

# Abschlussbericht

*Kurze Darstellung (Sachbericht Teil I)*


## **BoniKI**

### **KI-Basiertes Bonitursystem für pflanzengenaue, autonome Bonitierung**

Gefördert durch



Projektträger



aufgrund eines Beschlusses  
des Deutschen Bundestages

Gefördert durch Bundesministerium für Ernährung und Landwirtschaft aufgrund  
eines Beschlusses des Deutschen Bundestages unter dem Förderkennzeichen 28DK120A20

Zuwendungsempfänger (Name): <b>Landwirtschaftliches Technologiezentrum Augustenberg (LTZ)</b>	Förderkennzeichen: <b>28DK120B20</b>
Vorhabenbezeichnung: <b>KI-Basiertes Bonitursystem für pflanzengenaue, autonome Bonitierung (BoniKI)</b>	
Laufzeit des Vorhabens: <b>01.05.2021 bis 30.04.2024</b>	
Berichtszeitraum: <b>01.05.2021 bis 30.04.2024</b>	
Datum: 31.10.2024	Version: 1.0
Autor: Alle Projektbeteiligten	



## **1. Aufgabenstellung**

Das Projekt BoniKI hat sich zum Ziel gesetzt, eine automatisierte Bonitur von Einzelpflanzen durch die Erfassung von Bilddaten mittels unbemannter Flugsysteme (UAS, unmanned aerial systems) und die Auswertung mithilfe künstlicher Intelligenz (KI) zu ermöglichen. Damit soll eine neue Methode für die einfache, verlässliche und flexible Bonitur von Feldbeständen entwickelt werden. Eine robuste Erkennung, die auch unter anspruchsvollen Bedingungen wie Überdeckung, Verunkrautung und Sortenvielfalt zuverlässig funktioniert, soll durch KI-gestützte Ansätze ermöglicht werden, die Pflanzeigenschaften und Boniturparameter erlernen. Im Rahmen des Forschungsvorhabens sollten die Ergebnisse der gelernten Bonitur mit denen einer automatisierten Bonitur sowie einer klassischen manuellen Bonitur gegenübergestellt werden.

## **2. Wissenschaftlicher Stand an den angeknüpft wurde**

Im Rahmen des Projektes wurde an den wissenschaftlichen Stand in drei Domänen angeknüpft. Für die Bonitur im Feldversuchswesen besteht dieser in der manuellen Erhebung von phänotypischen Attributen ohne weitreichende Unterstützung durch technische Hilfsmittel. Im Bereich des Remote Sensing wird auf die Nutzung von Verbraucher-UAS mit moderater Bodenauflösung und hoher Befliegungszeit Bezug genommen. Im Bereich der künstlichen Intelligenz gibt es eine Vielzahl von Bildsegmentierungsverfahren, die ein Bild in seine Bestandteile zerlegen oder Klassifikationen aufgrund von gelernten Merkmalen durchführen können. Insbesondere für die Bonitur wurden diese Verfahren bisher noch nicht nennenswert eingesetzt.

## **3. Ablauf des Vorhabens**

Zur Durchführung des Vorhabens wurden relevante Boniturparameter festgelegt, anhand derer Feldversuche an verschiedenen Standorten und über mehrere Vegetationsperioden bonitiert wurden. Im unmittelbaren zeitlichen Zusammenhang mit den manuellen Bonituren fanden dazu Befliegungen mit einem spezialisierten UAS mit hochauflösender Kamera statt. Im Rahmen des Vorhabens wurden insbesondere die Kulturen Winterweizen, Wintergerste sowie Mais untersucht.

Die bei der Befliegung gewonnenen Daten wurden dann im Rahmen einer Vereinzelungspipeline in pflanzenzentrierte Kacheln zerlegt. Auf diesen Kacheln wurde anschließend eine automatisierte sowie eine gelernte Bonitur vorgenommen. Diese Bonitur beinhaltet dann eine pflanzenspezifische Bewertung der Nutzpflanze in Bezug auf die zuvor festgelegten Boniturparameter, zum Beispiel das BBCH-Stadium oder Fahndetektion. Die automatisierte Bonitur basierte auf klassischen Bildverarbeitungsverfahren und führte die Bonitur anhand verschiedener Grenzwerte durch. Bei der gelernten Bonitur wurden Daten einer Vegetationsperiode zum Training verwendet und manuell von einem Experten annotiert. Auf Grundlage dieser Daten wurde ein tiefes neuronales Netz nach dem



MultiNet-Ansatz trainiert. Dieses kann anhand eines gemeinsamen latenten Raumes die verschiedenen Bonitur-Parameter bestimmen.

Zur Evaluation wurden eine manuelle bildbasierte Bonitur eines Experten, die automatisierte und die gelernte Bonitur verglichen. In allen drei Verfahren wurden dieselben Bilder gezeigt, sodass kein Verfahren bevorzugt wurde. Die Daten in der Evaluation wurden nicht im Trainingsdatensatz verwendet und stammen aus einer anderen Vegetationsperiode.

#### **4. Wesentliche Ergebnisse**

Die Auswertungspipeline kann in zwei größere Themenkomplexe gegliedert werden, die initiale Pflanzenvereinzelung sowie die eigentliche Bonitur. Für die Vereinzelung wurde eine mehrstufige Verarbeitung der georeferenzierten Bilder erarbeitet. Mithilfe einer farbraumbasierten Detektion wurde automatisiert eine spärliche Annotation der Bilder vorgenommen. Mit diesen Annotationen wurde dann ein siamesisches Netz trainiert. Hierbei wurden die Originalbilder und eine augmentierte Version in die beiden Netzteile gegeben, die anhand der leicht unterschiedlichen Prädiktionen eine präzisere Vereinzelung vornehmen sollten. Das Verfahren wurde unter dem Titel „Single Plant Detection and Isolation on High Resolution UAV Data“ (Spielbauer et al. 2023) auf der CASE 2023 vorgestellt.

Für die Bonitur wurde ein MultiNet-Ansatz entwickelt, da dieser die benötigten gelabelten Datenmengen durch einen gemeinsamen latenten Raum für die verschiedenen Boniturparameter reduziert. Somit können pflanzenspezifische Merkmale effizienter für die unterschiedlichen Boniturparameter genutzt werden. Dieser Ansatz zeigte sich deutlich robuster im Vergleich zur Bonitur mit dem automatisierten Ansatz. Im Vergleich zum manuellen Ansatz wurde etwas Genauigkeit eingebüßt, allerdings ein schnellerer Durchsatz an Daten ermöglicht. Dementsprechend kann das entwickelte Verfahren für eine großflächige Bonitur genutzt werden und ist nicht auf Stichproben angewiesen.

Die erzielten Ergebnisse wurden sowohl in Veranstaltungen der Projektpartner als auch auf weiteren Fachtagungen wie der GIL, VDLUFA, sowie der Abschlusskonferenz des Begleitprojektes X-KIT gezeigt.

#### **5. Zusammenarbeit mit anderen Stellen**

Im Rahmen des Projektes hat das Konsortium mit der Universität Hohenheim zusammengearbeitet. Dabei wurden die Boniturdaten und Befliegungen der Feldversuche am Standort Kleinhohenheim mit den vom LTZ an den Standorten Grötzingen und Rheinstetten erhobenen Daten kombiniert, um den Umfang und die Variabilität des Datensatzes zu erhöhen.

# Abschlussbericht

*Eingehende Darstellung (Sachbericht Teil II)*

## **BoniKI**

### **KI-Basiertes Bonitursystem für pflanzengenaue, autonome Bonitierung**

Gefördert durch



Bundesministerium  
für Ernährung  
und Landwirtschaft

Projektträger



Bundesanstalt für  
Landwirtschaft und Ernährung

aufgrund eines Beschlusses  
des Deutschen Bundestages

Gefördert durch Bundesministerium für Ernährung und Landwirtschaft aufgrund  
eines Beschlusses des Deutschen Bundestages unter dem Förderkennzeichen 28DK120A20

Zuwendungsempfänger (Name): <b>Landwirtschaftliches Technologiezentrum Augustenberg (LTZ)</b>	Förderkennzeichen: <b>28DK120B20</b>
Vorhabenbezeichnung: <b>KI-Basiertes Bonitursystem für pflanzengenaue, autonome Bonitierung (BoniKI)</b>	
Laufzeit des Vorhabens: <b>01.05.2021 bis 30.04.2024</b>	
Berichtszeitraum: <b>01.05.2021 bis 30.04.2024</b>	
Datum: 31.10.2024	Version: 1.0
Autor: LTZ	



## 1. Vorhabens Übersicht

Das Verbundprojekt BoniKI hatte zum Ziel, eine auf künstlicher Intelligenz (KI) basierende, pflanzenspezifische Bonitur für Nutzpflanzen aus Befliegungen mit UAS (engl. unmanned aerial systems, unbemannte Flugsysteme) zu entwickeln, um eine präzisere Bewertung des Wachstumszustands zu ermöglichen. Im Rahmen des Projekts wurden Mais und Winterweizen als Beispielkulturen während ihrer Wachstumsphasen regelmäßig befliegen und eine Vielzahl von Boniturparametern über mehrere Vegetationsperioden hinweg erfasst. Der entwickelte KI-Bonituransatz wurde mit klassischer und automatisierter Bonitur verglichen, um die Effektivität der Methoden zu evaluieren.

