

# Bewertung des Phänotyps in der landwirtschaftlichen Züchtungsforschung anhand der photogrammetrisch bestimmten Wuchshöhe und spektraler Indizes am Beispiel verschiedener Genotypen der Gerste

PAUL HERZIG<sup>1</sup>, UWE KNAUER<sup>2</sup>, PETER BORRMANN<sup>1</sup>, DAVID KILIAS<sup>2</sup>,  
HANS-CHRISTIAN KLÜCK<sup>2</sup>, UDO SEIFFERT<sup>2</sup>, KLAUS PILLEN<sup>1</sup> & ANDREAS MAURER<sup>1</sup>

*Zusammenfassung: Durch den Fortschritt auf dem Gebiet der Pflanzengenomik hat sich die Phänotypisierung von Pflanzen im Freiland zu einem neuen Engpass in der Pflanzenzüchtung entwickelt. Es besteht ein steigender Bedarf an objektiver, präziser und zeitlich hochaufgelöster Charakterisierung eines sich entwickelnden Pflanzenbestandes. Die zerstörungsfreie und sensorgestützte Hochdurchsatz Phänotypisierung mittels Drohnen hat das Potential diese Lücke zu bedienen. In dieser Studie wird die Eignung zweier Sensorsysteme (Rot-Grün-Blau (RGB) Kamera und Multispektralkamera) unter der Verwendung unterschiedlicher Modellansätze zur Ertragsvorhersage einer Gerstenpopulation geprüft. Die an unbemannten Luftfahrzeugsystemen (UAVs) montierte Sensorik wurde wöchentlich zur Datenerfassung an 3 Standorten in Mitteldeutschland genutzt. Zusätzlich zu Vegetationsindizes wurden auch morphologische Merkmale wie Bestandshöhe, Bedeckungsgrad und Parameter der Wachstumsdynamik für die Ertragsvorhersage verwendet und mit Referenzwerten aus bodengestützten Phänotypisierungen verglichen. Die Präzision der Ertragsvorhersage beider Sensorsysteme lag auf dem gleichen Niveau und erreichte eine maximale Vorhersagegenauigkeit von  $r^2 = 0,82$  mit einer kontinuierlichen Zunahme der Genauigkeit über die gesamte Vegetationsperiode.*

## 1 Einleitung

Trotz zahlreicher Fortschritte auf dem Gebiet der Genetik und der Anwendung neuer molekularer Technologien in der Pflanzenforschung (GOWEN et al. 2013) hat sich der Ertragszuwachs durch züchterische Forschung bei den wichtigsten Nutzpflanzen in vielen Regionen der Welt stabilisiert oder stagniert sogar (ACRECHE et al. 2008; SADRAS & LAWSON 2011). Im Bereich der Pflanzenzüchtung ist die Phänotypisierung im Feld im Hinblick auf den hohen Durchsatz und die Qualität einer der größten Engpässe in Züchtungsprogrammen (ARAUS & CAIRNS 2014; TARDIEU et al. 2017).

Fernerkundungstechniken nutzen die Lichtreflexion des Pflanzenbestandes, um den Ertrag auf der Ebene des Genotyps zerstörungsfrei zu bewerten (REYNOLDS et al. 1999). Zu diesem Zweck werden mit passiven Sensoren Informationen über die Reflexion elektromagnetischer Wellen des Pflanzenbestandes gewonnen. Die gemessene Reflexion hängt von den chemischen und

---

<sup>1</sup> Institut der Agrar- und Ernährungswissenschaften, Professur für Pflanzenzüchtung, Martin Luther Universität Halle-Wittenberg, Betty-Heimann-Str. 3, D-06120 Halle; E-Mail: paul.herzig@hs-anhalt.de; peter.borrmann@julius-kuehn.de; [klaus.pillen, andreas.maurer]@landw.uni-halle.de

<sup>2</sup> Fraunhofer-Institut für Fabrikbetrieb und -automatisierung IFF, Sandtorstraße 22, D-39106 Magdeburg; E-Mail: uwe.knauer@hs-anhalt.de; udo.seiffert@compolytics.com

morphologischen Eigenschaften der Oberflächen ab und ändert sich mit dem Pflanzentyp, der Biomasse, dem Entwicklungsstadium, der Vitalität und den physiologischen Eigenschaften wie dem Wassergehalt und den Pflanzenpigmenten (BABAR et al. 2006; SILVA-PEREZ et al. 2018). Bestimmte Pflanzenmerkmale sind mit der Absorption ganz bestimmter Wellenlängen der elektromagnetischen Strahlung verbunden. Darüber hinaus können mehreren spezifischen Wellenlängen durch Koeffizienten, die so genannten Vegetationsindizes (VI), zusammengefasst werden.

Bei vielen UAV-Fernerkundungsanwendungen werden die Lichtspektren im sichtbaren Bereich (400-700 nm), im nahen Infrarot (700-1200 nm) und im kurzwelligen Infrarot (>1200 nm) mit multispektralen, hyperspektralen oder herkömmlichen Rot-Grün-Blau (RGB)-Kameras gemessen. Multi- und vor allem hyperspektrale Sensoren haben eine hohe spektrale Auflösung, sind aber in der Regel teurer und schwerer als handelsübliche RGB-Kameras. Außerdem ist die spektrale Erfassung empfindlicher gegenüber den Lichtverhältnissen der Umgebung als bei der Farbfotografie. Multispektralsensoren sind die verdichtete Form eines Hyperspektralsensors durch (typischerweise) anwendungsspezifische Bandenauswahl, da mehrere, über Filter frei wählbare Wellenlängenbänder im sichtbaren und infraroten Spektrum erfasst werden können und dennoch die Nutzung eines breiten Spektralindex ermöglichen (NEBIKER et al. 2016). Aber auch ultrahochauflösende Bilder von kostengünstigen RGB-Kameras mit einer allgemein hohen Qualität der werkseitigen Farbkalibrierung, bieten eine breite Palette von Anwendungen für die Phänotypisierung. Die hohe räumliche Auflösung ist der Hauptvorteil von RGB-Sensoren, die zur Rekonstruktion der 3D-Struktur des Blätterdachs auf der Grundlage des Structure from Motion-Algorithmus (SfM) (ULLMAN 1979) verwendet werden können und somit die Morphologie der Fläche sehr gut wiedergeben können. Die zusätzlichen Informationen über die Architektur des Blätterdaches können dann in die Modellierung der Ertragsbildung und Biomasse integriert werden (BENDIG et al. 2014; GARCÍA-MARTÍNEZ et al. 2020).

Landwirtschaftsmodelle, die sich auf Fernerkundungsdaten stützen, z. B. zur Ertragsschätzung, basieren zunehmend auf Methoden des maschinellen Lernens. Diese Methoden sind oft robuster und genauer als herkömmliche korrelative Methoden, da sie sich durch Training flexibel an die Komplexität der Daten anpassen können (LIAKOS et al. 2018). Darüber hinaus kann die Varianz einer vorherzusagenden Variable entweder durch parametrische oder nicht-parametrische Ansätze erklärt werden. Erstere sind aufgrund ihrer vordefinierten Struktur leichter zu interpretieren; letztere erfordern in der Regel mehr Training, sind aber auch anpassungsfähiger. Häufig verwendete Methoden sind die multivariate Regression (HAN et al. 2019; FERNANDEZ-GALLEGO et al. 2020), Entscheidungsbäume (HAN et al. 2019; LI et al. 2020), Support-Vektor-Maschinen (HAN et al. 2019) oder künstliche neuronale Netze (HAN et al. 2019; GARCÍA-MARTÍNEZ et al. 2020).

Trotz zahlreicher vielversprechender Fortschritte auf dem Gebiet der UAV-gestützten Hochdurchsatz-Phänotypisierung haben die Züchter in der Vergangenheit aufgrund der Komplexität und der Kosten gezögert, diese Technologien in ihre bereits erfolgreichen Züchtungspipelines zu integrieren. In dem Maße jedoch, wie das Wissen auf der Ebene der translationalen Forschung zwischen technologischen und biologischen Bereichen wächst, können sowohl die Komplexität der Datenerfassung und -verarbeitung als auch die Kosten der

Technologie reduziert werden, was die Akzeptanz erhöht. Darüber hinaus wird die Akzeptanz durch den Nachweis von Effizienzgewinnen bei der Erreichung von Zuchtzielen durch neue innovative Methoden erhöht (REYNOLDS et al. 2020).

