen einen separaten Testdatensatz validiert. Dabei wurden nicht nur quantitative Kennzahlen ausgewertet, sondern auch qualitative Bildanalysen durchgeführt, um typische Schwächen oder Verzerrungen des Modells zu erkennen.

Besonders hervorzuheben ist der erzielte IoU-Wert von etwa 0,82, der auf realen Feldern erreicht wurde. Dies stellt eine sehr solide Grundlage für die spätere Anwendung im Tracking (AP9) und in der Robotersteuerung (AP8) dar. Auch unter variierenden Lichtverhältnissen und Bodentypen blieb die Vorhersageleistung stabil.

Die Ergebnisse des Arbeitspakets zeigten, dass ein gezielt aufgebautes semantisches Segmentierungsmodell – unterstützt durch eine gute Datenbasis und systematisches Training – in der Lage ist, landwirtschaftliche Pflanzen zuverlässig zu erkennen und zu differenzieren. Die Integration in die operative Pipeline des PhenoAI-Systems wurde vorbereitet und bildet die Grundlage für die nächste Stufe der Umsetzung.

6.4 MLOps

Ein zentraler technologischer Meilenstein des Projekts PhenoAI war der Aufbau eines integrierten MLOps-Systems (Machine Learning Operations). MLOps bezeichnet den methodischen und technischen Rahmen, der alle Teilprozesse eines KI-Modells – von der Datenaufnahme über das Training bis hin zur Auslieferung – automatisiert, versioniert und reproduzierbar macht.

6.4.1 Was ist MLOps?

MLOps ist eine Kombination aus DevOps-Prinzipien (aus der Softwareentwicklung) und Machine Learning-Workflows. Ziel ist es, alle beteiligten Komponenten in einem KI-Lifecycle zu orchestrieren und dabei:

- manuelle Aufwände zu minimieren,
- Trainings- und Deployment-Prozesse zu standardisieren,
- eine schnelle Iteration und Skalierung zu ermöglichen.

Dadurch entsteht eine durchgängige, automatisierte Pipeline, mit der neue Modelle nicht nur entwickelt, sondern auch zuverlässig getestet, verglichen, dokumentiert und ausgerollt werden können.




Bild 18: E-TERRY MLOps

6.4.2 Aufbau des MLOps-Systems in PhenoAI

Basierend auf der Projektarchitektur wurde ein maßgeschneidertes MLOps-System entworfen, dessen Komponenten in der Präsentation durch folgende Infografik dargestellt wurden: Datenaufnahme → Annotation → Modelltraining → Deployment → Visualisierung. Diese Pipeline wurde wie folgt realisiert:

Datenerfassung: Durch den Einsatz strukturierter Felderhebungen (AP2) sowie synthetischer Bildgenerierung (AP6) wurden versionierte Datensätze geschaffen.

Annotation: Über die angepasste CVAT-Instanz (AP4) – erweitert durch Segment Anything (SAM) – konnten präzise Labels halbautomatisch erzeugt und direkt versioniert in das System eingespeist werden.

Training: Die Trainingsumgebung basierte auf Cloud-Instanzen (z. B. Amazon EC2) und wurde mit GitHub Actions & Continuous Machine Learning (CML) automatisiert. Dies ermöglichte eine wiederholbare, dokumentierte Modelloptimierung.

Deployment: Modelle wurden nach erfolgreicher Validierung automatisch deployt und in eine Inferenzpipeline überführt, welche die Echtzeitfähigkeit auf Jetson AGX Orin sicherte.

Visualisierung: Validierungsergebnisse wurden automatisiert in HTML-Dashboards übertragen und zentral zugänglich gemacht.

6.4.3 Automatisierung und Skalierbarkeit

Durch den Einsatz von MLOps wurde der zeitliche Aufwand für Trainings- und Anpassungsläufe drastisch reduziert. Wo zuvor mehrere Wochen zur Konfiguration, Datenaufbereitung und Trainingsdurchführung notwendig waren, kann heute innerhalb von 20 Minuten ein voll einsatzfähiger Phenotyping-Algorithmus erzeugt und evaluiert werden.

