Sachbericht zum Projekt *KI-iREPro*

Zuwendungsempfänger

Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e.V.

Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung (IOSB)

Förderkennzeichen

28DK128C20

Vorhabenbezeichnung

Künstliche Intelligenz für innovative Ertragsprognose bei Reben (KI-iREPro) — Teilprojekt C

Laufzeit des Vorhabens

01.04.2021 bis 31.10.2024

Teil I: Kurze Darstellung

Ursprüngliche Aufgabenstellung

Das Ziel des Projektes KI-iREPro war die Entwicklung einer innovativen, KI-basierten Ertragsprognose für den Ertrag der Rebe. Die präzise Prognose soll das Qualitätsmanagement, durch Verbesserung der Menge-Güte Relation, sowie die Transportlogistik (Transportkapazität vom Weinberg zum Betrieb, Reduktion von Wartezeiten bei der Traubenanlieferung) und Kellerlogistik (Auslastung von Weinpressen- und Gärtankkapazitäten) im praktischen Weinbau verbessern. Darüber hinaus sollte durch eine KI-basierte Ertragsvorhersage die Effizienz und Objektivität in der Rebenzüchtung gesteigert werden. Durch die Vorselektion von Sämlingen im Züchtungsprozess anhand ihres Ertragspotentials soll die Gesamtanzahl an Sämling verringern die schlussendlich manuell durch den Züchter ausgewählt werden müssen.

Wissenschaftlicher und technischer Stand an den angeknüpft wurde

Der deutsche Weinbau ist durch kleinparzellige Strukturen und betriebliche Heterogenität geprägt, was den Einsatz digitaler Technologien erschwert. Während Ertragsschätzungen oft manuell und fehleranfällig sind (Price and Lombard 1988; Wolfe 2006), bieten KI-gestützte Ansätze wie Deep-Learning-Modelle (Rose et al. 2016; Zabawa et al. 2019) neue Möglichkeiten, die Genauigkeit und den Zeitpunkt der Prognose zu verbessern.

Edge-Computing reduziert Datenvolumen und erhöht die Geschwindigkeit der Bildanalyse (Shi et al. 2016). Algorithmen wie M5 Prime wurden speziell für landwirtschaftliche Anwendungen und die Ertragsprognose entwickelt, um eine höhere Prognosegenauigkeit zu ermöglichen (González-Sanchez et al. 2014; Bóbeda et al. 2018).

Aktuelle Verfahren sind jedoch oft auf etablierte Rebsorten wie Riesling oder Sangiovese beschränkt (Rose et al. 2016; Di Gennaro et al. 2019), sodass pilzwiderstandsfähige Sorten (PIWIs) eine besondere Herausforderung darstellen. Eine Übertragung auf diese Sorten sowie die Integration von Sensordaten aus frühen Vegetationsstadien könnten die Praxistauglichkeit und Akzeptanz digitaler Technologien im Weinbau steigern (Sirsat et al. 2019).

Für große Betriebe und Genossenschaften bieten zudem Online-Ertragserfassungen während der Lese Potenzial für eine effizientere Planung und Logistik (Blom und Tarara 2009).

Ablauf des Vorhabens

1) Entwicklung neuartiger, innovativer Ertragsprognosemodelle basierend auf historischen Ertrags-, Klima-, Boden- und Prozess-Daten mithilfe von Methoden des Maschinellem Lernens (Teilbereich der Künstlichen Intelligenz).
2) Erweitern der Ertragsprognose durch den Einsatz einer kameragestützen Phänotypisierungsplattform und Verbesserung der Ertragsprognose durch die daraus gewonnenen, sensorbasierten Daten zur Merkmalsausprägung.
3) Die Erfassung und Auswertung von Ertragsrelevanten Merkmalen wurde darüber hinaus im Prozess der Rebenzüchtung zur Vorselektion von Züchtungsmaterial anhand des Ertragspotentials genutzt mit dem Ziel die Entscheidungsfindung in der Züchtung effizienter und objektiver zu gestallten.

Wesentliche Ergebnisse

Durch die umfassende Datenanalyse in Zusammenarbeit von P1, P2, P3 und P5 konnten wir herausarbeiten, wie ideale Datenerfassung zur späteren Ertragsprognose im Weinbau mittels KI aussehen muss, um bestmögliche Ergebnisse zu erzielen. Die Punkte enthalten dabei:

- Eine flurstückgenaue Erfassung der Erträge um Ursache und Wirkung der klimatischen Bedingungen an verschiedenen Flurstücken auf ihren Ertrag tatsächlich erfassen zu können.
- Weiterhin müssen Prozessmanagementdaten flächendeckend erhoben werden, um ertragsändernde Eingriffe zu erkennen und zu modellieren.
- Letztlich muss die Ertragsregulierung beachtet werden. Es müssen die tatsächlichen Erträge erfasst und dokumentiert werden, bevor aus Gründen der Ertragsregulierung Flächen undokumentiert nur teilweise geerntet werden.

Trotz der oben angeführten Probleme wurde ein Prototyp-System zur Ertragsprognose auf Flächenbasis erstellen. Das System KI-iREProWinemaker ist eine KI-Applikation zur Ertragsprognose, die automatisiert eine Prognose auf Basis von klimatischen Faktoren, Lageinformationen und historischen Ertragsdaten liefert. Bei Eingabe eines Winzers und einer Sorte prädiziert KI-iREProWinemaker den erwarteten Ertrag für das angefragte Jahr.

