

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): FZI Forschungszentrum Informatik	Förderkennzeichen: 28DK120A20
Vorhabenbezeichnung: KI-Basiertes Bonitursystem für pflanzengenaue, autonome Bonitierung(BoniKI)	
Laufzeit des Vorhabens: 01.05.2021 bis 30.04.2024	
Berichtszeitraum: 01.05.2021 bis 30.04.2024	
Datum: 31.10.2024	Version: 1.0
Autor: FZI, LTZ, SAM	

1. Aufgabenstellung

Das Projekt BoniKI hat sich zum Ziel gesetzt eine automatisierte Bonitur von Einzelpflanzen mit UAS-Datenerfassung und KI-gestützter Auswertung zu ermöglichen. Damit soll eine neue Methode für die einfache, verlässliche und flexible Bonitur von Feldbeständen entwickelt werden. Eine robuste Erkennung, welche auch in herausfordernden Szenen mit Überdeckung, Verunkrautung und Sortenvarianz funktioniert, soll dabei durch das Lernen von Pflanzeigenschaften und Boniturparameteren durch KI-gestützte Ansätze ermöglicht werden. Im Rahmen des Forschungsvorhabens sollten die Ergebnisse der gelernten Bonitur mit denen einer automatisierten Bonitur sowie einer klassischen manuellen Bonitur gegenübergestellt.

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 an die Nutzung von Verbraucher-UAS mit moderater Bodenauflösung und hoher Befliegungszeit angeknüpft. Im Bereich der künstlichen Intelligenz gibt es eine Vielzahl an Bildsegmentierungsverfahren, die eine Bild in die Bestandteile zerlegen oder Klassifikation aufgrund von gelernten Merkmalen durchführen können. Insbesondere für die Bonitur wurden diese Verfahren noch nicht nennenswert eingesetzt.

3. Ablauf des Vorhabens

Zur Durchführung des Vorhabens wurden relevante Boniturparameter festgelegt hinsichtlich 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 Einzelungspipeline 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 im Bezug auf die zuvor festgelegten Boniturparameter, zum Beispiel das BBCH-Stadium oder Fahndetektion. Die automatisierte Bonitur basierte auf klassischen Bildverarbeitungsverfahren und hat die Bonitur anhand verschiedener Grenzwerte vorgenommen. 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 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 Trainings 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. Mit Hilfe 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, diese haben dann anhand der leicht unterschiedlichen Prädiktionen eine präzisere Vereinzelung vorzunehmen. 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 zu der Bonitur mit dem automatisierten Ansatz. Im Vergleich zu dem 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 in Veranstaltungen der Partner 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 Landessortenversuche am Standort Klein Hohenheim mit denen vom LTZ am Standort Grötzingen erhobenen Daten kombiniert, um den Umfang und die Variabilität des Datensatzes zu erhöhen.

Abschlussbericht

Eingehende Darstellung (Sachbericht Teil II)

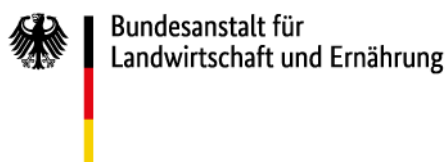
BoniKI

KI-Basiertes Bonitursystem für pflanzengenaue, autonome Bonitierung

Gefördert durch



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): FZI Forschungszentrum Informatik	Förderkennzeichen: 28DK120A20
Vorhabenbezeichnung: KI-Basiertes Bonitursystem für pflanzengenaue, autonome Bonitierung(BoniKI)	
Laufzeit des Vorhabens: 01.05.2021 bis 30.04.2024	
Berichtszeitraum: 01.05.2021 bis 30.04.2024	
Datum: 31.10.2024	Version: 1.0
Autor: FZI	

1. Vorhabens Übersicht

Ziel des Verbundprojektes BoniKI war es eine Pflanzengenaue Bonitur für Nutzpflanzen zu erstellen. Im Rahmen des Projektes wurden während der Wachstumsphase Mais und Winterweizen als Beispielkulturen in regelmäßigen Abständen befliegen und anhand der Daten von mehreren Vegetationsperioden verschiedene Boniturparameter erfasst. Insgesamt wurde ein gelernter KI-Bonituransatz entwickelt und mit einer klassischen Bonitur sowie einer automatisierten Bonitur in vergleich gesetzt. Abbildung 1 zeigt die Struktur der geplanten Arbeiten.