Diese Studie vergleicht UAV-gestützte RGB- und Multispektralbild-Analysen im Hinblick auf für die Züchtung geeignete Merkmale wie Pflanzenhöhe (HEI), Vegetationsbedeckung (VCOV) und Ertragsvorhersagen unter Verwendung verschiedener Modellierungsansätze während der gesamten Vegetationsperiode. Das zeitliche Raster (wöchentlich) der Merkmalerfassung an drei Versuchsstandorten wurde für die Extraktion von wachstumsdynamischen Merkmalen genutzt. Mit Hilfe der bodengestützten Phänotypisierung war es möglich, die Genauigkeit der UAV-gestützten Phänotypisierung zu quantifizieren. Es wurden Wiederholbarkeits- und Genotyp-Assoziationsstudien durchgeführt, um die Eignung der Verwendung konventioneller und neuer Merkmale für die Gerstenzüchtung zu testen. Gerste wurde in dieser Studie als Versuchsorganismus ausgewählt, da sie als genetische und phänotypische Modellpflanze für gemäßigte Getreidearten wie Weizen, Dinkel, Roggen und Triticale dient und gleichzeitig eine hohe wirtschaftliche Bedeutung hat. Darüber hinaus konnten die in dieser Studie unter Verwendung der vielfältigen Gerstenkartierungspopulation S42IL (SCHMALENBACH et al. 2008; HONSDORF et al. 2017) gefundenen Ergebnisse als eine Art Validierung mit zahlreichen zuvor veröffentlichten Studien zu dieser Population verglichen werden. Dieser Artikel stellt die Kurzfassung der schon veröffentlichten Studie HERZIG et al. (2021) dar.

## **2 Material & Methoden**

### **2.1 Pflanzenmaterial, Standort- und Anbaubedingungen**

Das Pflanzenmaterial umfasste 49 Wildgersten-Introgressionslinien (ILs) der S42IL-Bibliothek und 11 Sommergersten-Sorten als Kontrollen (SCHMALENBACH et al. 2008). Die S42IL-Population wurde konventionell in mehreren Genotyp-Assoziationsstudien phänotypisiert, um signifikante Introgressionslinien für Pflanzenhöhe (SCHMALENBACH et al. 2009; WANG et al. 2010a; HOFFMANN et al. 2012), Trockenstress (HONSDORF et al. 2014b; HONSDORF 2015; HONSDORF et al. 2017) und Ertrag (ZAHN et al. 2020) zu identifizieren, die in dieser Studie vergleichend für die sensorgestützte Phänotypisierung verwendet werden können. Die Feldversuche im Jahr 2019 wurden an drei Standorten in Deutschland auf den Versuchsfeldern der MLU in Halle (51°29'43 "N 11°59'50 "E) und Merbitz (51°36'32 "N 11°53'43 "E) sowie auf dem Versuchsgelände des Instituts für Pflanzengenetik und Kulturpflanzenforschung (IPK) in Gatersleben (51°48'15 "N 11°15'02 "E) durchgeführt (Abb. 1). Die Feldversuche umfassten 360 Ertragsparzellen. Weitere Informationen sind in HERZIG et al. (2021) aufgeführt.

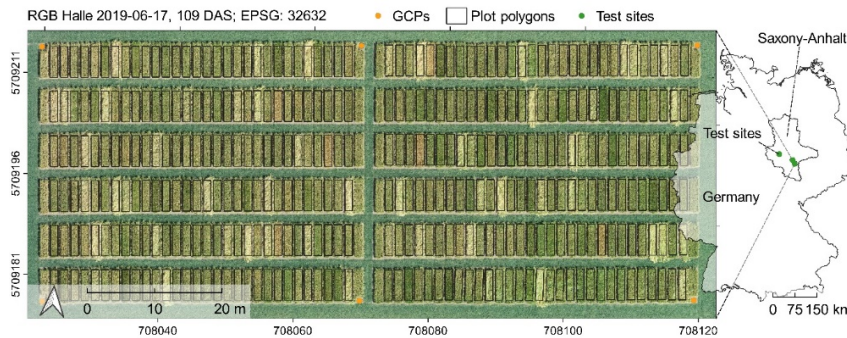


Abb. 1: Überblick über die drei Feldversuche im Jahr 2019 in Halle, Merbitz und Gatersleben

## 2.2 Bodenphänotypisierung

Die Phänotypisierung am Boden umfasste die in Tab. 1 beschriebenen agronomischen und entwicklungsrelevanten Merkmale, die in dieser Studie als Ground Truth (GT) verwendet wurden. Die Phänotypisierung wurde wöchentlich an allen Standorten parallel zu den UAV-Flügen durchgeführt.

Tab. 1: Liste und Beschreibung der untersuchten Merkmale

Merkm <sup>al</sup>	Ab- kürzung	Einheit	Detektions- instrument	Messung
<b>Schossen</b>	SHO	Tage	Visuell	Anzahl der Tage von der Aussaat bis zum ersten Knoten, (BBCH 31)
<b>Blüte</b>	HEA	Tage	Visuell	Anzahl der Tage von der Aussaat bis zum Erscheinen der Grannenspitzen, (BBCH 49)
<b>Reife</b>	MAT	Tage	Visuell	Anzahl der Tage von der Aussaat bis zur Geldbreife, (BBCH 87)
<b>Bestands- höhe</b>	HEI <sub>GT</sub> <sup>a/</sup> HEI <sub>CHM</sub> <sup>b/</sup> HEI <sub>CHMred</sub> <sup>c</sup>	cm	Visuell/ UAV (RGB)	Durchschnittliche Bestandshöhe aller Pflanzen einer Parzelle. UAV-RGB-Daten wurden verwendet, um digitale Höhenmodelle (DEM) zu erstellen, die zur Bestimmung von Wachstumsparametern führen (HEI <sub>Gri</sub> <sup>d</sup> , HEI <sub>GRd</sub> <sup>e</sup> , HEI <sub>MAX</sub> <sup>f</sup> )
<b>Be- deckungs- grad</b>	VCOV	%	UAV (RGB, Multispek)	Fläche einer Parzelle, die von Pflanzen bedeckt ist, die zur Bestimmung der Wachstumsparameter führen (VCOV <sub>Gri</sub> <sup>g</sup> , VCOV <sub>90</sub> <sup>h</sup> , VCOV <sub>smoothed</sub> <sup>i</sup> )
<b>Parzellen- ertrag</b>	YLD	kg	Ernte- maschine / UAV (RGB, Multispek)	Korngewicht bei der Ernte der gesamten Parzelle (7.5m <sup>2</sup> ) / Modellierung auf der Grundlage von spektralen UAV-Daten, VCOV und HEI.

<sup>a</sup> Im Feld gemessene Bestandshöhe.

<sup>b</sup> Vom UAV-Pflanzenhöhenmodell abgeleitete Bestandshöhe.

<sup>c</sup> Vom UAV-Pflanzenhöhenmodell abgeleitete Höhe des Kronendachs, reduziert auf den HEIGT-Datensatz.

<sup>d</sup> Wachstumsrate der Wachstumsphase der zunehmenden Pflanzenhöhe.

<sup>e</sup> Wachstumsrate der Wachstumsphase der abnehmenden Pflanzenhöhe.

<sup>f</sup> Maximale Pflanzenhöhe aller gemessenen Zeitpunkte.

<sup>g</sup> Wachstumsrate der Wachstumsphase der zunehmenden Vegetationsbedeckung.

<sup>h</sup> Anzahl der Tage, an denen die Vegetationsbedeckung von 10 % auf 90 % zunahm.

<sup>i</sup> Geglättete Daten zur Vegetationsbedeckung.

### **2.3 UAV-Plattformen, Kamerasysteme und UAV-Kampagnen**

Die wöchentlichen UAV-Flüge begannen Anfang April und endeten nach 11 Wochen in HAL und nach 12 Wochen in IPK und MER mit einem Flug kurz vor der Ernte. Es wurden zwei Kamerasysteme verwendet, die sich in Bezug auf Kosten, Gewicht, und Bilddaten unterscheiden. Hochauflösende RGB-Bilder wurden mit einem Quadrocopter-System DJI Phantom 4 Professional (SZ DJI Technology Co. Ltd., Shenzhen, China) aufgenommen, das standardmäßig mit einer Zenmuse X4S-Kamera (20-Megapixel-CMOS-Sensor (Complementary Metal Oxide Semiconductor)) ausgestattet war. Die Brennweite der Optik von 8,8 mm ergab eine Bodenauflösung von 0,82 cm/Pixel bei einer Flughöhe von 30 m und von 1,3 cm/Pixel bei einer Flughöhe von 50 m. Das Kreuzgitterflugschema bei Flughöhen von 30 m und 50 m wurde zur Erstellung eines detaillierten digitalen Höhenmodells (DEM) verwendet.