Neben der Ertragsprognose auf Flächenbasis wurde ein zweites Prototyp-System KI-iREProBreeding entwickelt, um die Ertragsprognose auf Einzelstockbasisbasis zu erstellen. KI-iREProBreeding ist eine Applikation, die in der Züchtung Einsatz finden wird. Auf Basis von phänotypischen Merkmalen wird eine rebstockgenaue Ertragsprognose ausgegeben. KI-iREProBreeding erlaubt durch den Schnittstellenentwurf das Fortschreiben der Modelle durch die Experten des JKI und allgemein im Weinbau. Mit der vom Fraunhofer IOSB

entwickelten sensorgestützten und mobilen Phänotypisierungsplattform auf der Basis des Trägersystems PHENOquad und dem Auswertesystem PHENOboxx erfolgt die Integration und Erweiterung von KI-iREProBreeding als Prognosesoftware um die sensorgestützten Phänotypisierungsdaten über den vom Fraunhofer IOSB entwickelten Vineyard-Viewer zum sensorgestützten Ertragsprognosesystem KI-iREProExt.

Teil II: Eingehende Darstellung

Durchgeführte Arbeiten

Arbeitspaket 2: Entwicklung der PHENOboxx

Ziel dieses Arbeitspakets war es ein Embedded-Vision-System (PHENOboxx) für eine bodengestützte Feldphänotypisierung im Weinberg zu entwickeln. Damit sollten automatisiert phänotypische Parameter mit Ertragsrelevanz erfasst werden, die als Eingabe für das erweiterte Ertragsprognosemodell KI-iREProExt in AP 3 dienen und in AP 4 zur Übertragbarkeit auf unbekannte, neue Sorten geprüft werden. Alle wesentlichen Punkte und Meilensteine konnten in diesem Arbeitspaket erreicht werden. Die multi-sensorische PHENOboxx wurde zunächst erfolgreich für die Datenakquise im Feld eingesetzt (Meilenstein 8). Nachdem einige Daten aufgenommen und annotiert wurden, konnten KI-Modelle gebaut werden, mit denen ertragsrelevante Merkmale aus den Bildern automatisiert bestimmt werden können. Zunächst offline (Meilenstein 9) und später auch in Echtzeit (Meilenstein 10), wobei die Bildauswertung nach Aufnahme einer Reihe gesammelt für die ganze Reihe im VineyardViewer erfolgt und die benötigten Informationen rechtzeitig für den Winzer zur Verfügung stehen. Diese Echtzeitanforderung ist für die hier beschriebene Anwendung mehr als ausreichend und so können die geeigneten und relevanten Bilder zu jedem Rebstock anhand der GPS-Position und des sichtbaren Bildausschnittes optimal ausgewählt werden. Der dafür vom IOSB entwickelte VineyardViewer ist ein Software-Tool, das die GPS-Georeferenzierung der Bilder, die Bildauswertung und die Extraktion der phänotypischen Merkmale für die gewünschten Rebstöcke zusammenführt und somit eine nutzerfreundliche Auswertung der Daten ermöglicht. Des Weiteren war auch die Übertragung der automatisierten Merkmalsextraktion aus Bildern auf neue Rebsorten erfolgreich (Meilenstein 11). Nachfolgend werden die einzelnen durchgeführten Arbeiten im Detail beschrieben.

Datenerhebung

Um die objektive und sensorgestützte Merkmalserfassung im Hochdurchsatz zu ermöglichen, wurde das Multi-Sensorsystem PHENOboxx entwickelt. Diese wurde im ersten Versuchsjahr 2021 in Front des PHENOliners montiert. Ab der Saison 2022 bis zum Ende der Projektlaufzeit erfolgte die Datenaufnahme mit dem PHENOquad. Es wurde sich dabei bewusst für ein Quad entschieden, da es in der Größe einem Weinbergschlepper ähnelt und mit ihm die Datenaufnahme von 4-6 km/h möglich ist, diese Arbeitsgeschwindigkeit entspricht den fachlichen Bewirtschaftungsschritten im Weinberg durch die Winzer. Darüber hinaus zeichnet sich das PHENOquad durch seine hohe Mobilität aus und kann mittels eines Anhängers auch über große Strecken transportiert werden.

Abbildung 1: PHENOquad mit der aufgebauten PHENOboxx bei der Aufnahme der Trauben zum Wachstumsstadium BBCH75 am Geilweilerhof.

Die Datenaufnahme im Projekt KI-iREPro erfolgte in der Regel mit 4 km/h hierbei wurden zwischen 6 und 10 Bildern pro Sekunde aufgenommen, was ungefähr einem Bild pro 11 cm Wegstrecke entspricht. Für die Datenakquise wurden vier Ortstypische Sorten, für das Weinbaugebiet Pfalz, ausgewählt. Hierbei handelt es sich um die Rebsorten Dornfelder, Riesling sowie Weiß- und Spätburgunder die alle als Versuchsreihen am Geilweilerhof verfügbar sind. Das Vorhandensein von jeweils 2 weißen und 2 roten Sorten sowie der unterschiedlichen Sortentypischen Ausprägungen von phänotypischen Merkmalen im Feld ermöglicht hierbei die Bild- und Referenzdatenerfassung eines variablen Datensatzes. Insgesamt wurde in den verschiedenen Arbeitspaketen eine Datenmenge von 20,6 TB durch die PHENOboxx erfasst, dies entspricht ca. 560.000 Bilder aufgenommen über die gesamte Projektlaufzeit.

Im ersten Versuchsjahr erfolgte die Datenaufnahme an 10 Zeitpunkten im Vegetationsverlauf. Hierbei wurden 8 verschiedene Entwicklungsstadien (BBCH 10, 57, 71, 73, 75, 81, 89 sowie zur dormanten Winterruhe) abgedeckt. Als Referenzdaten wurden dabei jeweils Ertragsrelevante Merkmale wie die Anzahl der Austriebe, Triebe, Geschein tragende Triebe, Gescheine, Trauben, Ertrag und das Schnittholzgewicht auf Einzelstockbasis erfasst. Mit dem Ertrag und dem Schnittholzgewicht wurde der sogenannte Ravaz-Index (Verhältnis Stockertrag und

Abbildung 2: Detailansicht der PHENOboxx bei der Datenaufnahme im Feld.