Am LTZ Augustenberg wurden verschiedene projektbezogene Aufgaben durchgeführt, die unterschiedliche Kompetenzen erforderten. Um das Projekt effektiv zu bearbeiten, wurde eine zusätzliche Stelle geschaffen. Zu Beginn des Projekts wurden die zu bonitierenden Parameter und die Versuchsflächen in enger Abstimmung mit den Projektpartnern festgelegt; diese Entscheidungen sind in einem separaten Bericht dokumentiert (Ergebnis 2.1). Zwischen 2021 und 2024 wurden die festgelegten Versuchsflächen regelmäßig manuell bonitiert, um Referenzdaten zu erhalten. Zusätzlich wurden die Flächen durch den Projektpartner SAM Dimension GmbH (SAM) sowie mit Prosumer-Drohnen des LTZ befliegen, um die Bildqualität spezialisierter Drohnen mit marktüblicher Technologie zu vergleichen. Die Bilddaten wurden anschließend mit den Versuchstechnikern ausgewertet, um die Erkennung der Boniturparameter in den Bildern zu prüfen und für die Annotation zu optimieren. Für die Auswahl geeigneter Trainingsdaten innerhalb des Datensatzes wurden Skripte entwickelt, die randomisierte Annotationsdatensätze generierten. Diese annotierten Datensätze, zusammen mit den Feldboniturdaten, stellen das Ergebnis 2.2 der Vorhabensbeschreibung dar.

Das LTZ entwickelte eine Automatisierung der Datenhaltung, um die Boniturergebnisse in den Befliegungsdaten gezielt zu identifizieren. Dadurch werden Fehler bei manuellen Eingaben vermieden und wiederkehrende Prozesse, wie das automatische Prüfen der Befliegungsdaten auf Boniturmarker, beschleunigt. Die so selektierten Befliegungsdaten wurden anschließend durch den vom Forschungszentrum Informatik (FZI) entwickelten Prozessor verarbeitet. Das Training des neuronalen Netzes und die Weiterentwicklung des Prozessors wurden vom LTZ begleitet, wobei Fortschritte und Verbesserungen regelmäßig evaluiert wurden, um den Status quo der computergenerierten Bonitur zu bestimmen. In regelmäßigen Treffen gab das LTZ Rückmeldungen an das FZI, um Optimierungspotenziale zu identifizieren und Problemstellen zu beheben. Die verarbeiteten Daten wurden schließlich mit den manuellen und visuellen Bonituren evaluiert (Ergebnis 7.1). Die im Projekt gewonnenen Erkenntnisse wurden fortlaufend auf wissenschaftlichen Konferenzen präsentiert und auf nichtakademischen Veranstaltungen für Landwirte und Berater



vorgelegt, um die praktische Anwendung der Ergebnisse zu fördern (Ergebnis 7.3). Zudem wurden Publikationen in Konferenzbänden und landwirtschaftlichen Fachzeitschriften veröffentlicht, um die Erkenntnisse auch wissenschaftlich zu verbreiten (Ergebnis 7.2).

## **2. Durchgeführten Arbeiten im Rahmen des Vorhabens**

### **AP 1: Koordination Management**

#### *Zielstellung:*

Im AP 1 lag der Fokus auf der zentralen Projektkoordination und der organisatorischen Leitung des Konsortiums. Durch regelmäßige Meetings und die Nutzung von Kollaborationstools wurden Arbeitsabläufe standardisiert, um einen reibungslosen Ablauf der Projektaktivitäten sicherzustellen. Die zentrale Koordination der Arbeitspakete wurde vom FZI übernommen, während das LTZ für die Organisation der Feldversuche sowie die Abstimmungen mit SAM zur Befliegung verantwortlich war.

#### *Ergebnisse:*

Das Kickoff-Treffen wurde kurz nach Projektstart erfolgreich durchgeführt und die technische Kommunikationsinfrastruktur eingerichtet, die aus einer zentralen Datenablage, einer Mailingliste und einer Plattform für Webkonferenzen bestand, um den regelmäßigen Austausch zwischen den Partnern zu ermöglichen (E 1.1). Im Rahmen der monatlichen Videokonferenzen wurde über den Status quo berichtet. Verschiedene Templates wurden mitgestaltet, um eine einheitliche Projektpräsentation und -durchführung zu unterstützen. Das LTZ übernahm in diesem Zusammenhang die Organisation und Durchführung der manuellen Bonituren sowie, in Zusammenarbeit mit SAM, die UAS-Befliegungen und deren Planung sowie die Zuarbeit bei der Dokumentation der Konsortialtreffen sowie die Abstimmung der Arbeitsergebnisse (E 1.2). In enger Zusammenarbeit mit den Projektpartnern wurde der Abschluss des Projekts vorbereitet, was auch die termingerechte Abgabe des technischen Abschlussberichts (E 1.3) einschloss. Darüber hinaus wurde eine Projektskizze für das Folgeprojekt „BlühKI“ erfolgreich mit dem FZI und der Universität Hohenheim eingereicht, die im Rahmen des Förderaufrufs „Experimentierfelder zur Digitalisierung und KI in der Landwirtschaft“ weiterentwickelt werden soll.

### **AP 2: Bonitur und Feldversuchswesen**

#### *Zielstellung:*

Im Rahmen von AP2 organisierte das LTZ die Planung der Boniturdaten auf Versuchsflächen in Baden-Württemberg gemäß den fachlichen Vorgaben und war für die Durchführung und Auswertung verantwortlich. Durch die Kombination manueller Bonituren und der Erfassung von Daten mittels UAS und hochauflösender Kamerasysteme wurden Ground-Truth-Daten für die Entwicklung von KI-

gestützten Analyseverfahren generiert. Das LTZ stellte in enger Abstimmung mit den Projektpartnern sicher, dass die erhobenen Daten für die spätere KI-Analyse genutzt werden konnten.

#### *Ergebnisse:*

Es wurden verschiedene Feldversuche in den Zielkulturen begleitet, die eine umfassende Datenerfassung für die Entwicklung eines KI-basierten Bonitursystems ermöglichten. Dabei wurden zentrale Boniturparameter erfasst, die für die spätere Analyse und Vereinzelung durch KI-Methoden von Bedeutung sind. In einem Beregnungsversuch im Mais wurden Einzelpflanzenerkennung und Bestandesdichte erhoben, während im Kreuzhackversuch der Effekt der mechanischen Unkrautregulierung untersucht wurde. In diesem Versuch wurden Daten zur Unkrautbedeckung und zum Unkrautregulierungserfolg gesammelt, was entscheidend für die spätere Entwicklung von KI-gestützten Unkrautklassifikationssystemen war. Darüber hinaus wurde ein Dauerversuch im Winterweizen begleitet, bei dem die Anzahl der Ähren pro Quadratmeter bonitiert wurde. Dieser Versuch bot die Möglichkeit, über mehrere Jahre hinweg konsistente Daten zu sammeln. Danach wurde die Bonitur auf Wintergerste in Landessortenversuchen ausgeweitet und entsprechende Labels erfasst, um zu testen, ob die KI-basierte Auswertung auch in Gerste eingesetzt werden kann und wie viele neue Trainingsdaten notwendig sind.