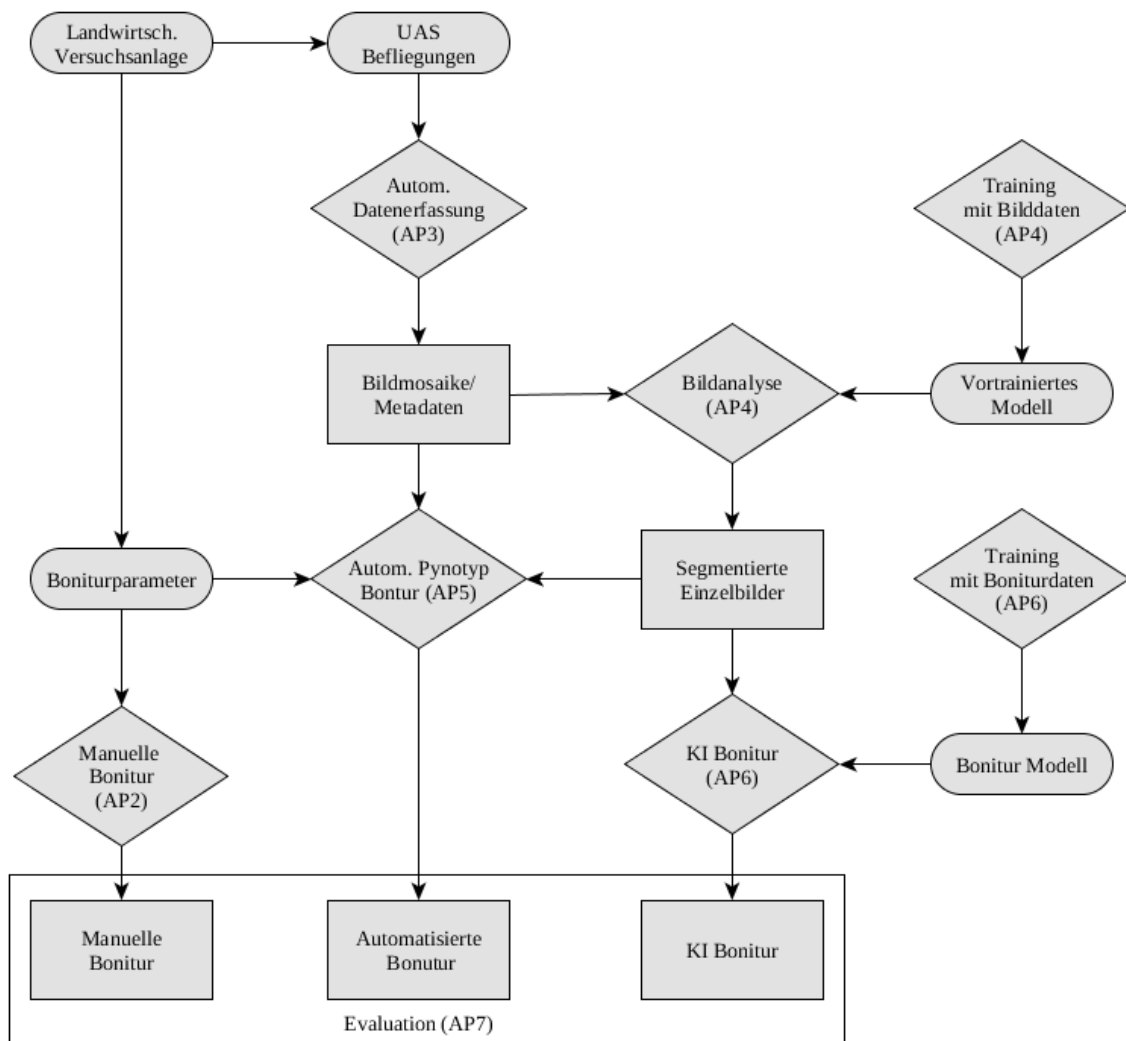


Abbildung 1 Übersicht und Zusammenhang der Arbeitspakete des Verbundprojektes BoniKI

Daten wurden in den Versuchsanlagen sowohl manuell (AP2) als auch mit einem UAS (AP3) gesammelt und dadurch die Grundlage für die weitere Aufbereitung geschaffen. Die Bilddaten wurden zudem durch eine Bildanalyse (AP4) auf Pflanzenebene vereinzelt und segmentiert. Auf Grundlage dieser Daten konnte dann eine manuelle (AP2), eine automatische (AP5) und eine KI-Gestützte (AP6) Bonitur entwickelt und die Ergebnisse gegeneinander Evaluieren (AP7) werden.

Dabei wurde die Arbeit zwischen den 3 Partnern LTZ, SAM und FZI gemäß ihren jeweiligen Schwerpunkten aufgeteilt. Während das LTZ vor allem die Bewertung, manuelle Bonituren und generelle Felderfahrung eingebracht hat wurden die Befliegungen und Entwicklung des UAS von SAM durchgeführt. Das FZI hat primär die automatischen verfahren, die Auswertepipeline und die KI entwickelt. Im Folgenden sind die Ergebnisse der FZI-Arbeiten im Detail aufgeführt

2. Durchgeführten Arbeiten im Rahmen des Vorhabens

AP 1: Koordination Management

Zielstellung:

Unter AP1 wurde die zentrale Koordination des Projekts und die organisatorische Leitung des Konsortiums abgedeckt. Ziel war es, durch regelmäßige Treffen, strukturierte Kommunikation und definierte Prozesse einen reibungslosen Ablauf der Projektarbeiten sicherzustellen und den Fortschritt zu dokumentieren.



Abbildung 2 Gemeinsame Feldbegehung mit Befliegung und manueller Bonitur

Ergebnisse:

Das Kickoff-Treffen, welches den Startschuss für die gemeinsame Projektarbeit bildete (Meilenstein M1.1), wurde erfolgreich organisiert. Darüber hinaus wurde eine technische

Kommunikationsinfrastruktur, bestehend aus einer zentralen Datenablage, Mailinglisten und einer Plattform für Webkonferenzen, die den regelmäßigen Austausch zwischen den Partnern ermöglichte (Meilenstein M1.2), eingerichtet. Im Rahmen der monatlichen Videokonferenzen leitete das FZI die Koordination der Arbeitspakete und stellte sicher, dass alle Partner kontinuierlich über den Projektfortschritt informiert wurden. Zusätzlich wurden verschiedene Templates erstellt, die die Partner bei der strukturierten Projektdurchführung unterstützten.

Ein weiterer wesentlicher Beitrag war die Koordination und Dokumentation der Konsortialtreffen sowie die Abstimmung der Arbeitsergebnisse. In enger Zusammenarbeit mit den Projektpartnern wurde der Abschluss des Projekts vorbereitet, was die termingerechte Abgabe des technischen Abschlussberichts umfasst (Meilenstein M1.3). Zudem wurde eine Projektskizze für das Folgeprojekt „BlühKI“ erfolgreich mit den Konsortialpartnern eingereicht, welche im Rahmen des Förderaufrufs „Experimentierfelder zur Digitalisierung und KI in der Landwirtschaft“ weiterentwickelt werden soll. Insgesamt konnte durch die Koordination ein reibungsloser Projektverlauf sichergestellt und somit die erfolgreiche Umsetzung der geplanten Meilensteine gewährleistet werden.

AP 2: Bonitur und Feldversuchswesen

Zielstellung:

Im Rahmen von AP2 sollte das LTZ bei der Planung und Auswertung der Bonituren, die als Grundlage für das Training von KI-Methoden dienen, unterstützt werden. Ziel war es, die manuell erhobenen Boniturdaten so zu gestalten, dass sie den technischen Anforderungen der späteren automatisierten und gelernten Bonitur entsprechen.