Winterschnittholzgewicht) ermittelt, um die Wüchsigkeit und das Verhältnis zwischen generativem und vegetativem Wachstum innerhalt der Vegetationsperiode bewerten zu können. In den folgenden Versuchsjahren wurde sich bei der Datenerfassung auf die Entwicklungsstadien und quantifizierbaren Merkmale aus Tabelle 1 fokussiert. Dieser Schritt erfolgte in erster Linie da absehbar wurde das nicht für alle erfassten Entwicklungsstadien aus dem Versuchsjahr 2021 eine ausreichende Anzahl an Trainigsdaten annotiert werden können. Aus diesem Grund wurde sich im Verbund dazu entschieden, keine weiteren Daten mehr zur Anzahl die Gescheine vor der Blüte zu erfassen. Darüber hinaus zeigte sich das die Datenerfassung zwischen BBCH71-75 und die Unterscheidung der einzelnen Entwicklungsstadien in der Praxis sich als schwierig erwies da die Stadien fließend ineinander übergehen und sich nicht zwangsläufig alle Stöcke einer Sorte zeitgleich im identischen Stadium befinden. Die Datenaufnahme erfolgte in den Jahren 2022, 2023 und 2024 zu je zwei Zeitpunkten zwischen BBCH71-75.

Tabelle 1: Für Ertragspotentialmonitoring relevante Zeitpunkte mit den quantifizierten Merkmalen auf Einzelstockbasis die hierfür erfasst wurden.

Zeitpunkt			**Merkmale auf Einzelstockbasis**
Monat	**Entwicklungsstadium**	**BBCH**	
Mai	Austrieb	10	Austriebe
Juni	Beerenansatz	71	Trauben & Beeren
Juni	Erbsengröße	75	Trauben & Beeren
Sept. – Okt.	Lese	89	Trauben, Beeren & Ertrag
Februar	Winter Dormanz	99	Schnittholzgewicht

Bildauswertung

Um die erhobenen Bilddaten mittels der KI auswerten zu können musste ein Teil der Bilddaten annotiert werden, um sie für das Training der KI nutzen zu können. Hierfür wurden zuerst Bilder ausgewählt, auf denen die aufgenommenen Reben möglichst vollständig zu sehen sind. Die Auswahl erfolgte hierbei durch P3. Die ersten Bilddatensets wurden dabei 2021 mit einem vom IOSB eigenständig programmierten Labeling-Software annotiert. Für die folgenden Jahre der Projektlaufzeit erfolgte der Wechsel auf eine leistungsstärkerer und kommerzielle Annotationssoftware Darwin V7 in der anschließend ausschließlich mit dem PHENOquad erfasste Daten annotiert wurden. Ziel war es hierbei eine ausreichende Anzahl annotierter Trainingsdaten für die Modellierung zu erhalten. Der Annotationsfokus wurde dabei ab 2023 auf 20 Bildern pro Entwicklungsstadium und die zu diesen Zeitpunkten relevanten Parameter gelegt. Hierfür wurden 20 Stöcke aus dem Datenset von 2022 ausgewählt von denen für jeden der ausgewählten Entwicklungsstadien georeferenzierte Bilddaten verfügbar waren. In der nachfolgenden Tabelle 2 ist die Anzahl der annotierten Bilder dargestellt.

Tabelle 2: Anzahl der Annotierten Bilder mit den gelabelten Parametern für die ausgewählten Wachstumsstadien

Wachstumsstadium	Parameter	Anzahl annotierter Bilder
Austrieb	Anzahl der Triebe	38
Beerenansaatz bis Erbsengröße	Traubenfläche	126
	Anzahl der Beeren	116
Lese	Traubenfläche	156
	Anzahl der Beeren	80
Dormante Winterruhe	Fläche dormantes Winterholz	216

KI-Bildauswertung

Mit den aufgenommenen Daten konnten KI-Modelle zur automatisierten Bestimmung von ertragsrelevanten Merkmalen trainiert werden. Nachfolgend werden für alle ertragsrelevanten Merkmale jeweils das Vorgehen und das Ergebnis der automatisierten KI-Bildauswertung beschrieben.

Anzahl der Austriebe

Für die Anzahl der Austriebe wurde ein Object Detection Modell (Faster-RCNN) trainiert. Als Trainingsdaten wurden 20 annotierte Bilder vom Mai 2022 und 18 annotierte Bilder vom Mai 2023 verwendet. Die 38 Bilder wurden zu 80%/10%/10% in Training/Validierung/Test aufgeteilt. Die Ergebnisse des Test-Set sind in Tabelle 3 dargestellt. In Abbildung 3 sind die vom Modell vorhergesagten Bounding-Boxen der Austriebe dargestellt (rechts), sowie die Ground-Truth Annotationen der Austriebe (links). Das Modell wurde für eine weitere Evaluierung im Vergleich zu den Boniturdaten auf 54 Bildern von ausgewählten Stöcken aus dem Mai 2023 inferiert.

Tabelle 3: Ergebnisse der Austrieb-Detektion auf dem Test -Set.

	mAP50 (%)	F1 (%)
Anzahl Austriebe	52,2+-4,0	71,2+-1,2

Abbildung 3: Ergebnis der Austrieb-Detektion für ein Beispielbild. Ground Truth (links) und Prediction (rechts).