Die Boniturparameter wurden gemeinsam mit den Projektpartnern definiert, damit die Daten für die KI-gestützte Bonitur bestmöglich erstellt werden konnten (E 2.1). Zu den Parametern zählten der Bedeckungsgrad, die Bestandesdichte, die Anzahl der Ähren pro Quadratmeter sowie der Grad der Unkrautbedeckung und die Messung des Entfahnung von Mais. Dabei wurde darauf geachtet, dass die erfassten Daten sowohl manuell als auch automatisiert auswertbar sind. Die Annotation der Trainingsdaten erfolgte mit der Software CVAT, die in ihrer kostenfreien Version ausreichend nutzbar ist und in einem Docker Container bereitgestellt wird (Abb. 1). Darin wurde ein projektspezifischer Klassifikationsschlüssel erarbeitet und die Annotation eng mit dem FZI abgestimmt. Dadurch wurde sichergestellt, dass die annotierten Daten den Anforderungen der späteren Analyse entsprechen und durch regelmäßige Iterationen mit den Partnern wurde dieser Prozess kontinuierlich optimiert. Zur Auswertung und Visualisierung wurden Skripte in der Programmiersprache R erstellt, um die Datensätze automatisiert auszuwerten und darzustellen. Um das Verständnis des landwirtschaftlichen Versuchswesens zu fördern, wurden Schulungen zur manuellen Bonitur für die Projektpartner durchgeführt. Diese Schulungen ermöglichten es, die Anforderungen der Bonitur besser zu verstehen und in die gemeinsame Diskussion über die



Abb. 1: Unmaskierte Kacheln einer Maispflanze (links); Maske für Maispflanze im automatisierten Verfahren (rechts).

Boniturparameter einzubeziehen und trugen dazu bei der Qualität der erhobenen Daten zu verbessern und eine solide Grundlage für die spätere Entwicklung des KI-basierten Bonitursystems zu schaffen.




Abb. 2: Fahnen im Mais (1); gelabelte Unkräuter (2); erkannte Ähren (3); gelabelte Pflanzenteile (4); Bonituraufbau für Luftbilddauswertung im Winterweizen (5); Boniturrahmen für Luftbilddauswertung, Labeln und Training (6).

### AP 3: UAS Datenerfassung

#### Zielstellung:

Im Arbeitspaket AP3 wurden UAS-Befliegungen auf Versuchsflächen durchgeführt, um hochauflösende Bilder, Orthophotos und Höhenmodelle für eine KI-gestützte Bildbonitur zu erstellen. Ziel war es, die Befliegungsparameter Flughöhe und Bildüberlappung zu optimieren, um georeferenzierte Einzelbilder, Orthophotos und Trainingsdaten für die Bildanalyse bereitzustellen. Hierbei sollte auch die Eignung marktüblicher UAS geprüft werden.

#### Ergebnisse:

Im Rahmen des AP3 wurden regelmäßige Befliegungen mit SAM Dimension durchgeführt und die Ergebnisse direkt ausgewertet. Dies diente der Qualitätssicherung und Optimierung der Daten für die entwickelte Auswertepipeline in den folgenden Arbeitspaketen. Die Befliegungen führte das LTZ mit handelsüblichen UAS (DJI Phantom4RTK und DJI Matrice300RTK mit Zennuse P1 Kamera, 50mm Brennweite, 45 MP) zusammen mit SAM durch. In mehreren Iterationen wurden die

Befliegungsparameter optimiert, um eine kontinuierliche Verbesserung der Trainingsdaten zu erreichen und die Grenzen der handelsüblichen Systeme zu ermitteln (E 3.2). Handelsübliche UAS lieferten zwar geringere Auflösungen, jedoch wertvolle Übersichtsbilder für Vergleichszwecke und halfen dem LTZ seine digitalen Kompetenzen auszubauen. Bodengestützte hochauflösende RGB-Kameras ergänzten die Daten als Ground-Truth zur Bewertung spezifischer Merkmale für die Erkennung und Annotation (Abb. 2). Die Ergebnisse zeigten, dass handelsübliche UAS nur bedingt für die Bonitur geeignet sind: Sie erreichen die notwendige Auflösung nur bei niedriger Flughöhe und langen Flugzeiten, wobei Pflanzenhöhe und Rotorabwind die Bildqualität beeinträchtigen können. Die Sensoren der Phantom4RTK kann kleinste Pflanzenteile nicht abbilden. Das größere und teurere System Matrice300RTK leistet Bodenaufösungen von 1,1 mm bei 12 m Flughöhe. Das SAM-System war aus 60 m Höhe und Auflösung im Submillimeterbereich deutlich leistungsfähiger und effizienter. Klassische Auswertungsmethoden stoßen bei Automatisierung und Erkennungsleistung an ihre Grenzen, da die präzise Geolokation ein Orthomosaik und damit Fachwissen, Rechenkapazität und Zeit erfordert. Die Einzelbildauswertung verlangt zudem komplexe KI für räumliche Zuordnung und Überlappungskorrekturen (Abb. 3).



Abb. 3: Abbildungsleistung Zenmuse P1 aus 15m (links), SAM-Dimension aus 60m (rechts).

Im Rahmen der KI-basierten Bildbonitur, die mit AP2 stark verbunden ist, übernahm das LTZ die Entwicklung und Bereitstellung von Trainingsdaten für die automatisierte Bonitur. Durch detaillierte Analysen der Bilddaten wurde bestimmt, welche Boniturparameter visuell erkennbar sind und als objektbezogene, gelabelte Daten für das Training der KI-Modelle genutzt werden können. Ebenfalls wurden die Anforderungen an die Boniturdaten und Aufnahme mit UAS festgelegt (E 3.4). Für die Bilddaten der Phantom4RTK wäre die automatische Auswertung im BoniKI-Prozessor nur nach weiteren umfangreichen Anpassungen der Auswerterroutine für den Parameter Bedeckungsgrad möglich, was nicht weiterverfolgt wurde. Ebenfalls wären zusätzliche annotierte Trainingsdaten erforderlich. Ein Bericht zur Erklärung der Boniturparameter und Anforderungen an die Bonitur wurde

separat für das Konsortium verfasst. Insgesamt zeigte sich, dass die erforderliche Abbildungsleistung nur mit professioneller Technik aus dem spezialisierten UAS-Segment erreicht werden konnte und Prosumer-UAS für diese Bonituraufgaben ungeeignet waren. Zur visuellen Interpretation und für weniger komplexe Boniturparameter sind Prosumerdrohnen gut geeignet.

#### AP 4: Bildanalyseverfahren

In AP4 wurde eine Verarbeitungspipeline entwickelt, die die annotierten Bild-Datensätze aus AP3 weiterverarbeitet und für die Analyse vorbereitet. Ziel war die Vereinzelung der Pflanzen in Einzelbilder, die Segmentierung der Bildpixel in Pflanzen- und Hintergrundbereiche und die Bereitstellung der Ergebnisse in einem nutzerfreundlichen Format. Dies bildet die Grundlage für alle weiteren Verarbeitungsschritte in den folgenden Arbeitspaketen.

##### AP4.1: Verarbeitungspipeline und Interface

###### Zielstellung:

Die Herausforderung von AP4.1 bestand darin, die Bilddaten aus AP3 für die KI-gestützte Analyse aufzubereiten. Dies umfasste die Entwicklung einer automatisierten Pipeline zur Segmentierung der Bilder, um einzelne Pflanzen isoliert analysieren zu können. Die effiziente Verarbeitung der Bilddaten und die Ausgabe der Boniturergebnisse in einem GIS-kompatiblen Format waren weitere zentrale Anforderungen.