Ergebnisse:

Die zu bonitierende Parameter wurden ausgiebig diskutiert und gemeinsam mit den Projektpartnern definiert. Insbesondere wurde darauf geachtet, dass die erhobenen Daten für die spätere Vereinzelung und gelernte Bonitur geeignet sind (Meilenstein 2.1). In diesem Rahmen wurde dem LTZ auf Basis des Annotationstools CVAT ein Docker Container mit entsprechenden projektspezifischen Konfigurationen zur Verfügung gestellt. Dieses Tool konnte dann zur manuellen Annotation der Befliegungsdaten genutzt werden. In enger Abstimmung der Partner wurde sichergestellt, dass die annotierten Daten der Anforderung der späteren Analyse genügen. Im Laufe des Projektes wurden durch regelmäßige Iterationsschleifen der Prozess gemeinsam mit den Projektpartnern verfeinert.




Abbildung 3 Annotationstool CVAT mit definierter Konfiguration um Datensätze von den Experten Annotieren zu lassen

Um das Wissen zu verfeinern, wurde an ausgewählten Befliegungen mit allen Projektpartnern parallel eine Einführung in die manuelle Bonitur gegeben um somit eine gemeinsame Basis der realen Bedingungen der Landwirtschaftlichen Praxis zu gewinnen. Dieses Verständnis konnte dann in den gemeinsamen Abstimmungen berücksichtigt werden.

AP 3: UAS Datenerfassung

Zielstellung:

Im Rahmen von AP3 sollten Datensätze aus Befliegungen mittels UAS (Unmanned Aerial Systems) über die Versuchsflächen generiert werden. Ziel war es, hochauflösende Bilddaten zu erzeugen und daraus georeferenzierte Einzelbilder, Orthophotos sowie Höhenmodelle zu erstellen, die als Grundlage für die Bildbonitur dienen. Diese Daten sollten so aufbereitet werden, dass sie in der KI-basierten Analyse genutzt und für Trainingsdaten verwendet werden können.

Ergebnisse:

Im Rahmen des APs wurden durch regelmäßige Diskussionen mit insbesondere SAM Dimension die Anforderungen an die Bilddaten spezifiziert. Dies diente der Qualitätssicherung und Optimierung der Daten für die entwickelte Auswertepipeline in den folgenden Arbeitspaketen. Insbesondere wurde der Befliegung und Erfassung beratend begleitet. In enger Zusammenarbeit wurde so die Verarbeitungspipeline der Rohdaten adaptiert, so dass die Daten in einem einheitlichen Format vorlagen

Weiterhin wurden in enger Zusammenarbeit die Datensätze der verschiedenen Vegetationsperioden gesichtet und in Daten für das Training der gelernten Verfahren und Daten für die Evaluation der drei

Boniturverfahren unterteilt. Hierbei wurde darauf geachtet, dass die Daten aus verschiedenen Vegetationsperioden kommen, um ein Bias im Training der KI-Methoden zu vermeiden, und dass bereits bekannte Pflanzen zur Evaluation genutzt werden. Zusätzlich wurde ein NAS angeschafft und eingerichtet damit die Daten am FZI gespiegelt werden und unmittelbar für die automatisierte und gelernte Bonitur verwendet werden konnten.

AP 4: Bildanalyseverfahren

Zielstellung:

In AP4 wurde eine Verarbeitungspipeline entwickelt, die es ermöglicht, die großen Bildmosaik-Datensätze aus AP3 weiter zu verarbeiten und für die Analyse vorzubereiten. 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 in diesem Arbeitspaket bestand darin, die großflächigen Bilddaten aus AP3 in eine Form zu bringen, die für die KI-gestützte Auswertung geeignet ist. Dies umfasste die Entwicklung einer automatisierten Pipeline, die die Bilder in Segmente unterteilt, sodass einzelne Pflanzen isoliert und analysiert werden können. Eine effiziente Verarbeitung der Bilddaten sowie die Bereitstellung der Boniturergebnisse in einem GIS-kompatiblen Format waren weitere zentrale Aufgaben.

Ergebnisse:

Die Verarbeitungspipeline wurde unter Verwendung von ROS als Kommunikationsframework implementiert. Dabei wurde die Pipelinestruktur so gestaltet, dass alle erforderlichen Tools integriert und die Vollständigkeit der Bilddaten auf dem Server überprüft werden kann. Somit kann jeder Datensatz initial analysiert werden und bei Bedarf vorhergehende Analyseschritte ausgeführt werden. Zur besseren Nutzbarkeit wurde hier zusätzlich zu den geplanten Aufgaben eine graphische Nutzeroberfläche für die Pipeline umgesetzt. Diese ermöglicht es Anwendern, die erstellte Auswertepipeline einfach zu nutzen. Die Nutzeroberfläche steuert sowohl die Vereinzelung aus AP4, sowie die automatisierte Bonitur (AP5) und die gelernte Bonitur (AP6). Durch diese vereinfachte Nutzbarkeit konnten die Projektpartner die entwickelten Modelle effizient in der Evaluation (AP7) nutzen.



Abbildung 4 Graphische Benutzeroberfläche für die Bonitur von Felddaten

Weiterhin wurden in diesem AP die Schnittstellen mit den Projektpartnern definiert und ausgearbeitet. So entstanden in diesem Arbeitspaket Werkzeuge, um Daten automatisch vom Server zu laden, und auf einer lokalen Instanz auszuführen, als zweite Option kann die graphische Oberfläche lokal gestartet und die Auswertung auf einer remote Instanz ausgeführt werden. Dies minimiert die benötigte Datenübertragung und ermöglicht den Einsatz auf mobilen Endgeräten. Als Ausgabeformat der Verarbeitungspipeline werden die Daten in Form von georeferenzierten Bildern bereitgestellt, zusammen mit den Karten können diese in gängigen GIS-Anwendungen (z.B.: QGIS geladen werden) und dort weiterverarbeitet werden.