Traubenfläche

Für die Bestimmung der Traubenfläche wurde ein semantisches Segmentierungsmodell (LinkNet) trainiert. Als Trainingsdaten wurden die 126 Bilder vom Juni 2022 (Erbsengröße) und 156 Bilder vom September 2022 (Lese) verwendet. Die 282 Bilder wurden zu 80%/10%/10% in Training/Validierung/Test aufgeteilt. Die Ergebnisse des Test-Set sind in Tabelle 4 dargestellt, dort sind der F1-Score und der IoU (Intersection over Union) für die vorhergesagten Trauben-Pixel aufgeführt. In Abbildung 4 sind die vom Modell vorhergesagten Traubenpixel dargestellt (rechts), sowie die Ground-Truth Annotationen der Trauben (links). Das Modell wurde für eine weitere Evaluierung im Vergleich zu den Boniturdaten auf Bildern von 54 ausgewählten Stöcken aus dem Juli 2023 (Erbsengröße) und September 2023 (Lese) inferiert.

Tabelle 4: Ergebnisse der semantischen Segmentierung der Traubenfläche auf dem Test-Set.

	F1 (%)	**IoU (%)**
Traubenfläche	91,2+-1,0	82,4+-1,7

Abbildung 4: Ergebnis der Traubenflächen-Bestimmung für ein Beispielbild. Ground Truth (links) und Prediction (rechts).

Anzahl der Beeren

Für die Bestimmung der Anzahl der Beeren wurde ein semantisches Segmentierungsmodell (LinkNet) trainiert. Als Trainingsdaten wurden die 118 Bilder vom Juli 2021 (Erbsengröße), 20 Bilder vom September 2022 (Lese), 19 Bilder vom September 2023 (Lese) und 20 Bilder vom Juni 2022 (Erbsengröße) verwendet. Ein ausgewähltes Subset dieser Daten, bestehend aus 16 Bildern, wurde als Test-Set verwendet. Die Ergebnisse des Test-Set sind in Tabelle 5 dargestellt, dort sind der F1-Score und der IoU (Intersection over Union) für die vorhergesagten Beeren-Pixel aufgeführt. Diese Ergebnisse beziehen sich nur auf die Pixelfläche, nicht auf die korrekte Anzahl bzw. Mittelpunkte der Beeren, die Evaluierung der Ergebnisse in Hinblick auf die Bestimmung der korrekten Anzahl der Beeren dauert zum Zeitpunkt der Erstellung dieses Berichts noch an und wird zeitnah im Rahmen einer geplanten Publikation veröffentlicht. In Abbildung 5 sind die vom Modell vorhergesagten Beerenmittelpunkte dargestellt (rechts), sowie die Ground-Truth Annotationen der Trauben (links). Das Modell wurde für eine weitere Evaluierung im Vergleich zu den Boniturdaten auf Bildern von 54 ausgewählten Stöcken aus dem Juli 2023 (Erbsengröße) und September 2023 (Lese) inferiert.

Tabelle 5: Ergebnisse der semantischen Segmentierung der Beerenmittelpunkt-Bestimmung auf dem Test-Set.

	F1 (%)	**IoU (%)**
Beeren-Pixelfläche	43,7+-3,0	28,0+-2,5

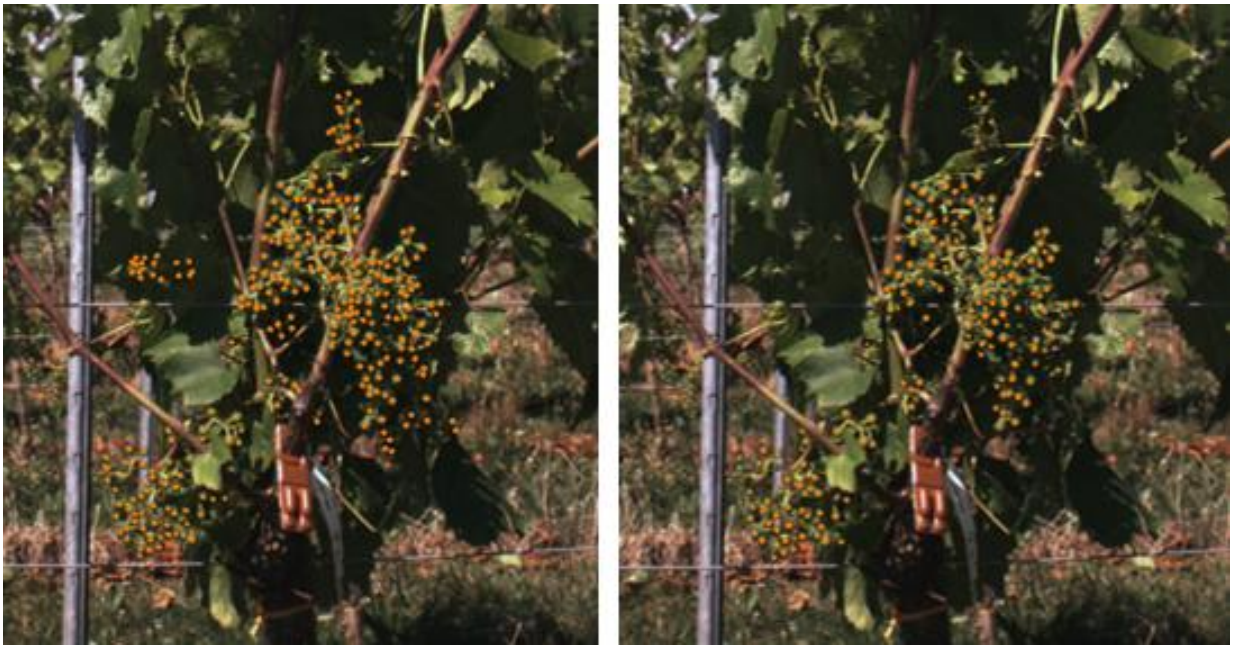

Abbildung 5: Ergebnis der Beerenmittelunkt-Bestimmung für ein Beispielbild. Ground Truth (links) und Prediction (rechts).