Die Multispektralbilder wurden mit der MACAW Multispektralkamera (Tetracam Inc., Chatsworth, CA, USA) aufgenommen, die auf der UAV-Plattform DJI Matrice 600 Pro (SZ DJI Technology Co. Ltd., Shenzhen, China) montiert war. Die Kamera besteht aus sechs unabhängigen CMOS-Bildsensoren mit einer Bildgröße von jeweils  $1280 \times 1024$  Pixeln (1,3 MP) und einer radiometrischen Auflösung von 16 Bit. Die Brennweite der Optik von 9,6 mm ergab eine Bodenauflösung von 1,5 cm/Pixel bei einer Flughöhe von 30 m. In dieser Studie wurden fünf Filter mit einer Halbwertsbreite von 10 nm (FWHM) mit den Zentralwellenlängen 670, 700, 740, 780 und 900 sowie ein Filter mit einer FWHM von 40 nm und Zentralwellenlängen von 970 nm ausgewählt. Weitere Daten zur spezifischen Filtertransmission, zu den Sensorspezifikationen und zur spektralen Empfindlichkeit des CMOS sind in HERZIG et al. (2021) aufgeführt.

Zur Korrektur der gemessenen Reflexionswerte wurde die Globalstrahlung mit Hilfe eines incident light Sensors (ILS) mit derselben Filterkombination auf der Oberseite der Matrice 600 Pro (M600) angebracht, gemessen.

Die Georeferenzierung der UAV-Bilder erfolgte über sechs Bodenkontrollpunkte (GCPs), die gleichmäßig über die Feldversuche verteilt waren. Die Position der GCPs wurden mit einem Trimble R9s GNSS-Empfänger (Global Navigation Satellite System) (Trimble Ltd., USA) mit einer Genauigkeit von 0,02 m bestimmt.

### **2.4 UAV-Datenverarbeitung**

Der gesamten Bearbeitungs-Pipeline ist in Abb. 2 dargestellt. Mit Ausnahme der anfänglichen Vorverarbeitung und der photogrammetrischen Verarbeitung wurden alle Arbeiten an den UAV-Daten in R (R CORE TEAM 2020) durchgeführt. Die verwendeten Spezialpakete werden in den entsprechenden Abschnitten erwähnt.

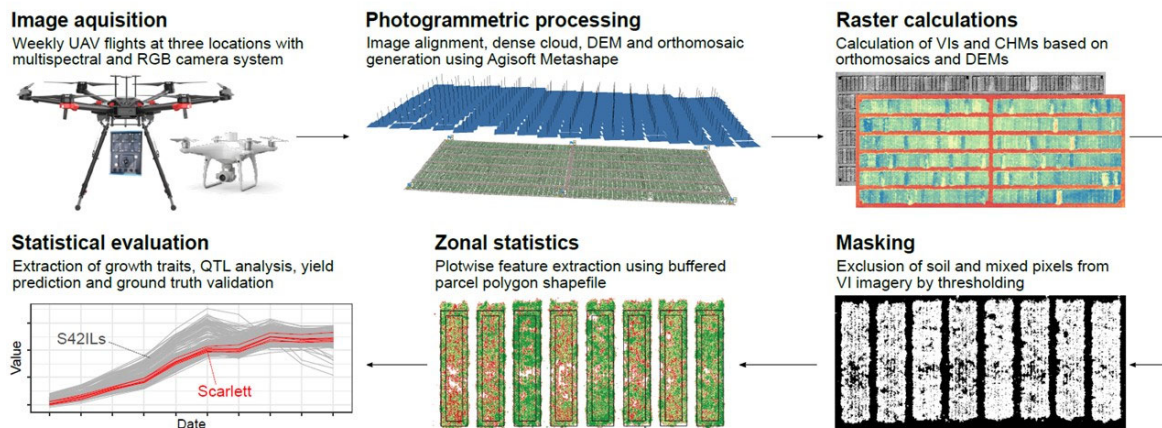


Abb.2: Schematische Darstellung der Bildaufnahme, Bildverarbeitung und Datenanalyse (HERZIG et al. 2021)

#### 2.4.1 Vorverarbeitung der Multispektral-Daten

Die Vorverarbeitung der MACAW-Bilder wurde mit dem Bildbearbeitungsprogramm Pixel Wrench 2 (Tetracam Inc.; Chatsworth, CA, USA) durchgeführt und umfasste im Wesentlichen die Versatz-Korrektur (Drehung und Skalierung der Bilder des jeweiligen Sensors) und die Korrektur auf die einfallende Strahlung. In Anbetracht der geringen Flughöhe der UAVs und des daher angenommenen begrenzten atmosphärischen Einflusses wurde keine zusätzliche atmosphärische Korrektur durchgeführt.

#### 2.4.2 Photogrammetrische Verarbeitung

Die photogrammetrische Datenverarbeitung der gewonnenen UAV-Bilder erfolgte in Agisoft Metashape Professional (Version 1.5.2.7838, Agisoft LLC, St. Petersburg, Russland). Der Arbeitsablauf zur Erstellung des Orthomosaiks bestand aus vier Hauptverarbeitungsschritten: Bildausrichtung, Erstellung einer dichten Punktwolke, Erstellung eines digitalen Höhenmodells (DEM) und abschließende Erstellung eines Orthomosaiks. Die detaillierten Einstellungen für die Verarbeitung der Datensätze sind in HERZIG et al. (2021) zusammengefasst.

#### 2.4.3 Berechnung des Pflanzenhöhenmodells (CHM) und des Vegetationsindex (VI)

Die Pflanzenhöhenmodelle (CHM) wurden aus hochauflösenden RGB-DEMs abgeleitet. Dabei diente die erste kalkulierte DEMs (Aufnahme direkt nach der Aussaat) als  $T_0$ -Modell von dem die Pixelwerten der nachfolgenden DEMs subtrahiert wurden, um die absolute  $HEI_{CHM}$  aller Parzellen zu erhalten.  $HEI_{CHMred}$  stellt eine Teilmenge von  $HEI_{CHM}$  dar, die auf die 107 Parzellen von  $HEI_{GT}$  reduziert wurde. 30 VIs wurden berechnet und im Hinblick auf ihre Sensitivität in folgende Gruppen unterteilt: Einzelband, Pigment, Wassergehalt und Physiologie. Die Liste der VIs findet sich in HERZIG et al. (2021). Alle Rasterberechnungen wurden mit dem Rasterpaket von HIJMAN (2020) durchgeführt.

#### 2.4.4 Maskierung des Bodens

Um eine Boden-Pflanzensegmentierung gerade in den ersten Entwicklungsstadien der Pflanzen zu vorzunehmen, wurde die Otsu-Methode auf kontrastreiche NDVI- und EG-Bilder angewendet. Die Otsu-Methode ist ein adaptiver, nichtparametrischer und daher nicht überprüfter Schwellenwertalgorithmus für die Bildsegmentierung auf der Grundlage von Graustufenhistogrammen (OTSU 1979), der sich als geeignet für die Trennung von Pflanzen- und Bodenpixeln erwiesen hat (MARCIAL-PABLO et al. 2018). Die Methode wurde mit der Funktion `auto_thresh` des Pakets von LANDINI et al. (2017) implementiert. Die resultierenden Masken wurden dann auf die entsprechenden Spektralbänder und VIs derselben Datensatzes angewendet.

#### 2.4.5 Bestimmung der Vegetationsbedeckung (VCOV)

Für die Bodenmaskierung zur Bestimmung der VCOV wurde nicht die Methode von Qtsu gewählt, da dieses Verfahren einen hohen Anteil an Misch-Pixel (Boden-Pflanze) zulässt, die zwar für die Erfassung der spektralen Merkmale, nicht aber für die Schätzung des relativen Vegetationsanteils erwünscht sind. Daher war eine strengere Diskriminierung erforderlich. Nur Pixel der RGB-Bilder, die über einem festen GCC-VI-Schwellenwert von 0,38 lagen, wurden als Pflanzenpixel behandelt. Im Gegensatz dazu wurden die multispektralen Bilder auf Basis des k-means Algorithmus mit vier Clusterzentren auf die NDVI-Bilder angewendet und maskiert, was zu einem dynamischeren Schwellenwert führte. Nur Pixel, die zum höchsten NDVI-Cluster gehören, wurden als Pflanzenpixel behandelt.

#### 2.4.6 Parzellenweise Merkmalsextraktion

Die parzellenweise Merkmalsextraktion wurden mit Hilfe des RSAGA-Pakets von BRENNING (2008) realisiert, das den Zugang zu den Geoberechnungs- und Geländeanalysefunktionen des geographischen Informationssystems ermöglicht. Es wurde die SAGA-Version 6.2.0 verwendet. Die Shapefiles der Feldversuche wurden mit der Software MiniGIS von Geo-Konzept (Adelschlag, Deutschland) erstellt. Nach Anwendung eines Puffers von -0,2 m auf jedes Parzellenpolygon-Shapefile, um Randeffekte zu berücksichtigen, wurden zusammenfassende Statistiken wie das arithmetische Mittel und das 95 %-Quantil der Parzellen extrahiert.