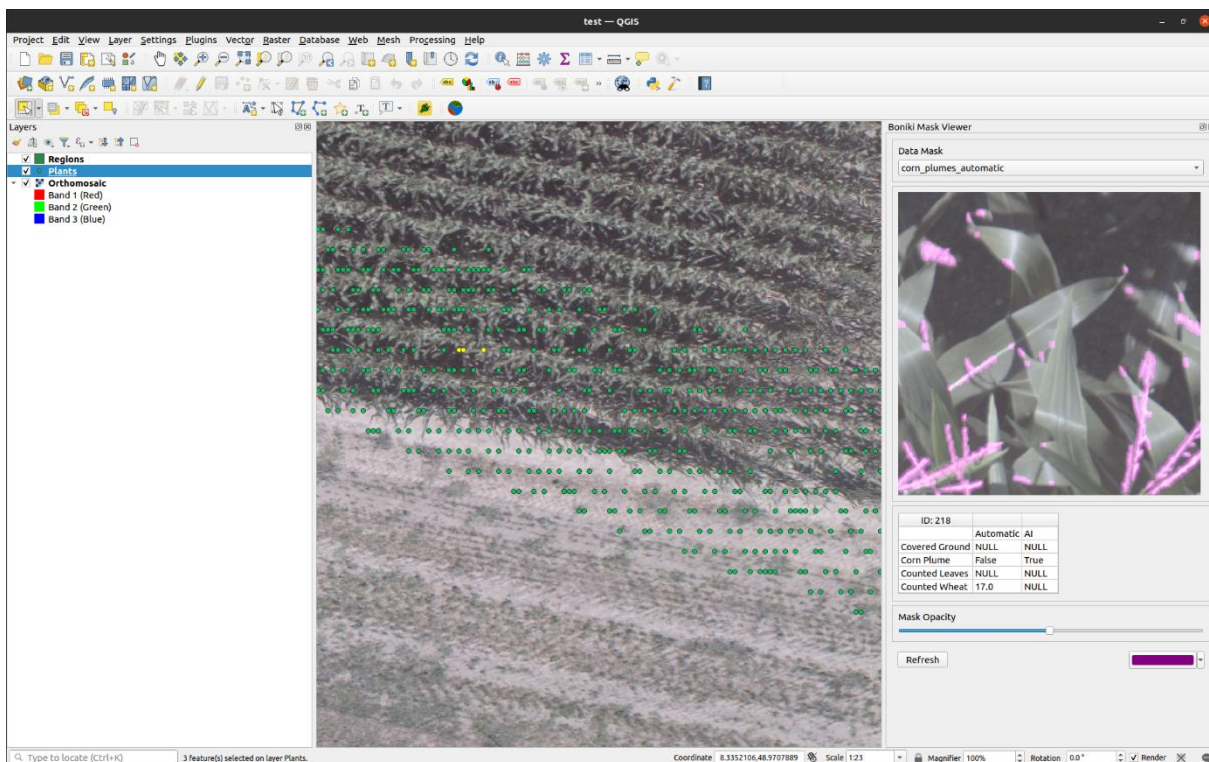


Abb. 4: Darstellung der identifizierten Fahnen in QGIS.



### *Ergebnisse:*

Zur Verbesserung der Nutzerfreundlichkeit wurde eine grafische Benutzeroberfläche für den Prozessor entwickelt, die das LTZ zur effizienten Steuerung der Prozessschritte Vereinzelung (AP4), automatisierte Bonitur (AP5) und trainierte Bonitur (AP6) nutzt und zur Anwendung der Modelle für die Evaluation (AP7) dient. Der Prozessor wurde per Fernzugriff des FZI auf einer Linux Workstation im Forschungsnetz des LTZ in Kooperation installiert und aktualisiert, wobei auftretende Probleme im direkten Austausch gelöst wurden. Für die Projektpartner wurden Schnittstellen geschaffen, die eine automatisierte Datenübertragung untereinander und lokale Auswertung ermöglichen. Die Ergebnisse wurden für die landwirtschaftliche Praxis in Geodatenformate überführt, die in Geographischen Informationssystemen (z. B. QGIS) weiterverarbeitet werden können (Abb. 4).

### **AP4.2: Segmentierung der Pflanzen**

#### *Zielstellung:*

Ziel des AP4.2 war die präzise Segmentierung der Pflanzen in den Bilddaten, um die einzelnen Pflanzen vom Hintergrund zu unterscheiden. Dies bildet die Grundlage für die weitere Analyse durch KI-Modelle, insbesondere durch neuronale Netze zur Vereinzelung, Objekterkennung und Segmentierung.

#### *Ergebnisse:*

Das LTZ unterstützte die Entwicklung der Pflanzensegmentierung durch agronomisches Fachwissen und erstellte die erforderlichen Trainingsdatensätze. Ein Grünwertfilter half bei der anfänglichen Auswahl von Pflanzenteilen, um einen grob annotierten Datensatz für das Training des neuronalen Netzes zu generieren. Das LTZ unterstützte durch Zuarbeit das FZI durch neue Trainingsdaten zur Steigerung der Segmentierungsgenauigkeit. Abschließend bereitete das LTZ die Ergebnisse in Form von Boniturnkarten im Geodatenformat auf, die in GIS- und Agraranwendungen integriert und mit vorhandenen Daten kombiniert werden konnten.

### **AP4.3: Vereinzelung der Pflanzen und Pflanzenteile**

#### *Zielstellung:*

In AP4.3 wurde eine standardisierte Bilddatenbasis für die Erstellung individueller Bilder für jede identifizierte Pflanzeninstanz oder jedes Pflanzenteils entwickelt und die Vereinzelung von überlappenden Pflanzenteilen vorgenommen. Zudem wurden Verfahren zur Trennung überlappender Pflanzen entwickelt, etwa durch das Maskieren nicht relevanter Pixel, um den Einfluss zu minimieren.

#### *Ergebnisse:*

Das LTZ unterstützte das FZI im Vereinzelungsschritt durch die Bewertung der Einzelbilder hinsichtlich ihrer Eignung für die Bonitur. In beiden Ansätzen wurden die Kacheln auf eine feste



Größe zugeschnitten und als Eingabe für die folgenden Auswertungsschritte bereitgestellt. Die in AP4.1 erstellte Benutzeroberfläche wurde zudem durch das FZI erweitert, sodass die Auswahl zwischen KI-basiertem Tiling (Kachelung) aus AP4.2 und automatischem Tiling ermöglicht wurde. Die Ergebnisse der Vereinzelung wurden evaluiert und dem FZI zur Anpassung der Pipeline und Parameter zurückgemeldet.

## **AP5 Automatische Phänotypische Bonitur**

### *Zielstellung:*

AP5 widmete sich der automatisierten Bewertung der segmentierten Einzelpflanzen und der generierten Orthomosaike mithilfe analytischer Algorithmen. Ziel war es, diverse Metriken zur Analyse der Pflanzen und Felder, wie etwa den Bedeckungsgrad oder die Detektion von Fahnenblättern, zu ermitteln. Die Algorithmen sollen in die übergeordnete Pipeline integriert werden und ihre Ergebnisse in einem standardisierten Format bereitstellen.

### *Ergebnisse:*

Das LTZ evaluierte die Ergebnisse der automatisierten und KI-basierten Bonitur im Vergleich zur manuellen Bonitur, um die Entwicklung der automatisierten Verfahren zu unterstützen. Die ausgewerteten Boniturparameter wurden merkmalsbezogen analysiert. Die automatisierte Berechnung von Metriken für größere Bildbereiche erwies sich als erfolgreich. Der Bedeckungsgrad wurde durch pixelbasierte Segmentierung und Farbhistogramme ermittelt und anschließend mit manuellen Daten verglichen. Die Fahndetektion zeigte sich allerdings vom Abreifungsgrad der Maispflanzen abhängig: Je mehr die Pflanzen verfärbt waren, desto schwieriger wurde die Erkennung. Beim Ährenzählen stellte die Ähnlichkeit der Farben von Ähren, Halmen und Blättern eine Herausforderung dar, die durch Kontur- und Größenfilter teilweise gelöst wurde. Die Ergebnisse wurden so aufbereitet, dass sie in QGIS visualisiert werden konnten, sodass die erstellten Masken und Instanzen direkt darstellbar waren.

## **AP6: Gelernte KI-Bonitur**

### *Zielstellung:*

Ziel des AP6 war die Entwicklung eines neuronalen Netzwerks zur Analyse von Boniturmerkmalen auf den in AP4 erzeugten Bildkacheln. Dadurch sollte die Expertise der Bonitur in das Netzwerk integriert und eine robuste Klassifikation für verschiedene Pflanzenarten ermöglicht werden. Das Netzwerk wurde auf Basis von durch Experten annotierten Daten trainiert, um das Wissen präzise zu kodieren und verallgemeinerbare Klassifikationen zu erzeugen. Der Schwerpunkt lag auf der Entwicklung einer geeigneten Netzwerkarchitektur sowie optimierten Trainingsstrategien, die die begrenzt verfügbaren Daten maximal nutzen. Weiterhin wurde untersucht, wie die Anforderungen an die Datenmenge für das Netzwerk minimiert werden konnte.



## **AP6.1: Konzeption einer geeigneten Netzwerkarchitektur**

### *Zielstellung:*

In AP6.1 wurde eine geeignete Netzwerkarchitektur zur Bewertung von Boniturmerkmalen entwickelt. Dafür wurden die Eingaben und Ausgaben des neuronalen Netzwerks entsprechend spezifiziert. Als Eingabe fungierten die in AP4 vorverarbeiteten Pflanzenbilder. Ziel war es, eine Architektur zu entwerfen, die entweder einen Pflanzen-Score oder spezifische Boniturmerkmale präzise beurteilen konnte. Die Konzeption des Netzwerks sollte praxisorientiert und modular gestaltet und in enger Abstimmung mit dem Wissen der Projektpartner optimiert werden.