Fläche dormantes Winterholz

Für die Bestimmung der Fläche des dormanten Winterholz wurde ein semantisches Segmentierungsmodell (LinkNet) trainiert. Als Trainings- und Validierungsdaten wurden die 218 Bilder vom Februar 2022 verwendet. Als Test-Daten wurden 20 Bilder vom Dezember 2022 verwendet. Die Ergebnisse des Test-Set sind in Tabelle 6 dargestellt, dort sind der F1-Score und der IoU (Intersection over Union) für die vorhergesagten Winterholz-Pixel aufgeführt. In Abbildung 6 sind die vom Modell vorhergesagten Traubenpixel dargestellt (rechts), sowie die Ground-Truth Annotationen der Trauben (links). Das Modell wurde für eine weitere Evaluierung im Vergleich zu den Boniturdaten auf Bildern von 54 ausgewählten Stöcken aus dem Januar 2024 und auf 20 Bildern vom Dezember 2023 inferiert.

Tabelle 6: Ergebnisse der semantischen Segmentierung der Winterholz-Fläche auf dem Test-Set.

	F1 (%)	**IoU (%)**
Bogen-Fläche	77,8+-3,0	63,7+-3,9
Trieb-Fläche	80,1+-1,4	68,0+-2,0

Abbildung 6: Ergebnis der Winterholzflächen-Bestimmung für ein Beispielbild. Ground Truth (links) und Prediction (rechts). Triebe (grün), Bogen (rot), Stamm (orange).

Laubwandfläche

Weiterhin wurde ein semantisches Segmentierungs-Modell zur Bestimmung der Blattfläche trainiert. Hierfür wurden 161 Bilder mit annotierter Laubwand verwendet und zu 80%/10%/10% in Training/Validierung/Test aufgeteilt. Die Vorhersage der Blattfläche funktioniert sehr gut mit F1-Werten von 92,2%+-0.,5%.

Chlorophyll-Auswertung

Neben Referenzdaten zur Phänologie der Versuchsstöcke wurden Chlorophyllmessungen im Versuchsjahr 2024 an 12 ausgewählten Stöcken zum Zeitpunkt BBCH75 - 80 durchgeführt, um deren Vitalität beurteilen zu können. Pro Stock wurden 6 Blätter ausgewählt, die sich in ihrem Alter unterschieden (jung, mittelalt und alt). Die Messung des Chlorophyllgehalts wurde mit dem Sensor MPM-100 von Opti-Sciences direkt an der Pflanze durchgeführt. Die Messreihe wurde am selben Tag zu zwei unterschiedlichen Zeitpunkten (zwischen 10-11 Uhr und 15-16 Uhr) an den jeweils selben Blättern durchgeführt, sodass insgesamt 144 Referenzwerte vorlagen. Die Pflanze wurde nach der Messung mit dem PHENOquad nach beiden Zeitpunkten messtechnisch erfasst. Vor den Zeitpunkten wurde ein Bild eines Referenzstandards aufgezeichnet, um die Charakteristik der Kamera bei der Auswertung zu beseitigen. Die Farbwerte der ausgewählten Blätter wurden in ihrer Fläche gemittelt, sodass zu jedem Blatt zunächst fünf Werte vorlagen. Eine PLS-Regression auf diese fünf Kanäle angewandt ergab einen RMSE der Vorhersage von 0,122. Aus diesen fünf Kanälen wurden in der Literatur gängige Indizes gebildet, sodass das Bild künstlich auf 24 Kanäle erweitert wurde, welche einen RMSE der Vorhersage von 0,120 lieferte. Durch Betrachtung der Koeffizienten des 24-kanäligen Modells wurden sechs Kanäle identifiziert, die den größten Einfluss auf die Vorhersage haben. Mit diesen sechs Kanälen wurde ein finales Modell erstellt, welches einen RMSE von

0,110 hat. Die sechs Kanäle waren der reine blaue Kanal, NDI, relative Intensität von Blau, Rot / Blau, NIR1 / NIR2 und (NIR1 – NIR2) / (NIR1 – Rot). In der nachfolgenden Abbildung 7 sind die Ergebnisse der Chlorophyllmessung dargestellt.

Übertragung auf neue Rebsorten

Die Modelle zur Extraktion phänotypischer Merkmale konnten auch auf neue Rebsorten übertragen werden. In den annotierten Daten wurden verschiedene Rebsorten berücksichtigt, die für das Modelltraining hinzugezogen oder weggelassen werden konnten. Dank der Projektverlängerung konnten hierfür nochmals gezielt weitere Daten aufgenommen werden. Solange die Rebsorten optisch nicht zu unterschiedlich sind, war eine Übertragung mit geringen Genauigkeitsunterschieden möglich. Wenn dies nicht gegeben war konnte durch Nachtrainieren und Nachjustieren der Modelle mit weiteren Daten eine Verbesserung erzielt werden. Eine ausführliche Evaluation dieser Ergebnisse ist zum Zeitpunkt der Berichterstellung noch in Arbeit und wird zeitnah im Rahmen einer Veröffentlichung noch publiziert werden.