### 2.5 Statistische Analyse

Die weitere Datenanalyse erfolgte anhand des 95 %-Quantils des Parzellen Polygons der HEI<sub>CHM</sub>-Orthomosaik und des Mittelwerts der VI- und VCOV-Orthomosaik.

#### 2.5.1 Validierung durch Ground Truth (GT) Daten

Zur Bewertung der Genauigkeit der durch die UAV-Bilder ermittelten Bestandshöhe (HEI<sub>CHM</sub>) wurden der Korrelationskoeffizient ( $r$ ) von Pearson und der mittlere quadratische Fehler (RMSE) von HEI<sub>CHM</sub> und HEI<sub>GT</sub> für jeden Zeitpunkt und über den gesamten Vegetationszeitraum berechnet (Formel 2).

#### 2.5.2 Modellierung der Wachstumsrate

Durch multitemporale Messungen wurde die Berechnung der Wachstumsraten von HEI- und VCOV-Daten durch Anwendung der im R-Paket `growthPheno` (BRIEN et al. 2020) ermöglicht.

Dieses Verfahren ermöglicht die Glättung von Wachstumskurven und anschließend die Extraktion von Merkmalen (SET). Details sind in HERZIG et al. (2021) zu finden.

### 2.5.3 Ertragsvorhersage

Unter Verwendung der spektralen Merkmale (Tab. 2) sowie die räumlichen Merkmale HEI und VCOV der beiden vorgestellten bildgebenden Systeme wurde die Vorhersagegenauigkeit des Parzellenertrags bewertet. Dabei wurden beide Systeme unabhängig voneinander betrachtet, um ihre Eignung zur Vorhersage zu vergleichen. Da  $HEI_{CHM}$  nur aus RGB-Bildern abgeleitet werden konnte, wurde keine Bestandshöhen bei der multispektralen Ertragsvorhersage verwendet. Die Modellierung des Parzellenertrags umfasste drei Ansätze:

- Ansatz 1:** Anwendung eines einzigen linearen Regressionsmodells für jedes Merkmal zu einem einzigen Zeitpunkt
- Ansatz 2:** Einbeziehung aller gemessenen und abgeleiteten Merkmale desselben Zeitpunkts als Prädiktoren in eine Mehrfachregression
- Ansatz 3:** Erweiterung des Mehrfachregressionsmodells, das durch eine gestapelte Datenbasis aller vorrangegangenen Messtermin zur Vorhersage führt

Für die Mehrfachregression in den Ansätzen 2 und 3 wurden ein verallgemeinertes lineares Modell (GLM) mit elastischem Netz und ein Random-Forest-Modell angepasst. Beide wurden mit Hilfe des ‚Tidymodels‘- Package (KUHNS & WICKHAM 2020) implementiert. Der Algorithmus für das regularisierte GLM mit elastischem Netz kombiniert linear L1- (Lasso) und L2- Regularisierungsstrafen (Ridge) in einem mehrfachen linearen Modell.

Der Random-Forest-Algorithmus ist eine robuste Lernmethode zur Klassifizierung und Regression (BREIMANN 2001). Die beiden Hyperparameter  $n_{tree}$  und  $m_{try}$  wurden konstant bei  $n_{tree} = 1000$  und  $m_{try} = n_{predictors}/3$  gehalten.

Die Zusammenhänge zwischen einzelnen Merkmalen und Erträgen wurden durch Berechnung des Bestimmtheitsmaßes ( $r^2$ ) bewertet. Bei der multiplen linearen Regression wurde auch der RMSE erfasst. Das  $r^2$  und der RMSE wurden wie folgt berechnet:

$$(1) r^2 = 1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

und

$$(2) RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}}$$

wobei  $x_i$  der tatsächliche Parzellenertrag,  $\bar{x}$  der durchschnittliche tatsächliche Parzellenertrag,  $y_i$  der vorhergesagte Parzellenertrag und  $n$  die Anzahl der Beobachtungen ist. Mehrfache Regressionsparameter wurden extrahiert und über eine zehnfache kreuzvalidierte Modellanpassung gemittelt.

Die Schätzungen der GLM-Variablen wurden aus der besten kreuzvalidierten Anpassung extrahiert und ihre entsprechenden Prozentwerte wurden als Bruchteil der gesamten absoluten Schätzungssumme berechnet.



Die für die Genotyp-Assoziationsstudie verwendeten vorhergesagten Erträge wurden über eine zehnmal wiederholte zehnfache GLM-Kreuzvalidierung ermittelt, wobei die Vorhersagen der unabhängigen Validierungsuntergruppe beibehalten und für jede Parzelle gemittelt wurden.

### 2.5.4 Genotyp-Assoziationsstudie

Vor der Genotyp-Assoziationsstudie wurde die Wiederholbarkeit ( $R^2$ ) als Maß für den Anteil der genotypischen Variation an der gesamten phänotypischen Varianz mithilfe des lme4-Pakets (BATES et al. 2018) für jedes Merkmal zu jedem Zeitpunkt wie folgt berechnet:

$$(3) R^2 = \frac{V_G}{V_P/r}$$

wobei  $V_G$  und  $V_P$  die genotypische und die phänotypische Gesamtvarianz sind und  $r$  die Anzahl der Wiederholungen ( $r = 6$  in dieser Studie) pro Genotyp ist. Die Genotyp-Assoziationsstudie wurde dann als Dunnett-Test (DUNNETT 1955) durchgeführt, wobei das durch die UAV ermittelte Merkmal jedes Genotyps mit der Kontrollsorte Scarlett unter Verwendung des glht-Pakets für allgemeine lineare Hypothesen (HOTHORN et al. 2008) miteinander verglichen wurde. Zusätzlich wurde die Bonferroni-Anpassung auf die Modellzusammenfassung angewendet und die Signifikanzschwelle auf  $p < 0,01$  festgelegt.

## 3 Ergebnisse

### 3.1 Bestimmung der Bestandshöhe

Die Korrelationen von  $HEI_{CHM}$  und  $HEI_{GT}$  über alle Zeitpunkte hinweg sind in Abb. 3 dargestellt. In den drei Umgebungen HAL, IPK und MER wurden Korrelationen von 0,82, 0,89 und 0,91 erreicht, was zu einer Gesamtkorrelation von  $r = 0,87$  unter Verwendung des 95 %igen CHM-Plot-Quantils führt. Trotz der in erster Linie starken Korrelationen wurde  $HEI_{GT}$  von der UAV im Allgemeinen unterschätzt. Eine Detaillierte Auswertung mit dem Bezug zu einzelnen Messterminen wird in HERZIG et al. (2021) gegeben.




Abb.3: Pearson-Korrelation der Bestandshöhenmessungen im Feld ( $HEI_{GT}$ ) und photogrammetrischer UAV-Pflanzenhöhenbestimmung ( $HEI_{CHMred}$ ) innerhalb und über die Umgebung hinweg. Die Farben geben den Zeitpunkt der Messung in Tagen nach der Aussaat (DAS) an (HERZIG et al. 2021)

Die Wiederholbarkeiten von  $HEI_{CHM}$ ,  $HEI_{CHMred}$  und  $HEI_{GT}$  zeigten hohe Werte zwischen den einzelnen Zeitpunkten von bis zu  $R^2 = 0,98$  fast über die gesamte Wachstumsperiode (HERZIG et al. 2021). Vor dem SHO war die Wiederholbarkeit gering, begann jedoch mit dem Höhenwachstum um SHO herum zuzunehmen, um ein Maximum und ein Plateau beim HEA zu erreichen, bis zum Zeitpunkt der Reife, wo die Wiederholbarkeit wieder abnahm.

Die im Dunnett-Test ermittelten größten signifikanten Unterschiede wurden im Zeitraum zwischen SHO und HEA gefunden, wobei die Bestandshöhe zu dieser Zeit auch die größten Unterschiede aufwies. Im Allgemeinen erreichte der  $HEI_{CHM}$ -Datensatz die höchste Signifikanz, und mehrere Linien wurden über den Messzeitraum hinweg konstant festgestellt. Im Vergleich dazu zeigten die reduzierten  $HEI_{GT}$ - und  $HEI_{CHMred}$ -Datensätze weniger signifikante Ergebnisse, was den großen Vorteil der UAV-Phänotypisierung zeigt, die einen größeren Stichprobenumfang abdecken kann.