### *Ergebnisse:*

Das LTZ spezifiziert in Zusammenarbeit mit dem FZI die Ein- und Ausgaben des neuronalen Netzwerks zur Erfassung und Nutzung von Boniturdaten. Bildbasierte und qualitative Boniturergebnisse sowie segmentierte Pflanzenbilder aus AP4 wurden als Eingaben festgelegt. Zudem wurde untersucht, ob eine Bildmaske die Vorhersagegenauigkeit verbessern könnte und ob ein kodierter Parameter die Nutzung eines Netzwerks für mehrere Pflanzenarten ermöglicht. Die Wahl fiel auf eine MultiNet-Architektur, die den Encoder auf den gesamten Datensatz trainiert und pflanzenspezifische Parameter im latenten Raum kodiert, um Datenanforderungen zu reduzieren. Eine Region-Proposal-Komponente verbesserte die Segmentierung, indem sie relevante Bildregionen identifizierte. Für das Netzwerk wurde eine graphische Oberfläche entwickelt, die die Auswahl von Boniturparametern und Datensätzen zur Auswertung durch das LTZ ermöglicht.

## **AP6.2: Entwicklung von effizienten Trainingsstrategien**

### *Zielstellung:*

AP6.2 hatte zum Ziel, effiziente Trainingsmethoden für das neuronale Netzwerk zu entwickeln, um die begrenzte Datenmenge bestmöglich auszuschöpfen. Hierbei wurde erforscht, inwiefern das Training auf eine Pflanzenart auf andere übertragbar ist (Transfer Learning). Zudem wurde geprüft, wie die in AP5 generierten Daten in den Trainingsprozess eingebunden werden können, um die Boniturergebnisse weiter zu verbessern. Durch gezieltes Training sollte die Leistungsfähigkeit des Netzwerks optimiert werden, um die Anwendbarkeit auch auf neue Pflanzenarten zu ermöglichen.

### *Ergebnisse:*

Das vom FZI entwickelte MultiNet wurde im LTZ intensiv getestet und bewertet, um eine praxisgerechte Unterstützung zu bieten. Eine Methode bestand darin, alle Daten gleichzeitig zu verwenden, wobei der jeweilige Fehler eines Decoders im MultiNet in den Encoder eingespeist wird. Bei der anderen Methode wurde nur der jeweilige Decoder trainiert, was zu besseren Ergebnissen führte, wenn der Datensatz ungleichmäßig für die verschiedenen Decoder verfügbar ist. Das LTZ führte diese Trainingsmethoden mit eigenen Datensätzen durch und bewertete die Leistung des



Modells für die Praxis. Das LTZ konnte mithilfe von Transfer Learning den bereits auf anderen Pflanzenarten trainierten Backbone für neue Kulturen einsetzen und prüfen. Dabei wurden eigene Daten genutzt, um die Genauigkeit der Erkennung zu evaluieren und Abweichungen zu dokumentieren.

## **AP7: Evaluation**

### *Zielstellung:*

Die Evaluation des Projekts in AP7 wurde in enger Zusammenarbeit vom LTZ mit den Projektpartnern durchgeführt. Dabei lag der Fokus auf der Bewertung der in AP6 trainierten neuronalen Netze, der automatisierten Bonituren aus AP5 sowie der manuellen Bonitur AP2 und der Befliegung in AP3. Zu diesem Zweck wurde ein unabhängiger Evaluationsdatensatz erstellt, wobei die manuell erhobenen Daten als Ground-Truth dienten und als Referenz für den Vergleich mit den automatisierten und gelernten Auswertungen genutzt wurden. Die Ergebnisse des Projekts wurden auf nationalen und internationalen Konferenzen sowie Feldtagen präsentiert, um die Anwendbarkeit der entwickelten Verfahren zu bewerten und die Resultate sowohl der wissenschaftlichen Fachwelt als auch potenziellen Anwendern in der Landwirtschaft zugänglich zu machen.

### *Ergebnisse:*

#### **Zusammenfassung zur Evaluation von KI-Methoden in der Agrarbildverarbeitung**

Die Evaluation der KI-Methoden wurde auf Test-Datensätzen durchgeführt, die unabhängig von den Trainings- und Validierungsdatensätzen waren, um eine unvoreingenommene Leistungsbewertung zu gewährleisten. Diese Test-Daten wurden mit den Verarbeitungsroutinen des BoniKI Prozessors für die automatisierte und für die gelernte verarbeitet und die Ergebnisse wurden anschließend mit der manuellen Bonitur, die als Ground-Truth galt, verglichen. Ziel war es, die Übereinstimmung und Genauigkeit der KI-Methoden gegenüber den menschlichen Einschätzungen zu ermitteln und eine Quantifizierung ihrer Leistung zu ermöglichen sowie zu prüfen, wo Grenzen der Anwendung im praktischen Feldversuchswesen liegen (Abb. 5). Evaluert wurden die Parameter Ährenzahl, Fahnenenerkennung und Boden-/Unkrautdeckungsgrad an vier Zeitpunkten über die Jahre 2021-2023.

#### **Fahnenenerkennung bei Maispflanzen**

Im Bereich der Hybridmaiszüchtung wurden die männlichen Blütenstände (Fahnen) an einer weiblichen Mais-Zuchtlinie entfernt, um eine gezielte Fremdbestäubung sicherzustellen. Da Mais monözisch ist, sind Blütenstaubgefäße zu entfernen, um Selbstbestäubung zu verhindern. Die saubere Entfahnung ist Bedingung für die Zucht. Die Fahnenenerkennung wurde anhand von Datensätzen eines Bewässerungsversuchs aus den Jahren 2021 und 2022 trainiert und evaluiert. Dabei markierten Bechermarker spezifische „Areas of Interest“ (AOIs) innerhalb der Versuchsfelder, die dann maschinell entfahnt wurden. Hochauflösende Drohnenbilder ermöglichten die Analyse von

Bildausschnitten, die den Zustand der Entfahnung zeigten und wurden für das Training sowie zur späteren Evaluation genutzt (Abb. 5).


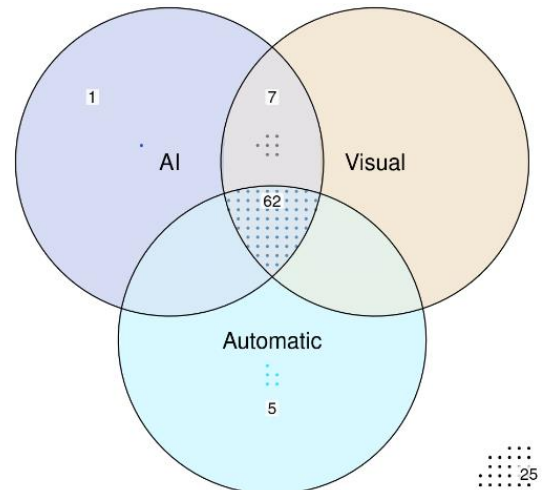


Abb. 5: Ähren zählen im Dinkel (oben), Ähren zählen in der Gerste (mittig), Erkennung von Maisfahnen (unten); jeweils automatische Bonitur (links), KI-Bonitur (mittig), automatische Bonitur (rechts), KI-Bonitur.

Für die Trainings- und Validierungsphasen kamen die Datensätze vom 15. und 25.07.2022 zum Einsatz, während die Test-Datensätze vom 30.08.2021 und 24.08.2022 stammten. Dadurch wurde die KI auf Datensätzen trainiert, die die Maispflanzen zu unterschiedlichen Zeitpunkten und unter unterschiedlichen Wachstumsbedingungen zeigten, was eine Evaluation über Jahre hinweg und an verschiedenen Standorten ermöglichte. Dies stellte sicher, dass der KI-Ansatz möglichst unabhängig von spezifischen Trainingsbedingungen bewertet wurde. Die Evaluation umfasste pro Test-Datensatz jeweils 100 Bildausschnitte (Tiles), die sowohl durch das KI-gestützte als auch das

automatisierte Verfahren prozessiert und anschließend visuell bonitiert wurden. Die Venn-Diagramme zeigten eine Übereinstimmung zwischen den gewählten Methoden. Das automatisierte Verfahren weist eine Genauigkeit von 87 % auf (insgesamt 59 %–88 %), wogegen das KI-gestützte Verfahren eine höhere Erkennungsgenauigkeit von 99 % (insgesamt 87 %–99 %) erzielte.