Diese Effizienzsteigerung beruht auf vollständiger Automatisierung der Schnittstellen zwischen Annotation, Modelltraining und Deployment, der modularen Wiederverwendung von Komponenten wie dem synthetischen Datensatzgenerator (BlenderProc-Pipeline) und der nahtlosen Integration von CVAT-Labels, Modellversionen und Evaluationsergebnissen über DVC und Weights & Biases.

7 AP 8-10: Deployment und Test des Phenotyping-Algorithmus auf dem E-TERRY

In den Arbeitspaketen 8 bis 10 lag der Fokus auf der praktischen Anwendung und Evaluation des entwickelten KI-Systems in einem realitätsnahen Umfeld. Ziel war es, den trainierten Phenotyping-Algorithmus auf dem E-TERRY-Roboter zu integrieren, die Funktionalität unter kombinierter Software- und Hardwareumgebung zu testen und die Ergebnisse systematisch auszuwerten.

7.1 Entwicklung und Integration (AP 8 u. 9)

Zur Steuerung des Roboters wurde ein eigenes ROS 2-Package entwickelt, das die Ansteuerung der Sensorik (Kameras, Tiefensensoren) sowie die Kommunikation mit dem KI-Modul ermöglichte. Die Integration erfolgte direkt auf dem NVIDIA Jetson AGX Orin, dem zentralen Rechensystem des Roboters.

Für die Objektverfolgung wurde ein hybrider Tracking-Ansatz umgesetzt:

Ein Kalman-Filter zur Positionsvorhersage wurde mit einem OpenCV-basierten Bildtracker kombiniert. Dadurch war es möglich, einzelne Pflanzen über mehrere Frames hinweg zu identifizieren und Bewegungsmuster zu erkennen – ein entscheidender Schritt für gezielte Interaktionen wie das mechanische Jäten.

7.2 Testaufbau und Validierung (AP 10)

Zur Validierung der Systemintegration wurde in der E-TERRY-Werkstatt ein dezidiertes Testszenario aufgebaut. Der Aufbau bestand aus:

- dem E-TERRY-Roboter mit angebaute Weeding-Tool,
- einer Kameraeinheit zur Datenerfassung,
- sowie einem Fließband, auf dem reale Feldbilder mit Salatpflanzen und Beikräutern projiziert wurden.

Dieser Versuchsaufbau ermöglichte es, sowohl die visuelle Erkennung als auch die mechanische Reaktion des Roboters unter kontrollierten Bedingungen zu testen. Dabei wurde die Kombination aus Software und Hardware gezielt evaluiert, um die zeitliche Reaktionsfähigkeit, Präzision der Pflanzenerkennung und Robustheit der Steuerung zu überprüfen.

Die durchgeführten Tests bestätigten, dass der Algorithmus auch unter Realbedingungen zuverlässig zwischen Kultur- und Beikräutern differenzieren kann und die Steuerung präzise ansteuert. Erkenntnisse aus dieser Phase flossen direkt in die Optimierung der Segmentierung, Tracking-Parameter und Systemkalibrierung ein.




Bild 19: Testaufbau Weeding-Tool

8 AP 11: Öffentlichkeitsarbeit (12/2024 – 02/2025)

Die Sichtbarkeit eines innovativen Forschungsprojekts wie PhenoAI ist nicht nur für die wissenschaftliche Anerkennung, sondern auch für die zukünftige Verwertung und Weiterentwicklung der Projektergebnisse von großer Bedeutung. Im Rahmen von Arbeitspaket 11 wurde daher eine gezielte Kommunikationsstrategie entwickelt, mit dem Ziel, die Meilensteine und Fortschritte des Projekts einem breiteren Publikum zugänglich zu machen.