AP4.2: Segmentierung der Pflanzen

Zielstellung:

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

Ergebnisse:

Im Rahmen des Vorhabens wurde für die Pflanzensegmentierung und der anschließenden

Vereinzelung ein mehrstufiges Verfahren entwickelt. Zunächst wurde auf den Eingabebildern aus dem vorherigen AP ein Grünwertfilter gelegt. Dieser wurde so gewählt, dass er eine grobe




Abbildung 5 Links: Spärliche Segmentierung durch Grünwertfilter, Rechts: Erkannte Instanzen des Siamesischen Netzwerks

Segmentierung vornimmt und nur bei sicheren Kandidaten eine Annotation vornimmt. Dies bedeutet, dass die Pflanzen bestimmte Kriterien an Größe und Abstand zu Nachbarpflanzen erfüllen mussten. Diese Vorverarbeitung resultierte in einem automatisch generierten spärlich annotierten Datensatz. Auf Grundlage dieses Datensatzes konnte anschließend ein Neuronales Netz trainiert werden, um die Pflanzen auf dem gesamten Feld zu detektieren und zu segmentieren (Abbildung 6). Für das Training wurde ein Co-Mining Ansatz in Form eines siamesischen Netzwerkes umgesetzt. Dieses besteht aus zwei identischen neuronalen Netzwerken, die dieselben Gewichte teilen und parallel arbeiten. Diese Architektur wird verwendet, um zwei Eingaben miteinander zu vergleichen und ähnliche oder unterschiedliche Merkmale zu erkennen. Im Kontext der Pflanzenerkennung dient das siamesische Netzwerk dazu, eine Bildpaarung zu analysieren: Ein Bild und seine durch Augmentation leicht veränderte Version werden gleichzeitig verarbeitet. Die Vorhersagen der beiden Zweige werden anhand eines Konfidenzschwellenwertes gefiltert. Niedrige Konfidenzwerte deuten darauf hin, dass diese Vorhersagen wahrscheinlich falsch sind (z.B. keine Pflanze oder überlappende Pflanzen). Non-Maximum Suppression (NMS) wird angewendet, um doppelte oder überlappende Bounding Boxes zu eliminieren. Dies reduziert die Anzahl der falschen und doppelten Erkennungen. Die übrig gebliebenen Vorhersagen werden mit den echten zusammengeführt und für das Training des Netzwerks verwendet. Dies verbessert die Genauigkeit der Pflanzenerkennung im Laufe der Zeit. Durch den reduzierten manuellen Aufwand können so schnell neue Pflanzen eingelernt werden und das Verfahren dadurch leicht für neue Kulturen angewandt werden.



Abbildung 6 Vereinzlung der Pflanzen mit Hilfe eines Siamesischen Netzwerkes

Die Segmentierungen für die Bonitur selbst wurden im Rahmen der folgenden Arbeitspakete umgesetzt, in AP5 für die automatisierte Bonitur und in AP6 für die gelernte Bonitur.

AP4.3: Vereinzlung der Pflanzen und Pflanzenteile

Zielstellung:

Die vereinzelt Pflanzeninstanzen sollten in separaten Bildern dargestellt werden, um eine detaillierte Analyse zu ermöglichen. Insbesondere die Vereinzlung von überlappenden Pflanzen stellte eine Herausforderung dar.

Ergebnisse:

Die aus dem vorherigen AP4.2 gewonnenen Informationen über die Pflanzeninstanzen wurde in diesem AP genutzt, um Kacheln um die jeweiligen Instanzen zu generieren. Es lassen sich insbesondere zwei Fälle voneinander unterscheiden: Zum einen gibt es Kulturen, bzw. Boniturparameter, in denen eine pflanzengenaue Vereinzlung nicht relevant oder möglich ist. So ist beispielsweise bei der Fahndetektion im Mais die Parzelle und die Reihe relevant, in denen nach erfolgter Entfahnung noch Fahnen vorhanden sind. Dementsprechend wird hierfür ein Ansatz gewählt, der die hochaufgelösten Bilder in Kacheln ohne Überlappung zerteilt und für die nachfolgenden Schritte vorbereitet. Für Boniturparameter, wie das BBCH-Stadium ist hingegen die Einzelpflanze relevant. In diesem Fall wird eine Kachel zurechtgeschnitten, die auf den Pflanzenmittelpunkt, zentriert ist. Dies ermöglicht den nachfolgenden Netzen, sich auf die Gesamtpflanze zu konzentrieren und vermeidet Artefakte durch Überhang auf andere Kacheln. In beiden Ansätzen werden die Kacheln auf eine feste Größe zugeschnitten, die als Eingabe für die nachfolgenden Schritte dient. Die bereits in AP4.1 erwähnte Nutzeroberfläche wurde dahingehend erweitert, sodass der Nutzer auswählen kann, ob er eine Zerteilung anhand der Modelle aus AP4.2 wünscht, oder ob ein direktes Kacheln vorgenommen werden soll.




Abbildung 7 Pipeline zur Vereinzelung der Daten in Pflanzenzentrierte Kacheln

Die Ergebnisse der Vereinzelung werden als Artefakt abgespeichert, so dass nicht in jedem Boniturdurchlauf die Gesamtpipeline erneut ausgeführt werden muss. Somit können die entstandenen Kacheln für unterschiedliche Bonituren genutzt werden und dienen gleichzeitig als Basis für die verschiedenen Stränge der Bonitur in der Evaluation. Neben den Kacheln selbst werden noch die Geoinformationen abgespeichert, dies ermöglicht es die entstandenen Kacheln in Systemen wie QGIS georeferenziert zu visualisieren.