Für den 30.08.2024 konnte der KI-gestützte Ansatz 99 von 100 Tiles korrekt klassifizieren und übertraf somit den automatisierten Ansatz, der 88 von 100 Tiles korrekt identifizierte (Abb. 6). Dabei wurden Fahnen, die tatsächlich existierten, zuverlässig erkannt; zudem erzeugte der KI-Ansatz weniger False-Positives als der automatisierte Ansatz. Die Fehleranalyse ergab, dass False-Positives, d. h. fehlerhafte Erkennung der Fahnen, was überwiegend durch Blattspitzen (48 %) oder Schatteneinschlüsse (44 %) verursacht wurde, eine ähnliche Form und Farbe wie Fahnen aufwiesen (Abb.



7). Der dritthäufigste Grund waren braune Blattränder (8 %), die der Form und Farbgebung von Fahnen

Abb. 6 Ergebnis der Fahnerkennung mittels KI-basierter, automatisierter und visueller Bildbonitur am 2021-08-30.

glichen. False-Negatives, d. h. übersehene Fahnen, traten vor allem bei abgereifter Vegetation (57 %) und Schattenwechsellern (28 %) auf, die die Erkennung erschwerten (Abb. 8).

Die KI-gestützte Methode wurde aus diesem Grund bewusst sensitiv eingestellt, sodass im Zweifelsfall eher eine Fahne angezeigt wurde, um den negativen Effekt von False-Negatives zu minimieren. In der praktischen Anwendung könnten sich die KI-Methoden als hilfreich erweisen, um Entfahnungskontrollen zu unterstützen. Fehlerhafte Detektionen durch False-Positives führten




Abb. 7: Ursachen für die False-Positives des KI-gestützten Verfahrens.

dazu, dass Kontrollpersonen unnötig Fahnen suchten. False-Negatives, also unentdeckte Fahnen, wurden als schwerwiegender erachtet, da sie zu unerwünschter Zucht führen. Der KI-gestützte Ansatz zeigte in den meisten relevanten Stadien die Fahnen präzise an und wurde daher als zuverlässiges Kontrollmittel angesehen, wodurch eine visuelle Nachkontrolle durch Personaleinsatz im Feld reduziert werden könnte. Die Häufigkeit von False-Negatives war in den Datensätzen vom 25.07.2022 und 24.08.2022 (beide Mais) besonders hoch, da der Mais in der Abreifephase war. In dieser Phase wurde das Blätterdach lichter, wodurch Untergrund und Schatten auf den Fahnen stärker sichtbar waren. Die Fahnen hingen zudem häufig unter dem abgereiften Blattwerk und die trockene Vegetation reduzierte den Farbkontrast zwischen Fahnen und Blättern. Diese Faktoren

erschweren die Erkennung, wodurch die Befliegung in der Abreifephase ungeeignet war. Um False-Negatives zu minimieren, sollten die Befliegungszeitpunkte an die Wachstumsphasen des Mais angepasst und frühere Erfassungen vor Beginn der Abreife durchgeführt werden.



*Abb. 8: Beispiele für False-Positives. In den oberen Reihen sind die originalen Luftbilder, in der unteren Reihe die aus dem KI-gestützten Verfahren resultierende Maske. False-Positives wurden hauptsächlich durch Schatteneinschlüsse (links), Überdeckungen (Mitte) oder braune Blattränder verursacht (rechts).*

### **Ermittlung der Ährenzahl und des Ährenschiebens**

Die Ährenzahl und das Ährenschieben gelten als Indikatoren für den Ertrag und den Entwicklungsstand der Getreidekulturen. Üblicherweise wird die Anzahl der Ähren im Feldversuchswesen manuell erhoben, wogegen die KI-Bonitur aus UAS-Daten eine Möglichkeit zur Automatisierung darstellt. Die Anzahl der Ähren wurde zusätzlich durch visuelle Einschätzung im Bild, für die verschiedenen Parzellen bestimmt. Im Rahmen eines Landessortenversuchs (LSV) wurden Winterweizen und Wintergerste bonitiert und befliegen. Die Parzellen waren mithilfe von Markern identifiziert und die Ähren wurden sowohl im Feld als auch auf Drohnenbildern gezählt. Die Marker waren codiert, sodass diese automatisch eingelesen werden konnten und die Georeferenzierung Fehler ausschloss. Danach wurden das manuelle, KI-gestützte und automatisierte Verfahren durchgeführt, um die Anzahl der Ähren zu vergleichen.

Die Trainingsdatensätze stammten aus Befliegungen vom 10.06.2022, während die Evaluation auf Datensätzen aus 2023 mit unterschiedlichen Entwicklungsphasen basierte, um eine unabhängige und verlässliche Bewertung der Auswertung des BoniKI Prozessors zu gewährleisten. Die




Abb. 9: Boniturfäche im Winterweizen, aufgenommen mit einer Handkamera (links) und Drohnenbild (rechts).

Ährenzählung ergab, dass die manuelle Bonitur im Feld durchgehend höhere Werte lieferte als die KI-basierte Bildanalyse, da Überlagerungseffekte und Schattenwurf in Drohnenbildern zur unvollständigen Erkennung führten. Abweichungen von bis zu 15 Ähren zwischen den Methoden zeigten, dass die visuelle Bildbonitur zwar genauer war als die KI, jedoch die manuelle Feldzählung auf Parzellen begrenzt war. Mit der bildbasierten Bonitur kann der komplette Schlag gezählt werden. Unterschiede zwischen KI-gestützter und automatisierter Bonitur traten bei späteren Datensätzen auf, da die KI die Strukturen besser unterscheiden konnte. Insgesamt bleibt die manuelle Feldzählung die verlässlichste Methode, während KI-gestützte Ansätze durch kulturspezifisches Training weiter optimiert werden könnten. Erste Tests deuteten darauf hin, dass eine Aufteilung der Trainingsdaten nach Kulturen, wie Winterweizen und Wintergerste, die Genauigkeit der KI-Erkennung steigern könnte. Da Überlagerungen von Ähren nur im Feld und nicht auf Bildern vollständig erkannt werden können, berücksichtigt die Bonitur auf Drohnenbildern lediglich die oberste Schicht der Überlagerung. Bereits hier zeigt sich, dass die Verschattung in Drohnenbildern die Erkennbarkeit der Ähren stärker beeinträchtigt als im Vergleich zu Aufnahmen mit einer Handkamera (Abb. 9). Zudem könnte die Qualität der UAV-Bilder weiter optimiert werden, um die Erkennungsgenauigkeit zusätzlich zu verbessern.

Die manuelle Bonitur der Ährenzahl in Winterweizen und Wintergerste ließ sich nur schwer durch eine automatisierte Bonitur auf Grundlage von Drohnenbildern ersetzen. Wie bereits beschrieben, führten Faktoren wie Überlagerungen und begrenzte Bildauflösung dazu, dass auch bei visueller Bildbonitur mit dem menschlichen Auge nicht alle Ähren eindeutig erkannt werden konnten. Es war anzunehmen, dass ein neuronales Netz – unabhängig von der Qualität des Trainings – die Genauigkeit der manuellen Feldbonitur nicht vollständig reproduzieren können. Allerdings bestand die Möglichkeit, mithilfe eines KI-gestützten oder automatisierten Verfahrens eine



Korrelation zwischen der manuellen Feldbonitur und der bildgestützten Bonitur herzustellen. Mit den hier untersuchten Datensätzen konnte eine solche Korrelation nicht nachgewiesen werden, da die Stichprobe zu gering war und die Erkennung durch mehr Trainingsdaten optimiert werden müsste. Eine automatisierte Bonitur der Ährenzahl hätte für das landwirtschaftliche Versuchswesen und die Praxis eine hohe Relevanz, da dadurch die zeitaufwendige manuelle Bonitur ersetzt werden könnte. Darüber hinaus wäre es möglich gewesen, ganze Parzellen hinsichtlich des Boniturparameters auszuwerten, anstatt sich lediglich auf Stichproben zu beschränken, was eine umfassendere Bewertung erlaubt hätte. Möglich sind aber bereits flächendeckende Zählungen der obersten Schichten in beiden Kulturen.