Der Schwerpunkt der Öffentlichkeitsarbeit lag auf dem Aufbau und der Durchführung einer Social-Media-Kampagne, insbesondere über die Plattform LinkedIn. Die Wahl fiel bewusst auf dieses Medium, da es eine hohe Reichweite in der Fachöffentlichkeit ermöglicht und sich gut für die Vernetzung mit anderen Forschungsprojekten, Technologieunternehmen und landwirtschaftlichen Fachakteuren eignet.

Im Rahmen der Kampagne wurden regelmäßig visuelle Beiträge, Textbeiträge und Statusmeldungen veröffentlicht. Dabei wurden zentrale Aspekte des Projekts verständlich aufbereitet und in einer professionellen, aber ansprechenden Form präsentiert. Thematische Schwerpunkte waren unter anderem:

- Vorstellung der Projektziele und beteiligten Partner
- Einblicke in die Feldarbeiten und Kameraaufbauten
- Fortschritte bei der Entwicklung des KI-Modells
- Demonstration von Ergebnissen der Datenerhebung und Segmentierung

https://www.linkedin.com/posts/janrybizki_letzte-woche-traf-sich-das-phenoai-konsortium-activity-7196130932666388483-FRKY?utm_source=share&utm_medium=member_desktop&rcm=ACoAABodRLkBf6u3PgK21T2pXru28iLhEaAtb18

https://www.linkedin.com/posts/janrybizki_gestern-waren-wir-zu-gast-bei-e-terry-in-activity-7163829402332557312-Ecnc?utm_source=share&utm_medium=member_desktop&rcm=ACoAABodRLkBf6u3PgK21T2pXru28iLhEaAtb18

Ergänzend zur Online-Kommunikation war das Projekt auch im physischen Raum präsent, um die Ergebnisse einem breiteren Fachpublikum vorzustellen. So wurde PhenoAI im Rahmen der Grüne Tage Thüringen auf der bedeutendsten Agrarmesse Thüringens präsentiert, mit direktem Austausch mit Landwirt*innen, Agrarverbänden und Technologieinteressierten.

Zudem wurde das Projekt auf dem Thüringer Innovationsforum präsentiert. Hier erfolgte die Vorstellung der technischen Innovationen und Diskussion mit Vertreter*innen aus Forschung, Wirtschaft und Politik.

Des Weiteren erfolgte der Besuch der Innovationsdienstleister*innen der Bundesländer sowie der Deutschen Vernetzungsstelle Ländliche Räume (DVS) – zuständig für die Umsetzung der Gemeinsamen Agrarpolitik der EU. Der Austausch fokussierte auf die Übertragbarkeit und Praxisrelevanz der Projektergebnisse für andere Regionen.

Der Gewinn des Sonderpreises beim Thex Award 2024 stellt einen weiteren Rahmen zur Präsentation des Projekts dar. Das Projekt PhenoAI wurde im Rahmen des Innovationswettbewerbs der Thüringer Gründerszene mit einem Sonderpreis ausgezeichnet. In diesem Zusammenhang entstand auch ein professionell produziertes Video, das die Kernidee und Wirkung des Projekts öffentlichkeitswirksam darstellt.

Diese Formate haben maßgeblich dazu beigetragen, das Projekt nicht nur in wissenschaftlichen Kreisen, sondern auch in der landwirtschaftlichen Praxis, der Innovationslandschaft und bei politischen Entscheidungsträgern sichtbar zu machen. Die Verknüpfung von Online- und Präsenzmaßnahmen erwies sich als besonders wirkungsvoll und legte den Grundstein für potenzielle Anschlussprojekte und Anwendungs Kooperationen.