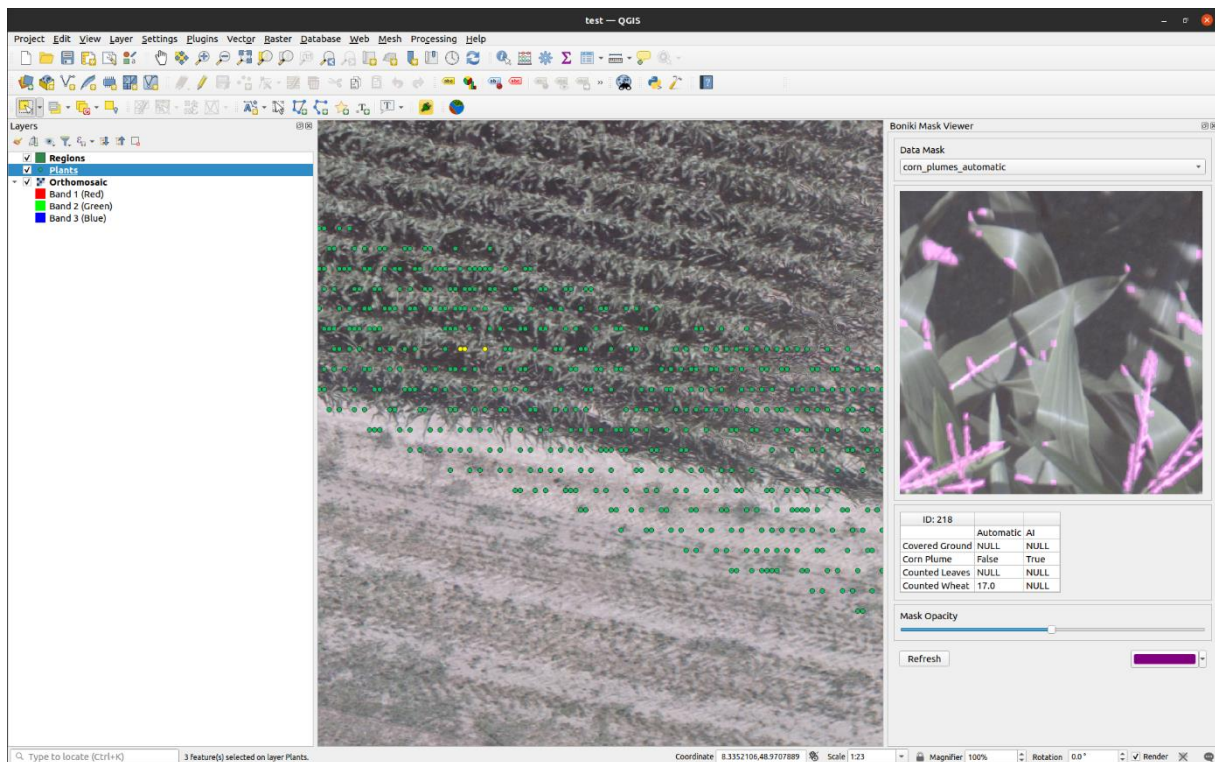


Abbildung 8 Darstellung der vereinzelt Pflanzen inklusive Bonituren in QGIS

AP5 Automatische Phänotypische Bonitur

Zielstellung:

In diesem Arbeitspaket geht es darum, die segmentierten Einzelpflanzen und die erstellten Orthofotos automatisch anhand analytischer Algorithmen zu bonitieren. Das Ziel ist es, verschiedene

Metriken zur Beurteilung der Pflanzen und Felder, wie den Bedeckungsgrad oder Fahndetektion, zu berechnen. Die Algorithmen sollen an die Gesamtpipeline angebunden sein und ihre Ergebnisse in einem standardisierten Datenformat ausgegeben werden.

Ergebnisse:

Die automatisierte Berechnung von Metriken für größere Bildbereiche (Felder) wurde erfolgreich durchgeführt. Der Gesamtbedeckungsgrad wurde auf Grundlage pixelbasierter Segmentierung und Farbhistogrammen analysiert und die Ergebnisse konnten mit manuell erhobenen Daten verglichen werden. Insbesondere wurden auf Feldebene Methoden zur Berechnung des Bedeckungsgrades entwickelt und implementiert. Diese wurden mit Hilfe von Grünwertfiltern und Histogrammanalysen durchgeführt. Mithilfe von Clustering Methoden wurde zusätzlich versucht Unkraut von Nutzpflanzen Anhand der Größe der jeweiligen Pflanze zu trennen, um hier eine präzisere Aufschlüsselung zu haben.




Abbildung 9 Ergebnisse der automatisierten Bonitur für die Detektion von Ähren im Winterweizen

Auf Pflanzenebene wurden Merkmale wie Fahndetektion im Mais und Ährenzählung im Winterweizen umgesetzt. Auch hierbei kamen vor allem Histogrammanalysen sowie Farbfilter zum Einsatz. Die Fahndetektion ist sehr abhängig vom Abreifungsgrades der Maispflanzen. Solange diese noch Grün sind, kann man die Fahnen mit den automatisierten Verfahren gut erkennen, sobald der Mais sich aber verfärbt ähneln sich der Farbton der Fahnen und des Mais zunehmend. Dementsprechend wird dann eine Erkennung rein auf Farbebene sehr schwierig. Ähnlich sieht es beim Ährenzählen aus, dort ähneln sich die Farben von Ähre, Halm und Blatt stark, dementsprechend wurden weitere Schritte wie Kontur und Größenfilter in die Pipeline eingebaut. Allerdings hat sich in der Praxis gezeigt, dass die Verfahren für jeden Datensatz ein Nachjustieren

der Parameter benötigen, damit die Merkmale sicher erkannt werden können. Die Generalisierung von automatisierten Verfahren Bedarf demnach manuelle Nacharbeit in der Auswertung. Gleichzeitig sind die Verfahren anfällig für Verdeckungen.

Die entstandenen Ergebnisse auf Feld und Pflanzenebene wurden so aufgearbeitet, dass diese in QGIS visualisiert werden können. Hierbei können die entstandenen Masken und Instanzen dargestellt werden, so dass die Anwender in bereits bekannten Programmen, die Ergebnisse visuell darstellen können. Gleichzeitig wurden die Ergebnisse in Tabellarischer Form aufgearbeitet, so dass diese für AP7 für die Evaluation aufgearbeitet sind.

AP6: Gelernte KI-Bonitur

Zielstellung:

Das Ziel von AP6 ist die Entwicklung eines neuronalen Netzwerks, das Boniturmerkmale auf den in AP4 erstellten Kacheln analysiert. Die Aufgabe des Netzwerks ist es, das Expertenwissen der Bonitur zu kodieren und generalisierbare Klassifikationen für verschiedene Pflanzenarten zu erstellen. Dabei wird das Netzwerk mithilfe manueller Annotationen eines Experten trainiert. Im Fokus steht die Entwicklung einer geeigneten Netzwerkarchitektur sowie effizienter Trainingsstrategien, um die begrenzten verfügbaren Daten optimal zu nutzen. Es soll weiterhin untersucht werden, wie man die Datenanforderungen für das Netzwerk reduzieren kann.