### **Unkraut- und Bodendeckungsgrad**

Der Bodendeckungsgrad beschreibt den Anteil der Bodenfläche, der durch Kulturpflanzen und Unkraut bedeckt ist. Ein hoher Unkrautdeckungsgrad zeigt erhöhten Unkrautdruck, der um Licht und Nährstoffe mit der Kulturpflanze konkurriert und damit deren Wachstum und Ertrag beeinflusst. Ein vollständiger Bodenschluss bedeutet 100 % Bodendeckung durch Kulturpflanzen ohne offene Bodenflächen. Ein Bodendeckungsgrad von 0 % hingegen weist auf offenen Boden hin, entweder vor dem Durchbrechen der Kulturpflanzen oder bei einer bedeckten Fläche durch Unkraut. Die Trainings- und Validierungsdatensätze stammten aus Befliegungen im Jahr 2022, während der Evaluationsdatensatz aus dem Jahr 2023 erhoben wurde. Die visuelle Bildbonitur diente als Ground-Truth, da sie den aktuellen Stand der Technik widerspiegelt. Standort und Entwicklungsstadium des Mais (BBCH-Stadium) variierten zwischen den Trainings- und Evaluationsdatensätzen, um eine Unabhängigkeit der Daten sicherzustellen.

Die Auswertung des Datensatzes vom 10.06.2023 ergab Unterschiede zwischen den Methoden der visuellen, KI-gestützten und automatisierten Bildbonitur. Während die visuelle und KI-gestützte Bonitur zwischen Boden, Unkraut und Kulturpflanze unterschieden, fasste die automatisierte Bonitur Unkraut und Kulturpflanze in einer Klasse zusammen. Der Bodenanteil war bei allen Methoden am größten, doch die Anteile an Unkraut und Kulturpflanze variierten je nach Boniturmethode. Die visuelle Bildbonitur schätzte den kombinierten Anteil von Unkraut und Kulturpflanze höher ein als die KI-gestützte Methode, während die automatisierte Methode teils darüber, teils darunterlag. Die Analyse zeigte auch, dass die KI-gestützte Methode den Unkrautdeckungsgrad oft geringer einschätzte als die visuelle Bonitur, was auf Schwierigkeiten bei der Erkennung kleiner Unkrautstrukturen zurückzuführen ist. Die automatisierte Methode neigte zur Unterschätzung des Bodendeckungsgrades und zeigte Rauschen, was eine exakte Bodenbedeckung erschwerte. Diese Diskrepanzen könnten durch Erfassungsprobleme und Ungenauigkeiten bei der visuellen Schätzung verursacht worden sein. Die Ergebnismasken der automatisierten Bildbonitur zeigten, dass Kulturpflanzen und Unkraut erkannt wurden, jedoch auch Rauschen auf dem offenen Boden auftrat,

was zu einer Überschätzung des Bodendeckungsgrades führte. Da das automatisierte Verfahren insgesamt niedrigere Bodendeckungsgrade als die visuelle Methode ergab, besteht Optimierungspotenzial für eine genauere Schätzung. Im KI-gestützten Ansatz erkannte das neuronale Netz Unkräuter oft nur teilweise, was die Genauigkeit des Bedeckungsgrades einschränkt. Die automatisierte Bonitur zeigte die höchste Genauigkeit, obwohl bei der Zählung der Unkräuter die Ansätze nur geringfügig voneinander abwichen (Abb. 10). Somit wäre eine kombinierte Boniturmethode möglich. Die KI-Bonitur, die nur Pflanzenteile erkannte, könnte so optimiert werden, dass verschiedene Teile derselben Pflanze nicht mehrfach gezählt werden. Dies wäre ein bedeutender Schritt für die flächendeckende Erkennung von Unkräutern pro Quadratmeter. Für die Erhebung eines prozentualen Deckungsgrades ist jedoch eine weiterführende Annotation von Trainingsdaten erforderlich. Die Ermittlung des Unkraut- und Bodendeckungsgrades mittels Befliegung sowie automatisierter oder KI-gestützter Verfahren hat sich als wertvoll für das landwirtschaftliche Versuchswesen erwiesen. Diese Methoden ermöglichen eine quantitative Erfassung des Bestandschlusses und des Unkrautdrucks auf Einzelpflanzen. Da bisherige Schätzungen nur stichprobenartig und weniger präzise waren, bietet die Automatisierung großes Potenzial. Die Ergebnisse zeigen, dass KI-gestützte und automatisierte Verfahren eine objektive und reproduzierbare Alternative zur herkömmlichen Bonitur darstellen und möglicherweise eine flächendeckende Analyse ganzer Parzellen ermöglichen.

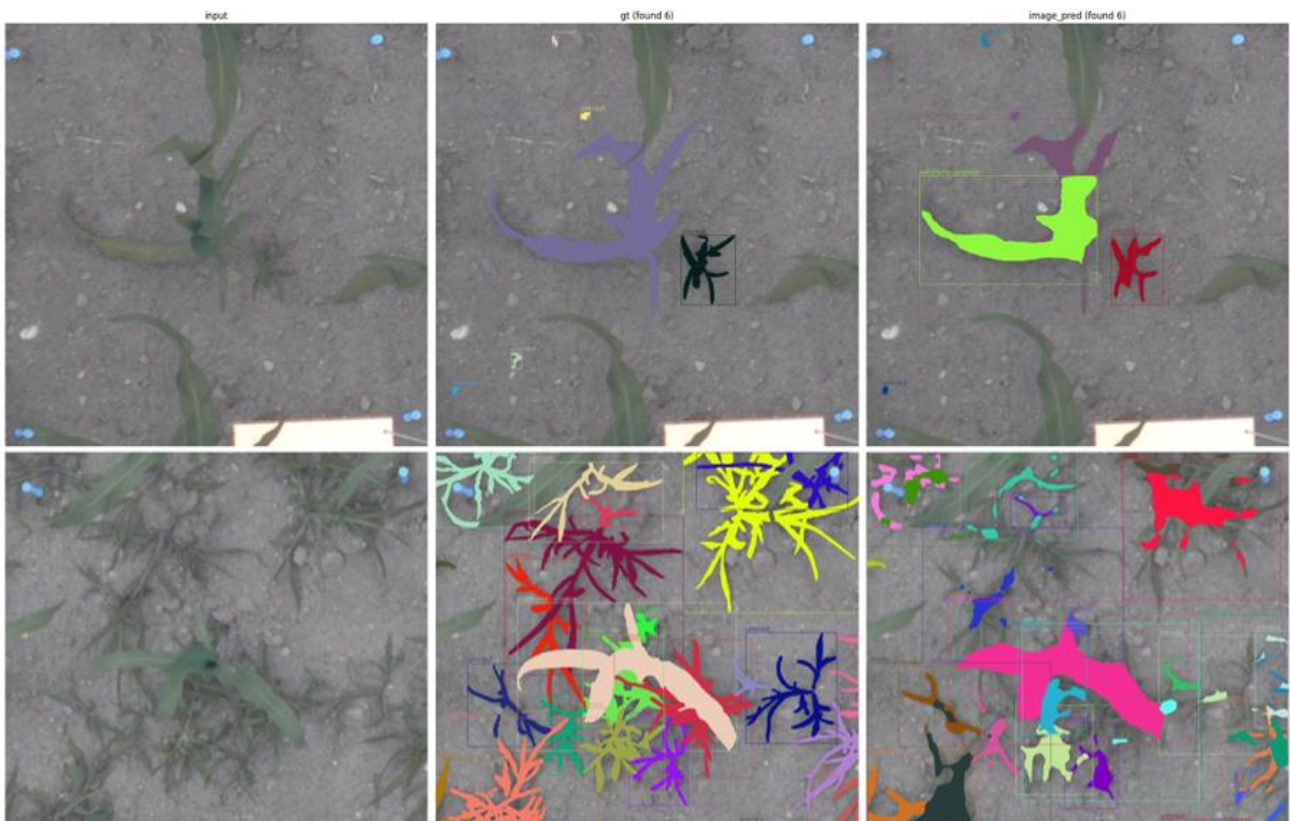


Abb. 10: Unkrautdetektion im Mais in zwei Szenarien. Wenige Unkräuter (oben), viele Unkräuter (unten).