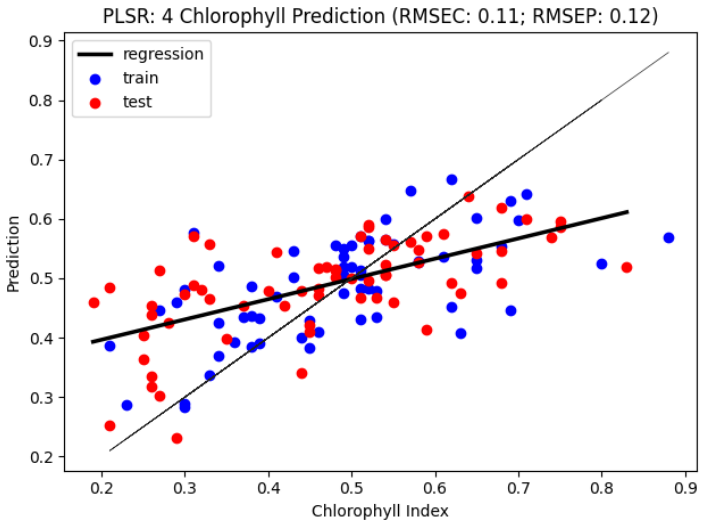

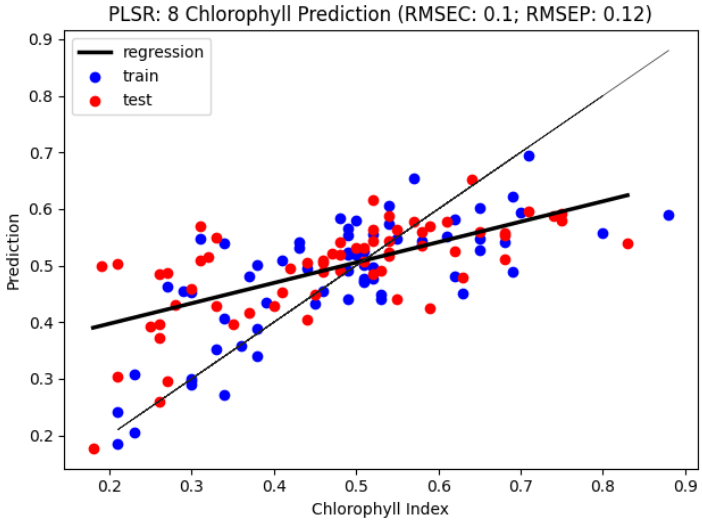

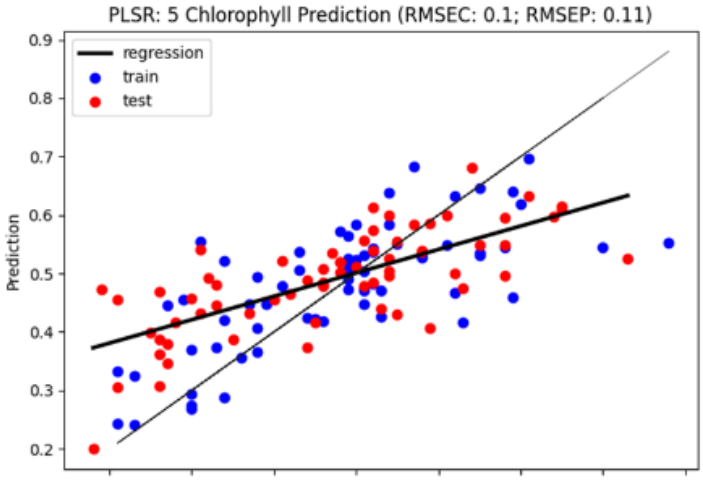

Abbildung 7: Ergebnisse der Validierung der Chlorophyllmessung. Modell mit den fünf Farbkanälen der Kamera, Modell mit 19 weiteren in der Literatur gängigen Indizes und Modell mit den 6 am stärksten gewichteten Kanälen aus dem zweiten Modell (v.l.n.r.)

VineyardViewer

Das Fraunhofer IOSB entwickelte im Rahmen des Projektes den sogenannten „VineyardViewer“. Dabei handelt es sich um ein Tool, das die GPS-Georeferenzierung der Bilder, die Bildauswertung und die Extraktion der phänotypischen Merkmale für die gewünschten Rebstöcke zusammenführt und somit eine nutzerfreundliche Auswertung der Daten ermöglicht. Er ermöglicht die Betrachtung und Verwaltung der Bilddaten. Er erlaubt es, gezielt auf bestimmte Parzellen/Reihen/Reb-stöcke zuzugreifen und Reports der phänotypischen Merkmale dieser Stöcke zu generieren. Die neu aufgenommenen Bilddaten können dafür einfach hochgeladen werden. Der VineyardViewer führt dann eine Georeferenzierung durch, um den einzelnen vermessenen und im VineyardViewer hinterlegten Rebstöcken die passenden aufgenommenen Bilder zuzuordnen. Dann wird für die gewünschten Rebstöcke die KI-Bildauswertung durchgeführt und es können ertragsrelevante Merkmale für jeden Rebstock angezeigt und auch exportiert werden, um diese für die Ertragsbestimmung von AP 3 KI-iREProExt zu verwenden. Es wurden einheitliche Datenschnittstellen mit der Uni Bonn (P2) abgestimmt, um die Daten problemlos übertragen zu können. In der nachfolgenden Abbildung 8 ist ein Screenshot des VineyardViewer dargestellt.