AP6.1: Konzeption einer geeigneten Netzwerkarchitektur

Zielstellung:

In AP6.1 soll eine geeignete Netzwerkarchitektur für die Bonitureinschätzung entwickelt werden. Dazu müssen die Ein- und Ausgaben des neuronalen Netzwerks spezifiziert werden, wobei als Eingabe die vorverarbeiteten Pflanzenbilder aus AP4 sind. Ziel ist es, eine Architektur zu entwickeln, die entweder einen allgemeinen Pflanzen-Score oder spezifische Boniturmerkmale zuverlässig bewerten kann. Das Netzwerk soll praxisnah definiert und mit dem Wissen der Projektpartner abgestimmt werden.

Ergebnisse:

Zunächst wurden verschiedene Architekturentwürfe erarbeitet und analysiert. Hierbei wurden die Vorzüge und Nachteile der jeweiligen Architekturen hinsichtlich der Datenmenge und vermuteten Genauigkeit erarbeitet. Aufgrund der spezialisierten Domäne und der geringen Datenmenge an vorhandenen Datensätzen wurde sich für eine MultiNet Architektur entschieden. Diese besitzt die Besonderheit, dass der Encoder (der Backbone) des Neuronalen Netz auf allen vorhandenen Daten gemeinsam trainiert wird. Anschließend werden aus dem gemeinsamen latenten Raum verschiedene Decoder genutzt um die spezifischen Boniturparameter zu inferieren. Dieser Ansatz bietet den Vorteil, dass in dem latenten Raum pflanzentypische Parameter gemeinsam encodiert werden. Dementsprechend sind pro Boniturparameter weniger Annotierte Daten nötig. In einer

Erweiterung wurde dann noch ein Region Proposal Backbone umgesetzt, um den latenten Raum zu erzeugen. Dieser erzeugt zunächst mögliche Kandidaten, die dann auf Features überprüft werden, einer der bekanntesten Beispiele, die eine solche Architektur verwenden ist das Mask-RCNN¹. Diese Architektur verbessert insbesondere die Ergebnisse für Instanzsegmentierungen, in dem möglichen Kandidaten bereits im Backbone identifiziert werden. Die weiteren Decoder, beispielsweise Regressionen für die Erkennung des BBCH-Stadiums sind durch den angepassten Backbone unverändert. Auch hier wurde das System wieder an die graphische Benutzeroberfläche angebunden und vom Nutzer können die verschiedenen Boniturparameter selektiert werden, die von Interesse sind, sowie der jeweils auszuwertende Datensatz.

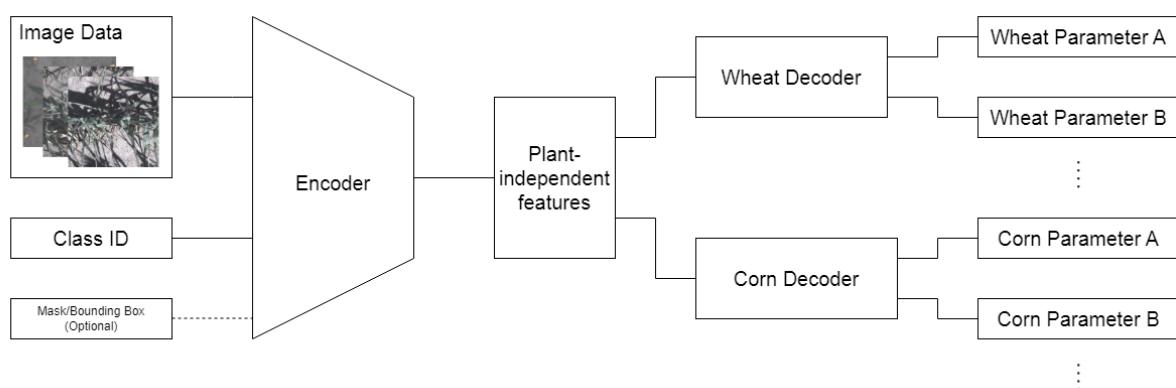


Abbildung 10 Aufbau der MultiNet Struktur, der gemeinsame Latente Raum speichert effizient Pflanzentypische Features, welche dann in den unterschiedlichen Decodern genutzt werden können

AP6.2: Entwicklung von effizienten Trainingsstrategien

Zielstellung:

AP6.2 zielt darauf ab, effiziente Trainingsstrategien für das neuronale Netzwerk zu entwickeln, um die begrenzten verfügbaren Daten optimal zu nutzen. Dabei soll untersucht werden, ob das Training einer Pflanzenart Rückschlüsse auf andere Pflanzenarten ermöglicht (Transfer Learning). Außerdem soll analysiert werden, wie die Daten aus AP5 im Training verwendet werden können, um die Boniturergebnisse weiter zu verbessern. Das Ziel ist es, durch gezieltes Training die Performance des Netzwerks zu steigern und die Übertragbarkeit auf neue Pflanzenarten zu maximieren.

Ergebnisse:

Der im vorherigen AP Entwickelte MutliNet Ansatz wurde so in eine Trainingspipeline integriert, dass auch Anwender das Netz mit eigenen Daten nachtrainieren können. Hierbei kann das Netz sowohl von einer Basiskonfiguration mit initialisierten Gewichten aus trainiert werden, als auch von einem bestehenden Netz, das durch die neuen Daten verfeinert wird. Insbesondere wurden den Anwendern verschiedene Strategien an die Hand gegeben, wie das MultiNet trainiert werden kann.

¹ Mask R-CNN – K. He, G. Gkioxari, P. Dollár and R. Girshick (2017)

Es kann entweder mit allen Daten parallel trainiert werden, so dass der jeweilige Fehler eines Decoders im MultiNet in den Encoder eingespeist wird. Alternativ wird nur der jeweilige Decoder trainiert und der Encoder bleibt unverändert. Letzteres ist insbesondere relevant, wenn der Datensatz sehr ungleichmäßig für die verschiedenen Decoder ist. So wird das Netz am besten trainiert, wenn die Daten gleichmäßig auf die Decoder verteilt sind. Bei einer ungleichmäßigen Verteilung löst man dieses Problem, indem das Gesamtnetz auf einem Subset der Daten trainiert wird und die Decoder anschließend auf dem gesamten Datensatz verfeinert werden.