### **3. Notwendigkeit und Angemessenheit der geleisteten Projektarbeit**

Die Förderung ermöglichte, neue Konzepte und Ansätze für die Digitalisierung der Landwirtschaft und des Feldversuchswesens zu entwickeln, insbesondere im Bereich der Bonitur. Die im Projekt verwendeten Ressourcen, wie etwa ein leistungsfähiges Notebook, waren notwendig, um Datenverarbeitung in einer Umgebung, die auf Bürokommunikation ausgelegt ist, zu ermöglichen. Weiterhin erforderte das Projekt speziell qualifiziertes Personal, das sich ausschließlich der Projektdurchführung widmete und die Arbeiten unter besonderer zeitlicher Flexibilität und Anpassung an Wetter-, Vegetations- und landwirtschaftliche Bedingungen durchführte. Durch die Förderung konnten verschiedene innovative Ansätze zur Bonitur im Feldversuchswesen entwickelt werden. Während Bonituren zuvor nur stichprobenartig durch Fachpersonal erfolgten, ermöglichte das Projekt nun eine großflächigere Bonitur mittels Befliegung und neuronaler Netze. So wurden in den Beispielkulturen Winterweizen, Wintergerste und Mais Boniturparameter automatisiert bestimmt. Die entwickelten Methoden sind skalierbar und für zusätzliche Parameter und Kulturen erweiterbar, was zukünftige Anwendungen ermöglicht. Das Projekt evaluierte realitätsnahe Bedingungen durch die Arbeit mit Daten aus dem Versuchswesen und präsentierte die Ergebnisse auf Feldtagen, nationalen und internationalen Fachkonferenzen in den Bereichen Agrarwissenschaft, Robotik und Automatisierung. Aufgrund der entstandenen Anschlussmöglichkeiten wird das Projekt BoniKI als zukunftsweisend angesehen und Folgeprojekte wurden bereits initiiert.

### **4. Voraussichtlicher Nutzen der Ergebnisse**

Die Projektergebnisse sollen mittelfristig im Rahmen der regelmäßig am LTZ stattfindenden Feldtage an Landwirte, Berater, Verwaltungstätige, Versuchstechniker und Entscheidungsträger weitergegeben werden, um sie in Fragen der Digitalisierung zu unterstützen. Ebenfalls ist geplant, den im Projekt entwickelten Prozessor bei der Bonitur eigener Feldversuche unterstützend einzusetzen. Im Zuge dessen ist geplant, bestehende Algorithmen in Aufträgen weiterzuentwickeln und neuronale Netze durch Nachtrainieren mit zusätzlichen Annotationsdaten zu optimieren. Die gewonnenen Erkenntnisse werden vom LTZ außerdem in der Beratung von Ministerien, Fachberatern und Landwirten verwendet sowie auf Konferenzen und Fachtagungen vorgestellt. Die Entwicklungen im Vorhaben BoniKI haben eine wichtige Grundlage für wissenschaftliche und wirtschaftliche Weiterentwicklungen in verschiedenen Anwendungsbereichen geschaffen. Die entwickelte Pipeline zur Vereinzelung und anschließenden Erkennung kann aufgrund der modularen Struktur und der flexiblen Trainingsalgorithmen auch in anderen Bereichen, eingesetzt werden. Insbesondere für den agrarwissenschaftlichen Bereich war BoniKI ein bedeutender Schritt, um das Erfahrungswissen von Experten aus der Landwirtschaft in neuronalen Netzen zu kodieren und so großflächigere Bonituren zu ermöglichen. Aus dem Projekt sind bereits Folgeprojekte und Beauftragungen hervorgegangen, darunter Anwendungen zur Detektion von Wildschäden im Mais,



bei denen die Systeme aus BoniKI auf einen neuen Kontext übertragen werden sollen.

Der wissenschaftliche Nutzen des Projekts zeigt sich insbesondere in der transparenten und detaillierten Dokumentation der Ergebnisse in Form von Beiträgen auf Fachtagungen und Konferenzen. Alle relevanten Aspekte wurden für die wissenschaftliche Community zugänglich gemacht und sind reproduzierbar. BoniKI leistet somit auch einen Beitrag zur Ausbildung und Förderung neuer wissenschaftlicher Fachkräfte. Im geplanten Anschlussvorhaben BlühKI sollen die im Projekt BoniKI gewonnenen Erkenntnisse und Erfahrungen genutzt und um auf Sprachmodellen basierte Methoden erweitert werden. Die im Projekt entwickelten Komponenten dienen dabei als Grundlage und Input für die neue Projektausrichtung.

### **5. Während der Durchführung des Vorhabens dem ZE bekannt gewordenen Fortschritts auf dem Gebiet des Vorhabens bei anderen Stellen**

Während des Projektzeitraums wurde regelmäßig nach weiteren Vorhaben, welche sich mit vergleichbaren Themengebieten beschäftigen, recherchiert. Dabei sind die nachfolgenden vier Vorhaben näher in den Fokus gerückt. Die Ergebnisse der bekannt gewordenen Forschungsprojekte wurden zur Projektlaufzeit analysiert und aufgearbeitet. Hierbei konnte jeweils eine klare Abgrenzung identifiziert werden.

- <https://www.sumiagro.com/case/anya/>: Betrachtet vor allem Ernährungsdefizite der Pflanzen oder Krankheitsausbreitung sowohl auf UAS als auch Satellitendaten.
- <https://www.hiphen-phenoscale.com/>: Produktentwicklung die auf UAV Bildern Ertrag, Biomasse und ähnliches berechnen. Nutzen auch vereinzelt Boniturparameter.
- <http://agrobotics.uni-bonn.de/projects/>: Bei WeedAI der Universität Bonn geht es um die automatisierte Bewertung von Unkrautbekämpfungsmaßnahmen aus UAS Bilddaten. Die spezifische Bonitur wird hier bei der Zuckerrübe durchgeführt.
- <https://www.phenoinspect.de/?lang=de>: Das Projekt Pheno Inspekt ist vor allem auf UAV Befliegungen von Versuchsflächen ausgerichtet und verwendet ebenfalls KI Ansätze um Einzelmerkmale zu bestimmen. Durch die Fokussierung auf kleine Flächen erfolgt jedoch ein anderer Auswerteprozess und Fokussierung auf andere Boniturmerkmale.

### **6. Erfolgten oder geplanten Veröffentlichungen des Ergebnisses nach Nr. 5 der NABF.**

Im Verfahren getätigte Veröffentlichungen wurden im gesamten Konsortium erarbeitet und dementsprechend mit den Projektpartnern gemeinsam veröffentlicht, je nach Zugehörigkeit des Erstautors ist der jeweilige Projektpartner für die Präsentation auf dem entsprechenden Kongress verantwortlich gewesen.

- Markus Strathmann, Christian Bauer, Robin Mink, Lennart Puck, Georg Heppner, Niklas



Spielbauer, Kurt Möller (VDLUFA 2022): BoniKI – KI-basiertes Bonitursystem für eine pflanzengenaue und autonome Bonitur

- Niklas Spielbauer, David Blumenthal, Lennart Puck, Georg Heppner, Markus Strathmann, Christian Bauer, Moritz Roth, Robin Mink, Alexander Linn, Arne Roennau, Rüdiger Dillmann (CASE 2023): Single Plant Detection and Isolation on High Resolution UAV Data

Als weitere Veröffentlichung ist ein Paper zur Bonitur unter Verwendung des MultiNet Ansatzes geplant, welches aktuell noch in Arbeit ist und auf einer Robotik Konferenz eingereicht werden wird. Der aktuelle Arbeitstitel lautet:

- Niklas Spielbauer, Lukas Sapich, Maximilian Schik, Lennart Puck, Georg Heppner, Markus Strathmann, Christian Bauer, Moritz Roth, Robin Mink, Alexander Linn, Arne Roennau, Rüdiger Dillmann: Individual Assessment of Plant Growth Parameters Utilizing a Multi-Net Approach

Neben den gelisteten Veröffentlichungen wurde das Projekt noch an weiteren Fachtagungen vorgestellt. Im Jahr 2023 wurde es zusätzlich mit einem Poster bei der GPW (Gesellschaft für Pflanzenwissenschaften e. V.) präsentiert. Fortschritte wurden auch im Rahmen der Jahreskonferenzen der Gesellschaft für Informatik in der Land-, Forst- und Ernährungswirtschaft (GIL) 2021 und 2024 präsentiert sowie bei verschiedenen LTZ Veranstaltungen. Zusätzlich dazu wurde BoniKI im Rahmen des Begleitforschungsprojektes X-KIT bei der Auftaktveranstaltung sowie Abschlussveranstaltung präsentiert. Ebenfalls wurde BoniKI in einem Artikel in der Landinfo (2022) präsentiert. Diese Zeitschrift informiert die baden-württembergische Landwirtschaftsverwaltung und ist für diese, im Gegensatz zu peer-Review Journals, eine wichtige Informationsquelle: Markus Strathmann, Christian Bauer (2022). Einsatz von Künstlicher Intelligenz (KI) zur Bestandsbeurteilung Projekt: BoniKI.