### 3.2 Bestimmung der Vegetationsbedeckung

Die Schätzung der VCOV durch die RGB-Bilder ergab eine höhere Kontinuität zwischen den aufeinanderfolgenden Flügen mit einer späteren Sättigung und einer geringeren Rate an Ausreißern, was einen zuverlässigeren Datensatz im Vergleich zu den mit multispektralen Bildern ermittelten VCOV-Werten ergab. Die VCOV-Werte des multispektralen Datensatzes schienen aufgrund der größeren Streuung und Ausreißerquote eine schlechtere Qualität aufzuweisen. In MER wiesen die VCOV-Werte die größten Schwankungen zwischen den beiden Bestimmungsmethoden auf. Dennoch lässt sich über alle Datensätze hinweg feststellen, dass der Populationsdurchschnitt der S42ILs leicht über der Leistung von Scarlett liegt.

### 3.3 Ertragsvorhersage

Der gemessene Parzellenertrag war der Zielwert für die Ertragsmodellierung. Die höchsten Erträge wurden am IPK mit einem Durchschnittsertrag von  $4,43 \text{ kg}/7,5\text{m}^2$  ( $\cong 59,1 \text{ dt/ha}$ ) gefunden, gefolgt von MER mit  $4,01 \text{ kg}/7,5\text{m}^2$  ( $\cong 53,5 \text{ dt/ha}$ ) und HAL mit  $3,73 \text{ kg}/7,5\text{m}^2$  ( $\cong 49,7 \text{ dt/ha}$ ). HAL zeigte den höchsten Variationskoeffizienten mit  $CV=0,27$ , gefolgt von MER mit  $CV = 0,16$  und IPK mit  $CV = 0,12$ . Im Folgenden werden nur die Ergebnisse der GLM-Modelle beschrieben; die Ergebnisse der entsprechenden RF-Modelle, die im Allgemeinen die gleichen Trends widerspiegeln, sind in HERZIG et al. (2021) enthalten.

Die Modelle aus Ansatz 1, die auf einem einzigen Merkmal zu einem Zeitpunkt reduziert wurden, zeigte die lineare Regression starke Unterschiede in der Vorhersageleistung zwischen den Modellen (Abb. 4a). Für Abb. 4a wurden die beiden VIs mit den höchsten  $r^2$ -Werten pro Umgebung und Bilddatensatz ausgewählt und über alle Umgebungen hinweg aufgetragen, was zu vier bzw. fünf VIs für die multispektralen und RGB-Bilddatensätze führte. Die höchsten  $r^2$ -Werte des RGB-Datensatzes wurden in allen drei Umgebungen kurz vor MAT mit  $r^2 = 0,55$ ,  $r^2 = 0,37$  und  $r^2 = 0,21$  in HAL, MER und IPK ermittelt (Abb. 4a). Im multispektralen Datensatz wurden sowohl um HEA als auch kurz vor MAT hohe  $r^2$ -Werte festgestellt, die in der gleichen Größenordnung lagen wie im RGB-Datensatz, mit Ausnahme der hohen Vorhersagekraft der multispektralen Daten bei 47 DAS in MER.

Bei Ansatz 2 wurden für die Ertragsvorhersagemodelle die Summe aller Merkmale aus dem RGB- oder Multispektraldaten inklusive der vorhandenen morphologischen Merkmale ( $HEI$  und  $VCOV$ )

zu einem jeweiligen Zeitpunkt gebildet und berücksichtigt. Die Vorhersagekraft nahm zu, unterlag aber immer noch großen Schwankungen zwischen den Zeitpunkten (Abb. 4b). Die Kurven der Vorhersagegenauigkeit zwischen dem RGB- und dem multispektralen Datensatz zeigten ähnliche Schwankungen in einem Bereich zwischen  $r^2=0,03$  und  $r^2=0,6$ . Die höchste Vorhersagegenauigkeit wurde an allen drei Standorten im letzten Drittel der Vegetationsperiode mit Werten von  $r^2 = 0,6$ ,  $r^2 = 0,5$  und  $r^2 = 0,29$  in den RGB-Bildern in HAL, MER bzw. IPK (Abb. 4b) erreicht.

Ansatz 3 bestand darin, alle Merkmale wie in Ansatz 2 zu verwenden, welche sich zusätzlich mit jedem voranschreitenden Messtag addierten, sodass alle zuvor ermittelten Merkmale in die Modellierung des aktuellen Modells miteinfließen. Bei diesem Ansatz nahm die Vorhersagegenauigkeit mit jedem zusätzlichen Messtag zu und übertraf die Vorhersagegenauigkeit am Ende der Vegetationsperiode im Vergleich zum zweiten Ansatz deutlich (Abb. 5). Die Vorhersagegenauigkeit aller Modelle zur Ertragsschätzung zeigte im Allgemeinen einen asymptotischen Trend. Die Trends in der Vorhersagegenauigkeit zwischen den Standorten und den RGB- und Multispektraldatensätzen wurden von Ansatz 2 übernommen, allerdings auf einem höheren Niveau. Hohe  $r^2$ -Werte wurden ebenfalls vor MAT festgestellt und erreichten den höchsten Wert in HAL mit  $r^2 = 0,82$ , gefolgt von  $r^2 = 0,65$  in MER und  $r^2 = 0,55$  in IPK. Dennoch hatten die hohen  $r^2$ -Werte in HAL einen größeren RMSE als in MER oder IPK. Der RMSE der Regressionsmodelle des multispektralen Datensatzes lag zwischen 0,24 und 0,39 kg/Plot ( $\cong 6,4$ -10,4%) in HAL, zwischen 0,27 und 0,35 kg/Plot ( $\cong 6,7$ -8,7%) in MER und zwischen 0,26 und 0,33 kg/Plot ( $\cong 5,9$ -7,5%) in IPK. Der RMSE der RGB-basierten Regressionsmodelle lag in HAL zwischen 0,23 und 0,45 kg/Plot ( $\cong 6,1$ -12,1%), in MER zwischen 0,24 und 0,32 kg/Plot ( $\cong 6,1$ -8,0%) und in IPK zwischen 0,23 und 0,33 kg/Plot ( $\cong 5,2$ -7,6%). Obwohl IPK den niedrigsten  $r^2$ -Wert aufwies, ist der absolute Schätzfehler am geringsten, weil der CV des gemessenen Ertrags am kleinsten ist.

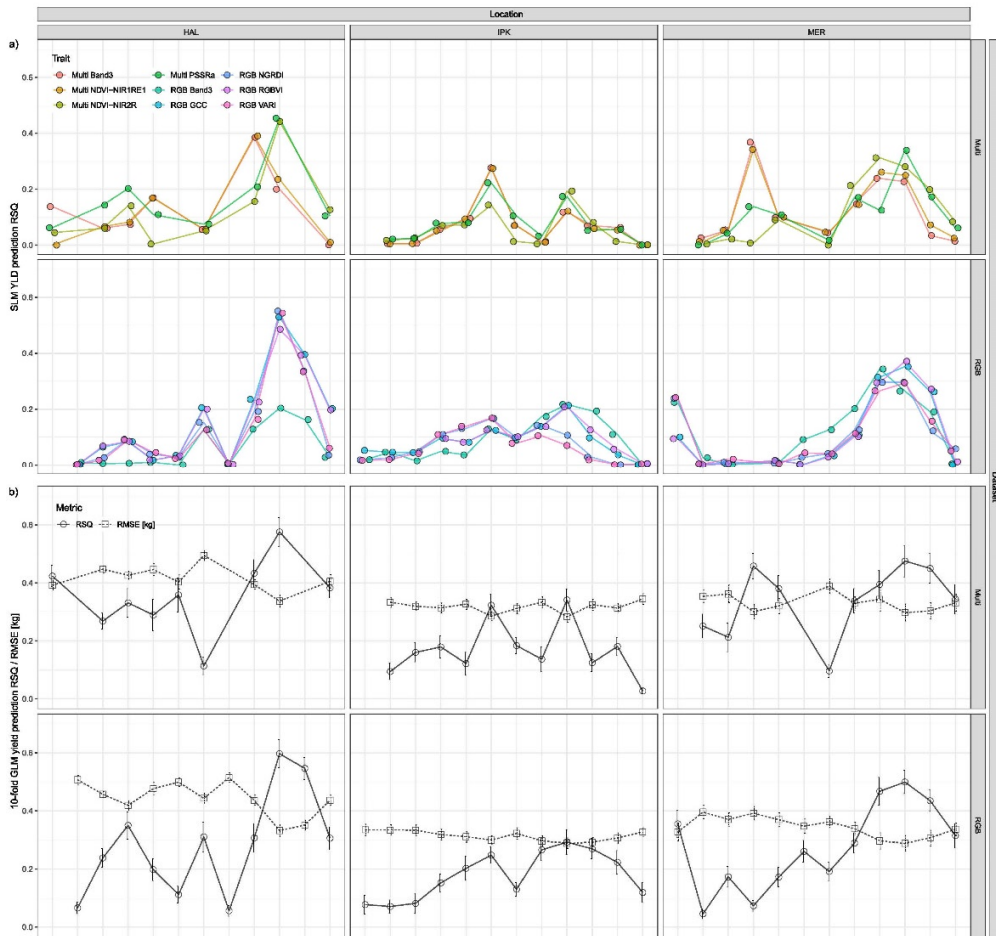


Abb.4: Vergleich der Ertragsvorhersagemodelle. (a) Vorhersagegenauigkeit eines einzelnen Merkmals mit linearer Regression (SLM). (b) Ertragsvorhersageleistung der GLM-Modelle, basierend auf den täglich zusammengeführten Datensätzen. RSQ ( $r^2$ ) und RMSE (root mean square error) wurden als Qualitätskriterium für die Vorhersagegenauigkeit verwendet