Abbildung 11 Ergebnisse der Fahndetektion im Mais von der gelernten KI-Bonitur mittels MultiNet
Weiterhin wurde das Netzwerk so konzipiert, dass es um neue Boniturparameter und Pflanzenarten erweitert werden kann. Hierbei kann Transfer Learning genutzt werden, um für neue Kulturen den Backbone, der bereits auf anderen Pflanzenarten trainiert worden ist, zu verfeinern und weiter einzusetzen. Dementsprechend können bereits vorhandene Features wiederverwertet werden. Bei der Untersuchung, ob die Ergebnisse aus AP5 weiterverwertbar sind, stellte sich heraus, dass diese mit starkem Rauschen versehen sind. Um diese sinnvoll zu verwerten wären manueller Aufwand nötig, um einen homogenen Datensatz zu erzeugen. Dementsprechend ist ein manuell annotierter Datensatz, der aus weniger Datenpunkten, dafür aber heterogenen Daten besteht, besser verwertbar. Die Performancesteigerung und Erweiterbarkeit wurde in dem verwendeten System durch die Architektur und selektierten, guten Datenpunkte umgesetzt. Dies ermöglicht es den Anwendern mit weniger Trainingsbeispielen bessere Ergebnisse zu erzielen.




Abbildung 12 Ergebnisse der Ährendetektion im Winterweizen der KI Bonitur mittels MultiNet

AP7: Evaluation

Zielstellung:

Die Evaluation des Projekts soll in enger Zusammenarbeit mit Projektpartnern durchgeführt werden. Im Fokus steht die Beurteilung der trainierten neuronalen Netze aus AP6, der automatisierten Bonituren aus AP5, sowie einer manuellen Bonitur. Für die Evaluation soll ein unabhängiger Evaluationsdatensatz erstellt werden. Die manuell erhobenen Daten dienen dabei als Ground Truth, gegen die die automatisierten und gelernten Auswertungen verglichen werden. Des Weiteren werden die Projektergebnisse auf nationalen und internationalen Konferenzen und Feldtagen präsentiert. Ziel ist es, die Praxistauglichkeit der entwickelten Verfahren zu bewerten und die Ergebnisse der wissenschaftlichen Community sowie potenziellen Anwendern in der Landwirtschaft zugänglich zu machen.

Ergebnisse:

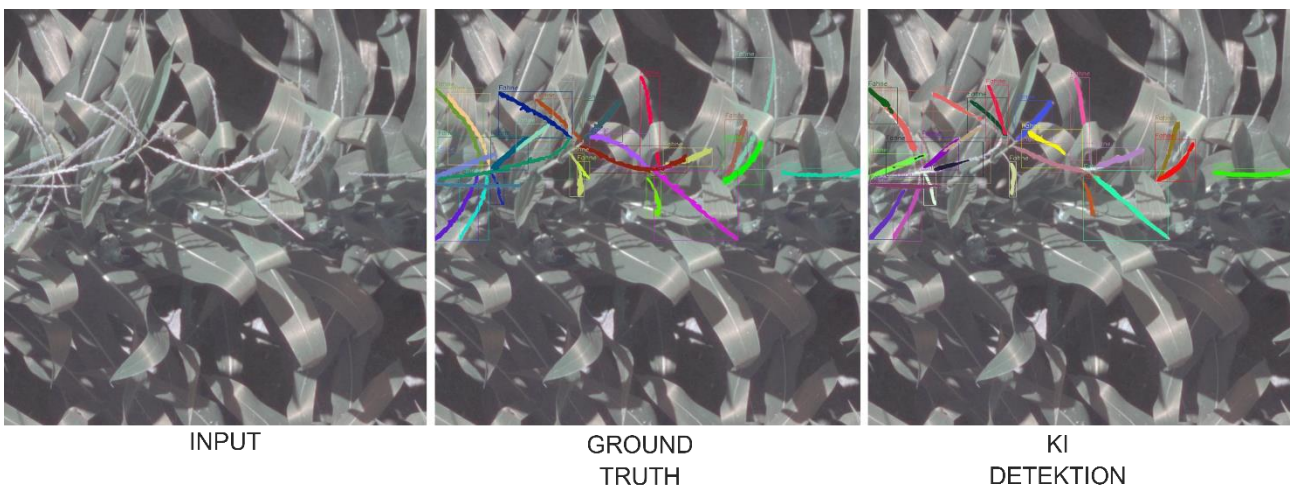


Abbildung 13 Vergleich der Ground-Truth und KI-Basierten Erkennung von Maisfahnen

Im Rahmen der Evaluation wurde das LTZ mit dem Knowhow aus den vorherigen APs unterstützt, die Pipeline wurde dahingehend angepasst, dass die eigentliche Ausführung und Ergebnisgenerierung von Seiten des LTZ ausgeführt werden konnte. So wurde sichergestellt, dass kein Entwickler Bias in der Auswertung eingeflossen ist. Weiterhin wurde mit den Projektpartnern die Auswahl des Evaluationsdatensatzes durchgeführt, hierbei wurde insbesondere darauf geachtet, dass der Evaluationsdatensatz aus einer anderen Vegetationsperiode als die Trainingsdatensätze stammt, um auch hier keinen Bias oder Verfälschung der Ergebnisse zu erzeugen.




Abbildung 14 Vergleich der Ground-Truth und KI-Basierten Erkennung von Ähren

Die Projektergebnisse wurden auf verschiedenen Veranstaltungen über die Projektlaufzeit vorgestellt. So wurde das LTZ bei der Erarbeitung der Paper Beiträge und Projektvorstellungen für die GIL, GPW und VDLUFA unterstützt. Weiterhin wurde ein Beitrag in der Zeitschrift Landinfo (Ausgabe 2-2022) gemeinsam im Konsortium verfasst.