9 AP 12: Management u. Verwaltung (09/2024 – 02/2025)

Das Arbeitspaket 12 bildete den organisatorischen und administrativen Rahmen für das gesamte Projekt PhenoAI. Es übernahm die strategische Koordination, finanzielle Steuerung, Abstimmung mit Fördergebern sowie die inhaltliche Synchronisation aller beteiligten Arbeitspakete. Als querschnittliches Arbeitspaket war es nicht an spezifische technische Aufgaben gebunden, sondern hatte die zentrale Aufgabe, die Integrität und Regelkonformität des Projekts über seine gesamte Laufzeit hinweg sicherzustellen.

9.1 Finanzmanagement und Abrechnungen

Ein wesentlicher Bestandteil des Arbeitspakets war die finanztechnische Abwicklung. Diese beinhaltete die systematische Erfassung und Aufbereitung aller projektbezogenen Ausgaben. In enger Orientierung an den Richtlinien der EU-Fördermittelvergabe und der Thüringer Aufbaubank (TAB) wurden Zwischen- und dieser Schlussbericht erstellt.

9.2 Projektkoordination und Schnittstellenmanagement

Ein weiterer Kernbereich war die inhaltliche und zeitliche Koordination aller Projektaktivitäten. Um die verschiedenen Arbeitspakete in Einklang zu bringen, wurden regelmäßige Statusmeetings durchgeführt, ein zentraler Projektzeitplan gepflegt und Meilensteine fortlaufend aktualisiert.

Dabei übernahm das AP12 auch eine vermittelnde Rolle zwischen:

- Technischen Leitungsteams (z. B. KI-Entwicklung, Robotik, Datenmanagement)
- Feldpartnern wie dem Biohof Scharf und dem TLLLR
- Verwaltungsinstanzen wie der Thüringer Aufbaubank

Diese koordinierende Funktion trug wesentlich dazu bei, mögliche Zielkonflikte frühzeitig zu erkennen, Ressourcen effizient zu steuern und Schnittstellenprobleme pragmatisch zu lösen.

9.3 Controlling und Qualitätssicherung

Im Bereich Projektcontrolling wurden Instrumente zur Überwachung des Projektfortschritts, zur Risikoanalyse und zur Sicherung der Ergebnisqualität etabliert. Dazu zählten unter anderem die Entwicklung und Pflege von KPI-Dashboards zur Überwachung zentraler Leistungskennzahlen (z. B. Datenvolumen, Inferenzgeschwindigkeit) sowie die Durchführung interner Audits, insbesondere zur Einhaltung von Datenschutz- und Datenmanagementrichtlinien.

AP 12 stellte somit sicher, dass PhenoAI nicht nur technisch erfolgreich, sondern auch administrativ effizient und förderkonform umgesetzt wurde.

Abbildungsverzeichnis

Bild 1:	Nvidia AGX Orin Developer Kit	3
Bild 2:	Unterseite des AGX Orin Entwickler-Kits	3
Bild 3:	E-Terry Roboter	4
Bild 4:	Von Ollendorf gesammeltes Bild mit seiner Beschriftung	5
Bild 5:	Präzise Erkennung von Segment Anything (SAM)	6
Bild 6:	UI von CVAT	7
Bild 7:	Unkraut von Ollendorf 1	9
Bild 8:	Unkraut von Ollendorf 2	10
Bild 9:	Unkraut von Ollendorf 3	10
Bild 10:	Unkraut von Ollendorf 4	11
Bild 11:	3D-Rekonstruktion von Pflanzenbildern	11
Bild 12:	Mit Blender erzeugte synthetische Bilder	12
Bild 13:	Bilder unterschiedlicher Lichtverhältnisse	13
Bild 14:	Bilder verschiedener Bodenarten	13
Bild 15:	AI-Algorithmus (Mask2Former)	14
Bild 16:	Überwachung der Metriken über Gewichte und Biases	15
Bild 17:	Erkennung von Unkraut mit einer Genauigkeit von bis zu 86 %	16
Bild 18:	E-TERRY MLOps	17
Bild 19:	Testaufbau Weeding-Tool	19