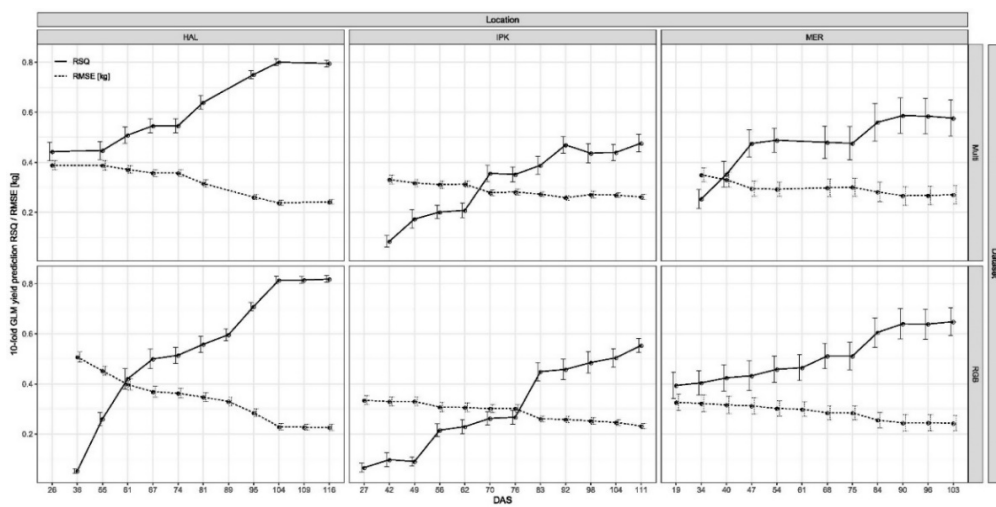


Abb. 5: Ergebnisse der Ertragsvorhersage des GLM-Modells, basierend auf Ansatz 3

## 4 Diskussion

### 4.1 Bestimmung der Bestandshöhe

Die Korrelationen von  $HEI_{CHM}$  und  $HEI_{GT}$  lagen geringfügig unter den in ähnlichen Studien (BENDIG et al. 2014; BARETH et al. 2016) beobachteten Korrelationen, was darauf zurückzuführen sein könnte, dass die Pflanzenhöhe beim Einsatz von Pflanzenwachstumsregulatoren eine relativ geringe Variation aufwies. Ohne den Einsatz von Pflanzenwachstumsregulatoren, wie es bei HAL der Fall war, litten die Parzellen unter Lagerbildung und die Bestimmung der Höhe war sowohl mit der Drohne als auch mit dem Lineal schwierig, was zu einer ungenauen Messung führte. Zudem können die  $HEI_{GT}$ -Messungen im Feld aufgrund der Subjektivität der Messung nicht als allgemeiner Standard für die Bestimmung der Kronenhöhe angesehen werden (PASK et al. 2012). Die Unterschätzung der Pflanzenhöhe durch die Bestimmung des SfM-Algorithmus ist ein bereits bekanntes Problem (GRENZDÖRFFER 2014). Dieser Effekt tritt eher mit zunehmender Bestandshöhe und unter windigen Bedingungen auf. Darüber hinaus ist der Bestand in der Phase der Triebverlängerung zwischen SHO und HEA sehr dünn, was den größten Effekt auf die Unterschätzungen des  $HEI_{CHM}$  haben dürfte. Dies deutet darauf hin, dass ein dünnerer Pflanzenbestand die Wahrscheinlichkeit verringert, Tie-Points an der Spitze des Bestandes zu finden. Es ist wahrscheinlicher, dass Tie-Points in einer niedrigeren Ebene gefunden werden können, wo die Blätter ein dichteres Blätterdach bilden.

Beim Vergleich der Wiederholbarkeiten zwischen  $HEI_{CHM}$ ,  $HEI_{GT}$  und  $HEI_{CHMred}$  zeigte  $HEI_{CHM}$  die höchsten Werte, was darauf hindeutet, dass es möglich ist, die Bestandshöhe zu einzelnen Zeitpunkten mit hoher Genauigkeit mittels UAV zu bestimmen. Die absolute  $HEI$ -Bestimmung hingegen ist mit verschiedenen Fehlerquellen behaftet und daher nur mit geringerer Genauigkeit möglich. Darüber hinaus deutet die höhere Wiederholbarkeit von  $HEI_{CHM}$  im Vergleich zu  $HEI_{CHMred}$  darauf hin, dass ein größerer Stichprobenumfang die statistische Aussagekraft erhöht, die durch den Einsatz von UAVs zur Bestimmung der Bestandshöhe in der Praxis erreicht werden kann.

Die Ergebnisse des Dunnett-Tests zeigen eine starke Überlappung der gefundenen signifikanten Linien zwischen  $HEI_{CHM}$ ,  $HEI_{GT}$  und  $HEI_{CHMred}$ , wobei die meisten dieser Linien bereits aus früheren Veröffentlichungen bekannt waren (SCHMALENBACH et al. 2009; WANG et al. 2010b; HOFFMANN et al. 2012; HONSDORF et al. 2014b; HONSDORF et al. 2014a).

### 4.2 Vegetationsbedeckung

Eine frühe Bestandsetablierung wirkt sehr kompetitiv und in der Lage Beikräuter zu verdrängen, was für den ökologischen Landbau von besonderem Interesse ist. Dieses Merkmal korreliert in hohem Maße mit dem physiologischen Zustand der Pflanze, wie z. B. dem Blattflächenindex, der Pflanzenvitalität, der Biomasse, dem Ertrag und der Reaktion auf erhöhte Temperaturen (LIU & PATTEY 2010; GRIEDER et al. 2015; LIEBISCH et al. 2015; BALLESTEROS et al. 2018; KIM et al. 2019; GARCÍA-MARTÍNEZ et al. 2020).

In dieser Studie scheinen die Ergebnisse der RGB-ermittelten VCOV zuverlässiger zu sein, was teilweise durch eine höhere Bildauflösung erklärt werden kann, die mit der geringeren Flughöhe, aber auch mit einer besseren räumlichen Auflösung des RGB-Kamerasensors zusammenhängt. Darüber hinaus ist die schlechtere Qualität der multispektral ermittelten VCOV möglicherweise

darauf zurückzuführen, dass einzelne Messtermine entfernt werden mussten, weil die Multispektralkamera zu Beginn der Saison in MER und IPK ausfiel.

Die Ergebnisse des anschließend durchgeführten Dunnett-Tests bestätigten, dass die Bestimmung von VCOV-Merkmalen durch die Verwendung von an Drohnen montierten RGB-Kameras möglich war und dass die Genauigkeit der Ergebnisse für weitere quantitative genetische Analysen ausreichend ist. Allerdings waren die hier vorgestellten Ergebnisse durch die Anzahl der Beobachtungen zum Zeitpunkt der Merkmalszunahme stark eingeschränkt, denn um die Wachstumsdynamik aus Bilddaten zu extrahieren, ist eine zeitlich hochauflösende Datenerfassung entscheidend (AASEN et al. 2020). Die wöchentliche Überwachung der Merkmale in der Umgebung ergab nur 2-3 relevante Beobachtungen, die für die Wachstumsmodellierung verwendet werden konnten, bis eine Sättigung erreicht war, was nicht ausreichte, um die kleinen Merkmalsvariationen innerhalb der Population zu erkennen. Dennoch zeigen die Ergebnisse das Potenzial dieser Methode zur Erfassung der VCOV-Merkmale, insbesondere wenn die Überwachungsintervalle auf alle 2-3 Tage erhöht werden. Wenn nur die VCOV-Merkmale von Interesse sind, könnte eine kommerzielle RGB-Kamera mit ihrer einfacheren Datenverarbeitung und konsistenteren Ergebnissen eine bessere Wahl sein.