Auf der CASE 2023, einer der drei Flagship Konferenzen der IEEE im Bereich Robotik, wurde 2023 das Peer-Reviewte Paper „Single Plant Detection and Isolation on High Resolution UAV Data“ veröffentlicht. Dieses stellt die Ergebnisse aus dem AP4 vor und zeigt den Einsatz des siamesischen Netzwerkes für die Vereinzelung von Pflanzen. Ein weiteres Paper über die Ergebnisse der Evaluation und der Darstellung der Ergebnisse aus AP6 mit dem Working Title „Individual Assessment of Plant Growth Parameters Utilizing a Multi-Net Approach“ ist aktuell in Arbeit.

Weiterhin wurde das Projekt im Rahmen des FZI Open House mit einem Demonstrator und Video der Projektergebnissen vorgestellt. Ebenfalls wurde es auf der Abschlussveranstaltung des Begleitforschungsprojektes X-KIT präsentiert. Neben der Abschlussveranstaltung von X-KIT wurde das Projekt auch in mehreren Clustertreffen vorgestellt und relevante Aspekte den anderen geförderten Projekten präsentiert und über die Fragestellungen gemeinsam diskutiert.

3. Notwendigkeit und Angemessenheit der geleisteten Projektarbeit

Die Förderung ermöglichte die Entwicklung und Konzeptionierung neuer Ansätze in der Landwirtschaft im Kontext der Bonitur. Bisher wurden Bonituren nur Stichprobenartig von geschultem und erfahrenem Fachpersonal durchgeführt. Durch die im Vorhaben geleistete Projektarbeit konnte ein Ansatz entwickelt werden, der dem Fachpersonal zur Hilfe steht, um mittels Befliegungen großflächigere Bonituren vorzunehmen. Dadurch wurde es möglich, das in den gewählten Beispielkulturen vom Winterweizen und Mais unterschiedliche Boniturparameter automatisiert mit Hilfe von Neuronalen Netzen bestimmt werden können. Die entwickelten Ansätze sind erweiterbar für weitere Parameter und Kulturen und können dementsprechend in zukünftigen Arbeiten verwendet werden. Durch die Erprobung der Verfahren auf im Projekt aufgenommene Realdaten konnten erwartbare Bedingungen und Umgebungen evaluiert werden. Die im Projekt entwickelten Ergebnisse wurden auf Fachtagungen, sowie nationalen und internationalen Konferenzen im Agrarbereich, sowie der Robotik und Automatisierung vorgestellt. Durch die entwickelten Anknüpfungspunkte positioniert das Projekt BoniKI als zukunftsfähiges und verwertbares Projekt. So wurden bereits Anträge für Folgeprojekte eingereicht und gestartet.

4. Voraussichtlicher Nutzen, insbesondere der Verwertbarkeit des Ergebnisses im Sinne des fortgeschriebenen Verwertungsplans

Die Entwicklungen im Vorhaben BoniKI haben den Grundstein für wissenschaftliche und wirtschaftliche Weiterentwicklungen in verschiedenen Domänen gesetzt. Die entwickelte Pipeline der Vereinzelung und anschließenden Erkennung kann auch in anderen Domänen verwendet werden. Beispielsweise beim Monitoring von Bauteilen in Industrieprozessen. Durch die modulare Struktur und Trainingsalgorithmen können die Verfahren schnell transferiert werden. Aber insbesondere für die Agrardomäne war das Projekt BoniKI ein erster Schritt, um gesammeltes Erfahrungswissen der Experten in neuronalen Netzen zu enkodieren, um somit großflächigere Bonituren vorzunehmen. So sind aus dem Projekt bereits Folgeideen und Beauftragungen entstanden, unter anderem zur Detektion von Wildschäden im Mais. Hierbei sollen die aus BoniKI entstandenen Systeme auf einen anderen Kontext abgewandt werden. Im geplanten Anschlussvorhaben BlühKI, soll das gesammelte Wissen und die Erfahrungen aus dem Projekt BoniKI verwendet werden und um LLM-basierte Methoden erweitert werden. So können die entwickelten Komponenten als eine Eingabe-Modalität für das Folgeprojekt gesehen werden.

Der Nutzen für die Wissenschaft liegt vor allem in der transparenten und detaillierten Dokumentation in Form von Fachtagungs- und Konferenzbeiträgen und dem aufgebauten Know-How der beteiligten Wissenschaftler. Alle Aspekte wurden für die wissenschaftliche Community dargestellt, um eine Reproduktion zu ermöglichen. Des Weiteren wurden studentische Abschlussarbeiten im Kontext

BoniKI fertiggestellt und ein Promotionsvorhaben unterstützt. BoniKI erfüllt dadurch auch seinen Zweck zur Ausbildung und Förderung neuer wissenschaftlicher Fachkräfte

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

Es wurden relevante Forschungsprojekte und Ausgründungen im Laufe des Vorhabens bekannt, die im Zusammenhang mit Teil-APs stehen, jedoch die Aspekte unter anderen Gesichtspunkten betrachten:

- <https://www.sumiagro.com/case/anya/>
Betrachtet vor allem Nutrition-Defizite der Pflanzen oder Krankheitsausbreitung. Dies sowohl auf UAV als auch Satelliten Fotos.
- <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 Uni 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.

Die Ergebnisse der bekannt gewordenen Forschungsprojekte wurden zur Projektlaufzeit analysiert und aufgearbeitet. Hierbei konnte jeweils eine klare Abgrenzung identifiziert werden.

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

Im Verfahren getätigte Veröffentlichungen wurden im gesamten Konsortium erarbeitet und dementsprechend mit über die Projektpartner 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
(GIL 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 zu der Bonitur mit dem MultiNet Ansatz geplant, dieses befindet sich aktuell in Arbeit und wird versucht zeitnah auf einer gängigen Robotik Konferenz eingereicht. 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. So wurde es 2022 auf der VDLUFA, sowie dem LTZ-Winterseminar vorgestellt. In 2023 wurde es zusätzlich mit einem Poster bei der GPW (Gesellschaft für Pflanzenwissenschaften) präsentiert. Beim FZI wurde das Projekt im Rahmen des Open House jährlich präsentiert. Zusätzlich dazu wurde BoniKI im Rahmen des Begleitforschungsprojektes X-KIT bei der Auftaktveranstaltung, sowie Abschlussveranstaltung und in der Landinfo präsentiert.