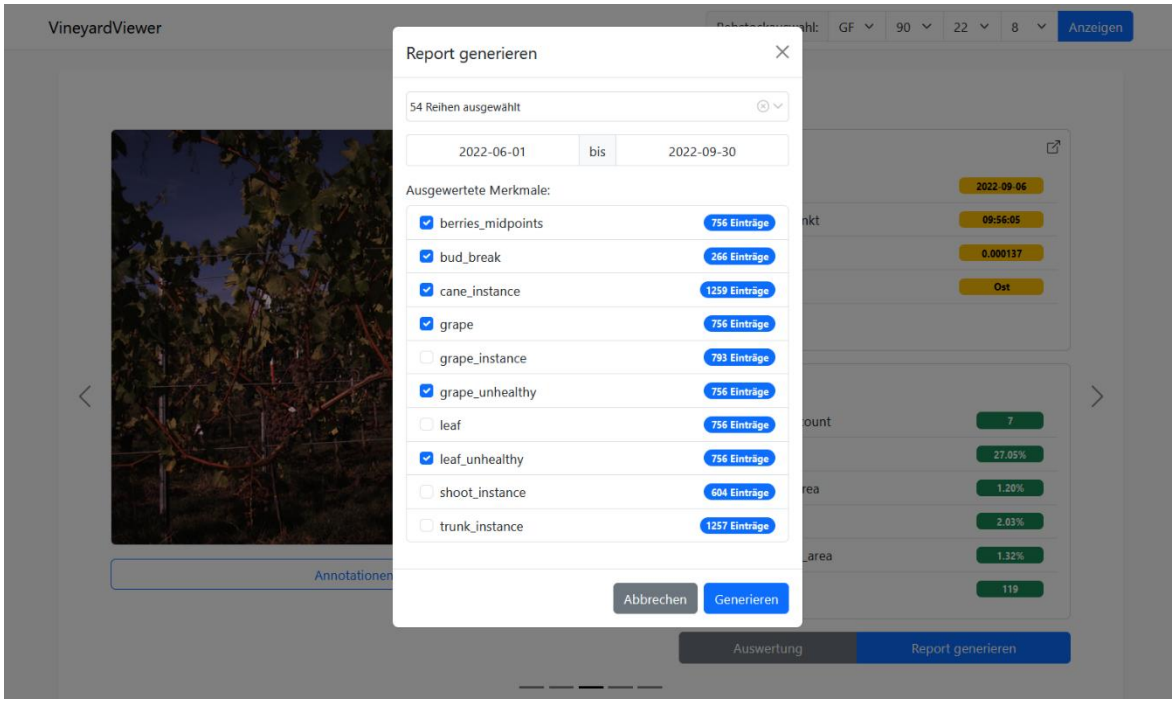

Abbildung 8: Benutzeroberfläche des VineyardViewer: Erstellung eines Reports mit ertragsrelevaten Merkmalen für ausgewählte Stöcke zu einem ausgewählten Zeitraum.

Arbeitspaket 3: Entwicklung KI-iREProExt

Im Rahmen des AP 3 führte das IOSB mehrere unterstützende Aufgaben durch. Es fanden regelmäßige Abstimmungen mit der Universität Bonn statt, um Schnittstellen für die Integration von Sensordaten aus AP 2 zu definieren und zu entwickeln. Zudem wurden repräsentative Rebstöcke ausgewählt und analysiert, um Zeitreihendaten für die Validierung der Prädiktionsmodelle zu sammeln. Auf Basis der Bild- und Sensordaten wurden KI-gestützte Modelle zur Ertragsprognose entwickelt und anhand manuell annotierter Ground-Truth-Daten validiert. Eine bewilligte Projektverlängerung ermöglichte die Erhebung zusätzlicher Daten über eine weitere Vegetationsperiode, um die Robustheit und Praxistauglichkeit der KI-Modelle zu verbessern.

Arbeitspaket 5: Wissenstransfer

Im Rahmen des Arbeitspakets hat das IOSB zur Verbreitung der Projektergebnisse beigetragen. In Zusammenarbeit mit Partner P1 unterstützte das IOSB die Vorbereitung von Informationsveranstaltungen für Winzer durch Bereitstellung von Fachwissen und organisatorische Hilfe. Zudem führte das IOSB Demonstrationen der PHENOboxx und des PhenoQuads durch, um Film- und Fotomaterial für Social Media, Flyer und Poster zu erstellen. Ein weiterer Beitrag war eine Gastvorlesung mit Übung zum Thema "Computer Vision im Präzisionsweinbau" am Weincampus Neustadt, bei der das IOSB den Studierenden die Anwendung moderner Bildverarbeitungstechniken im Weinbau erklärte.

Verwendung der Zuwendung

Die wichtigsten Positionen des zahlenmäßigen Nachweises

Die wichtigsten Positionen des zahlenmäßigen Nachweises sind der Schlussrechnung zu entnehmen.

Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten

Die im Projekt KI-iREPro durchgeführten Arbeiten waren sowohl notwendig als auch angemessen, um die gesteckten Ziele erfolgreich zu erreichen. Die präzise und objektive Erfassung phänotypischer Merkmale ist für die Ertragsprognose im Weinbau unerlässlich und stellt eine zentrale Datenquelle dar. Aufgrund des Fehlens geeigneter kommerzieller Bildverarbeitungslösungen war es erforderlich, eine eigene Lösung zu entwickeln. Insbesondere der Einsatz von Multispektralkameras (MSI-Kameras) stellt hierbei eine innovative Methode dar. Das Fraunhofer IOSB hat hierfür die PHENOboxx entwickelt, ein bodengestütztes Embedded-Vision-System zur Feldphänotypisierung im Weinberg. Dieses Multi-Sensor-System kombiniert eine Multispektralkamera zur Bildaufnahme mit einem 3D-Sensor zur Tiefenerfassung. Durch die Fusion dieser Daten können ertragsrelevante Merkmale der Reben, wie beispielsweise die Anzahl der Trauben oder der Gesundheitszustand der Pflanzen, präzise und in Echtzeit erfasst werden. Diese detaillierten Informationen sind für die Erstellung genauer Ertragsprognosen unerlässlich. Die vom IOSB entwickelten Technologien und Methoden ermöglichen es, aktuelle, ortsbezogene Messdaten direkt im Weinberg zu erfassen und in die Ertragsprognosemodelle zu integrieren. Dies führt zu einer Verbesserung der Prognosegenauigkeit und unterstützt Winzer bei der Planung und Optimierung ihrer Produktionsprozesse.