### 4.3 Ertragsvorhersage

Der Variationskoeffizient des im Feld bestimmten Ertrags war in HAL am höchsten und in IPK am niedrigsten, und auch die Ertragsvorhersage von Ansatz 1 zeigte die höchste Vorhersagekraft in HAL und die niedrigste in IPK (Abb. 4a), was darauf hindeutet, dass eine größere Variation des vorhergesagten Merkmals höhere  $r^2$ -Werte ermöglichen kann. Ähnliche Korrelationen wurden auch in anderen Studien zur Ertragsmodellierung festgestellt (OEHLISCHLAGER et al. 2018; GARCÍA-MARTÍNEZ et al. 2020; TAO et al. 2020). Ansatz 2, der aus einer Datenfusion mehrerer VIs, HEI- und VCOV-Informationen bestand, führte zu besseren Ertragsvorhersagemodellen in den multispektralen und auch RGB-Datensätze, was im Einklang mit den Ergebnissen weiterer Studien (GEIPEL et al. 2014; BENDIG et al. 2015; RISCHBECK et al. 2016) steht. Ansatz 3 zeigte die beste Vorhersagegenauigkeit mit der höchsten Genauigkeit in HAL, was mit einer höheren Variation der untersuchten Merkmale zusammenhängen könnte. Zum Beispiel war HAL die einzige Umgebung, in der keine Wachstumsregulatoren eingesetzt wurden, was zu einer größeren Merkmalsvariation in der Bestandshöhe und dem Zielmerkmal Parzellenertrag führte. In HERZIG et al. (2019) wurde ebenfalls festgestellt, dass die Variation des Zielmerkmals die Vorhersagegenauigkeit von Regressionsmodellen beeinflusst. Eine zunehmende Vorhersagegenauigkeit des Ertrags über die Vegetationsperiode hinweg konnte in einer Reihe von Studien ebenfalls beobachtet (YUE et al. 2017; HASSAN et al. 2019; TAO et al. 2020). Eine vertiefende Diskussion über die Ertragsmodelle und dessen Auswahl von Merkmalsgruppen und dessen Effektgrößen folgt in HERZIG et al. (2021).

Die anschließend durchgeführte Genotyp-Assoziationsstudie mit den Daten der Ertragsvorhersage konnte nur bei IPK signifikante Linien detektieren. Sechs der neun in den YLD<sub>GT</sub>-Daten entdeckten signifikanten Linien konnten auch in ZAHN et al. (2020) gefunden werden. Die Überlappung der detektierten signifikanten Linien zwischen YLD<sub>GT</sub> und dem multispektralen Datensatz nimmt mit höherem  $r^2$  zu und falsch-positive Linien wurden nur zwischen dem Beginn

und der mittleren Phase der Vegetationsperiode entdeckt, was darauf hindeutet, dass eine zunehmende Vorhersagegenauigkeit falsch-positive Entdeckungen verringert. Die Ergebnisse der Assoziationsstudie, insbesondere die der Modelle am Ende der Vegetationsperiode mit weniger falsch-positiven Linien, können für die Pflanzenzüchtung genutzt werden. Eine robuste und verbesserte Vorhersageleistung über mehrere Versuchsjahre und Umgebungen hinweg könnte genauere Assoziationsstudie mit weniger falsch-negativen Ergebnissen ermöglichen.

## 5 Schlussfolgerungen

Es wurde prognostiziert, dass die Fernerkundung mittels UAV ein wichtiges neues Instrument zur Unterstützung von Züchtern und Landwirten in der Präzisionslandwirtschaft sein wird, aber die vielversprechenden UAV-Anwendungen werden bisher nur langsam angenommen (FREEMAN & FREELAND 2015). Daher wurde in dieser Studie ein einfacher praktischer Ansatz zur objektiven und präzisen Phänotypisierung traditioneller und neuer Merkmale mit hohem Durchsatz verwendet, der auf dem methodischen Vergleich von zwei unterschiedlichen Kamerasystemen ausgestatteten UAVs beruht. Die hochauflösenden RGB-Bilder konnten, mit Hilfe des SfM-Algorithmus, dazu verwendet werden, um die relative Bestandshöhe mit hoher Präzision über die gesamte Vegetationsperiode zu extrahieren. Die Ergebnisse der Genotyp-Assoziationsstudie mit der hohen Überlappung signifikanter Linien von UAV-geschätzter Höhe und im Feld gemessener Höhe zeigen den praktischen Nutzen für die Pflanzenzüchtung. Die Bestimmung der Vegetationsbedeckung zu Beginn der Vegetationsperiode ist nur mit objektiver Sensortechnik möglich. Daher wurden RGB- und Multispektralbilder verwendet, um den prozentualen Anteil der Pflanzendecke innerhalb einer Parzelle zu ermitteln. Die Ergebnisse des RGB-Datensatzes zeigten eine präzisere und konsistentere Extraktion der VCOV über mehrere aufeinanderfolgende Flüge hinweg, so dass dieser für das Merkmal VCOV geeigneter ist als der multispektrale Datensatz.

Darüber hinaus ermöglicht die nicht-invasive UAV-Phänotypisierung Wachstumsanalysen und damit die Identifizierung von Genotyp-Assoziationen, was für die Merkmale Bestandshöhe und Vegetationsgrad erfolgreich durchgeführt wurde. Für diese Art der Anwendung ist es von entscheidender Bedeutung, das richtige Zeitintervall für die Phänotypisierung je nach Merkmal zu bestimmen. Das Phänotypisierungsintervall von 7 Tagen für das Merkmal Vegetationsbedeckung erwies sich als zu groß. Nichtsdestotrotz waren die Vegetationsbedeckung und die modellierte Bestandshöhe für die Ertragsprognose von Bedeutung. Die Fusion von spektralen Vegetationsindizes und räumlichen Merkmalen lieferte ergänzende Informationen für die Ertragsschätzung, was in zahlreichen Studien bestätigt wurde.

Insbesondere die auf den RGB-Bildern basierenden Ertragsmodelle konnten durch die räumlichen Merkmale verbessert werden, was dazu führte, dass die Vorhersageleistung beider Kamerasysteme auf dem gleichen Niveau lag.

Die Modellierung auf der Grundlage einzelner Zeitpunkte führte zu großen Unterschieden in der Vorhersageleistung über die Vegetationsperiode, während die Akkumulation von Zeitpunkten eine stetige Verbesserung der Vorhersagemodelle zeigte. Im Gegensatz dazu führte die Fusion von RGB- und Multispektraldatensätzen nicht zu einer Verbesserung der Ertragsvorhersage, was auf Redundanz in den Datensätzen hindeutet. Die Zusammenführung der Datensätze über

verschiedene Umgebungen hinweg führte zu einem allgemeinen Vorhersagemodell mit durchschnittlicher Genauigkeit für die drei Umgebungen. Um das volle Potenzial von UAV-Anwendungen auszuschöpfen und die Akzeptanz zu erhöhen, ist die Übertragbarkeit von Modellen auf unterschiedliche Jahre, Populationen und Standorte erforderlich. Um diese Qualität in der UAV-Fernerkundung zu erreichen, ist ein umfassendes und standardisiertes Datenerfassungs- und Modellierungsverfahren nötig, um allgemeine und genaue Ertragsvorhersagemodelle zu erstellen.