Voraussichtlicher Nutzen und Verwertbarkeit des Ergebnisses

Die im Projekt KI-iREPro entwickelten Technologien und Methoden bieten verschiedene Anwendungsmöglichkeiten und wirtschaftliche Potenziale. Die vom IOSB entwickelte PHENOboxx, ein Multi-Sensor-System, ermöglicht die präzise Erfassung ertragsrelevanter Merkmale direkt im Weinberg. Diese Technologie kann nicht nur im Weinbau, sondern auch in anderen Sonderkulturen wie dem Apfelanbau eingesetzt werden, indem die Bildauswertungsverfahren durch Transfer-Learning an spezifische Anforderungen angepasst werden. Zudem eröffnet die PHENOboxx Perspektiven im Markt der Agrarrobotik. Als vielseitig einsetzbare Multi-Sensorkomponente kann sie in verschiedenen Roboterplattformen integriert werden, um automatisierte Monitoring- und Analyseaufgaben in der Präzisionslandwirtschaft zu unterstützen.

Die im Projekt entwickelten Verfahren zur Ertragsprognose und die zugrunde liegenden maschinellen Lernmodelle lassen sich durch Nachtrainieren mit spezifischen Datensätzen erweitern. So können Anwendungen zur Früherkennung von Pflanzenkrankheiten oder zur

Beurteilung von Nährstoffmängeln realisiert werden, was zu einer verbesserten Ressourcennutzung und gesteigerter Effizienz in der Landwirtschaft beitragen könnte.

Die Projektergebnisse sollen über wissenschaftliche Publikationen und Beiträge auf nationalen und internationalen Tagungen verbreitet werden. Zudem ist geplant, die Entwicklungen auf Fachmessen wie der Intervitis oder Agritechnica sowie bei Feldtagen der Weinbaupraxis vorzustellen, um den Wissenstransfer in die Praxis zu fördern. Durch die Zusammenarbeit mit Wirtschaftsbetrieben im Bereich Sonderkulturen wird angestrebt, praxistaugliche Produktentwicklungen voranzutreiben. Dies umfasst Softwarelösungen für Entscheidungshilfen oder Qualitätssensoren, die auf Basis der im Projekt entwickelten Technologien und Methoden basieren.

Bekannter Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen

Aufgrund der schnellen Fortschritte im Bereich der Künstliche Intelligenz forschen verschiedene Gruppen an den Einsatzmöglichkeiten für die Ertragsprognose. Während des Projektzeitraums sind folgende Publikationen erschienen:

- Olenskyj et al. (2022) vergleichen drei Deep-Learning-Ansätze (Objekterkennung, CNN-Regression und Transformer-Modelle) zur Schätzung des Traubenertrags aus bodennahen Kamerabildern in einem kommerziellen Weinberg.
- Rahim et al. (2022) entwickeln einen Deep Learning-basierten Ansatz zur automatischen Zählung von Blüten in Weinreben durch ein zweistufiges Verfahren: Zunächst werden Blütenstände mittels Mask R-CNN segmentiert, anschließend einzelne Blüten innerhalb dieser Bereiche detektiert und gezählt.
- López-García et al. (2022) entwickeln eine Methodik zur Weinertragsprognose durch die Kombination von UAV-Luftbildern (RGB und multispektral) mit traditionellen Ertragsmessungen wie Traubenanzahl und Beerengewicht in frühen Wachstumsstadien.

Diese Arbeiten stützen im Wesentlichen die Arbeitshypothese des Projekts und belegen die Vorteile KI-gestützter Bildauswertung für die Ertragsprognose. Im Unterschied zum vorliegenden Projekt liegen die Schwerpunkte dieser Arbeiten in Machbarkeitsuntersuchungen und weniger in der Entwicklung einer praxistauglichen Bildverarbeitungslösung.

Erfolgte oder geplante Veröffentlichungen des Ergebnisses

- Huber, F., Hofmann, B., **Engler, H**., **Gauweiler, P., Fischer, B**., Herzog, K., Kicherer, A., Töpfer, R., **Gruna, R**., & Steinhage, V. (2024). A Concept Study for Feature Extraction and Modeling for Grapevine Yield Prediction. VITIS - Journal of Grapevine Research, 63, 7. https://doi.org/10.5073/vitis.2024.63.03

- **Engler, H**., **Gauweiler, P**., Huber, F., **Krause, J., Fischer, B., Hoffmann, B., Schumacher, P**., Yushchenko, A., **Gruna, R**., Steinhage, V., Herzog, K., Töpfer, R., & Kicherer, A. (2023). PHENOquad: A new multi sensor platform for field phenotyping and screening of yield relevant characteristics within grapevine breeding research. VITIS Journal of Grapevine Research, 62(5), 41–48. https://doi.org/10.5073/vitis.2023.62.special-issue.41-48

Weitere Veröffentlichungen sind geplant:

- X. Zheng, Engler H., **B. Fischer**, B.Hoffmann, P. Gauweiler, R. Gruna, O. Trapp, A. Kicherer (2025) Image-based yield estimation for the pre-selection of new grapevine genotypes in grapevine breeding research. In preparation
- X. Zheng, Engler H., **B. Fischer**, B.Hoffmann, P. Gauweiler, R. Gruna, O. Trapp, A. Kicherer (2025) Proof of concept: Digital Phenotyping in Grapevine Breeding. In preparation