## 6 Literaturverzeichnis

- ASEN, H., KIRCHGESSNER, N., WALTER, A. & LIEBISCH, F., 2020: PhenoCams for Field Phenotyping: Using Very High Temporal Resolution Digital Repeated Photography to Investigate Interactions of Growth, Phenology, and Harvest Traits. *Front Plant Sci*, **11**: 593.
- ACRECHE, M. M., BRICENO-FELIX, G., SANCHEZ, J. A. M. & SLAFER, G. A., 2008: Physiological bases of genetic gains in Mediterranean bread wheat yield in Spain. *Eur J Agron*, **28**: 162-170.
- ARAUS, J. L. & CAIRNS, J. E., 2014: Field high-throughput phenotyping: the new crop breeding frontier. *Trends in plant science*, **19**: 52-61.
- BABAR, M. A., REYNOLDS, M. P., VAN GINKEL, M., KLATT, A. R., RAUN, W. R. & STONE, M. L., 2006: Spectral reflectance indices as a potential indirect selection criteria for wheat yield under irrigation. *Crop Sci*, **46**: 578-588.
- BALLESTEROS, R., ORTEGA, J. F., HERNANDEZ, D. & MORENO, M. A., 2018: Onion biomass monitoring using UAV-based RGB imaging. *Precis Agric*, **19**: 840-857.
- BARETH, G., BENDIG, J., TILLY, N., HOFFMEISTER, D., AASEN, H. & BOLTEN, A., 2016: A Comparison of UAV- and TLS-derived Plant Height for Crop Monitoring: Using Polygon Grids for the Analysis of Crop Surface Models (CSMs). *Photogramm Fernerkun*: 85-94.
- BATES, D., KLIEGL, R., VASISHTH, S. & BAAYEN, H., 2018: Parsimonious Mixed Models. *arXiv preprint arXiv:1506.04967*.
- BENDIG, J., BOLTEN, A., BENNERTZ, S., BROSCHEIT, J., EICHFUSS, S. & BARETH, G., 2014: Estimating Biomass of Barley Using Crop Surface Models (CSMs) Derived from UAV-Based RGB Imaging. *Remote Sensing*, **6**: 10395-10412.
- BENDIG, J., YU, K., AASEN, H., BOLTEN, A., BENNERTZ, S., BROSCHEIT, J., GNYP, M. L. & BARETH, G., 2015: Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *Int J Appl Earth Obs*, **39**: 79-87.
- BREIMANN, L., 2001: Random Forests. *Machine Learning*, 45.
- BRENNING, A., 2008: Statistical geocomputing combining R and SAGA: The example of landslide susceptibility analysis with generalized additive models. *Hamburger Beiträge zur Physischen Geographie und Landschaftsökologie*, **19**(23-32), 410
- BRIEN, C., JEWELL, N., WATTS-WILLIAMS, S. J., GARNETT, T. & BERGER, B., 2020: Smoothing and extraction of traits in the growth analysis of noninvasive phenotypic data. *Plant Methods*, **16**: 36.
- DUNNETT, C. W., 1955: A Multiple Comparison Procedure for Comparing Several Treatments with a Control. *J Am Stat Assoc*, **50**: 1096-1121.



- FERNANDEZ-GALLEGO, J. A., LOOTENS, P., BORRA-SERRANO, I., DERYCKE, V., HAESAERT, G., ROLDAN-RUIZ, I., ARAUS, J. L. & KEFAUVER, S. C., 2020: Automatic wheat ear counting using machine learning based on RGB UAV imagery. *The Plant journal for cell and molecular biology*, **103**: 1603-1613.
- FREEMAN, P. K. & FREELAND, R. S., 2015: Agricultural UAVs in the U.S.: potential, policy, and hype. *Remote Sensing Applications: Society and Environment*, **2**: 35-43.
- GARCÍA-MARTÍNEZ, H., FLORES-MAGDALENO, H., ASCENCIO-HERNÁNDEZ, R., KHALIL-GARDEZI, A., TIJERINA-CHÁVEZ, L., MANCILLA-VILLA, O. R. & VÁZQUEZ-PEÑA, M. A., 2020: Corn Grain Yield Estimation from Vegetation Indices, Canopy Cover, Plant Density, and a Neural Network Using Multispectral and RGB Images Acquired with Unmanned Aerial Vehicles. *Agriculture*, **10**(7), 277.
- GEIPEL, J., LINK, J. & CLAUPEIN, W., 2014: Combined Spectral and Spatial Modeling of Corn Yield Based on Aerial Images and Crop Surface Models Acquired with an Unmanned Aircraft System. *Remote Sensing*, **6**: 10335-10355.
- GOWEN, A.A., TAGHIZADEH, M. & O'DONNELL, C.P., 2013: Using Hyperspectral Imaging for Quality Evaluation of Mushrooms. *Hyperspectral imaging for food quality analysis and control*, 403-430.
- GRENZDÖRFFER, G. J., 2014: Crop height determination with UAS point clouds. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, **XL-1**: 135-140.
- GRIEDER, C., HUND, A. & WALTER, A., 2015: Image based phenotyping during winter: a powerful tool to assess wheat genetic variation in growth response to temperature. *Funct Plant Biol*, **42**: 387-396.
- HAN, L., YANG, G., DAI, H., XU, B., YANG, H., FENG, H., LI, Z. & YANG, X., 2019: Modeling maize above-ground biomass based on machine learning approaches using UAV remote-sensing data. *Plant Methods*, **15**: 10.
- HASSAN, M. A., YANG, M., RASHEED, A., YANG, G., REYNOLDS, M., XIA, X., XIAO, Y. & HE, Z., 2019: A rapid monitoring of NDVI across the wheat growth cycle for grain yield prediction using a multi-spectral UAV platform. *Plant Sci*, **282**: 95-103.
- HERZIG, P., BACKHAUS, A., SEIFFERT, U., WIREN, N. VON, PILLEN, K. & MAURER, A., 2019: Genetic dissection of grain elements predicted by hyperspectral imaging associated with yield-related traits in a wild barley NAM population. *Plant Sci*, **285**: 151-164.
- HERZIG, P., BORRMANN, P., KNAUER, U., KLÜCK, H.-C., KILIAS, D., SEIFFERT, U., PILLEN, K. & MAURER, A., 2021: Evaluation of RGB and Multispectral Unmanned Aerial Vehicle (UAV) Imagery for High-Throughput Phenotyping and Yield Prediction in Barley Breeding. *Remote Sensing*, **13**: 2670.
- HIJMANS, R. J., 2020: Package 'raster' - Geographic Data Analysis and Modeling.
- HOFFMANN, A., MAURER, A. & PILLEN, K., 2012: Detection of nitrogen deficiency QTL in juvenile wild barley introgression lines growing in a hydroponic system. *BMC genetics*, **13**: 88.
- HONSDORF, N., MARCH, T. J., BERGER, B., TESTER, M. & PILLEN, K., 2014a: High-throughput phenotyping to detect drought tolerance QTL in wild barley introgression lines. *PloS one*, **9**: e97047.

- HONSDORF, N., MARCH, T. J., HECHT, A., EGLINTON, J. & PILLEN, K., 2014b: Evaluation of juvenile drought stress tolerance and genotyping by sequencing with wild barley introgression lines. *Mol Breeding*, **34**: 1475-1495.
- HONSDORF, N., MARCH, T. J. & PILLEN, K., 2017: QTL controlling grain filling under terminal drought stress in a set of wild barley introgression lines. *PloS one*, **12**: e0185983.
- HOTHORN, T., BRETZ, F. & WESTFALL, P., 2008: Simultaneous inference in general parametric models. *Biom J*, **50**: 346-363.
- KIM, S. L., CHUNG, Y. S., JI, H., LEE, H., CHOI, I., KIM, N., LEE, E., OH, J., KANG, D. Y., BAEK, J., LEE, G. S., KWON, T. R. & KIM, K. H., 2019: New Parameters for Seedling Vigor Developed via Phenomics. *Applied Sciences*, **9**(9), 1752.
- KUHN, M. & WICKHAM, H., 2020: Tidymodels: Easily Install and Load the 'Tidymodels' Packages. R package version 0.1.2.
- LANDINI, G., RANDELL, D. A., FOUAD, S. & GALTON, A., 2017: Automatic thresholding from the gradients of region boundaries. *J Microsc*, **265**: 185-195.
- LI, B., XU, X., ZHANG, L., HAN, J., BIAN, C., LI, G., LIU, J. & JIN, L., 2020: Above-ground biomass estimation and yield prediction in potato by using UAV-based RGB and hyperspectral imaging. *ISPRS Journal of Photogrammetry and Remote Sensing*, **162**: 161-172.
- LIAKOS, K. G., BUSATO, P., MOSHOU, D., PEARSON, S. & BOCHTIS, D., 2018: Machine Learning in Agriculture: A Review. *Sensors*, **18**(8), 2674.
- LIEBISCH, F., KIRCHGESSNER, N., SCHNEIDER, D., WALTER, A. & HUND, A., 2015: Remote, aerial phenotyping of maize traits with a mobile multi-sensor approach. *Plant Methods*, **11**: 9.
- LIU, J. G. & PATTEY, E., 2010: Retrieval of leaf area index from top-of-canopy digital photography over agricultural crops. *Agr Forest Meteorol*, **150**: 1485-1490.
- MARCIAL-PABLO, M. D. J., GONZALEZ-SANCHEZ, A., JIMENEZ-JIMENEZ, S. I., ONTIVEROS-CAPURATA, R. E. & OJEDA-BUSTAMANTE, W., 2018: Estimation of vegetation fraction using RGB and multispectral images from UAV. *Int J Remote Sens*, **40**: 420-438.
- NEBIKER, S., LACK, N., ABÄCHERLI, M. & LÄDERACH, S., 2016: Light-Weight Multispectral Uav Sensors and Their Capabilities for Predicting Grain Yield and Detecting Plant Diseases. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, **XLI-B1**: 963-970.
- OEHLSCHLAGER, J., SCHMIDHALTER, U. & NOACK, P. O., 2018: UAV-Based Hyperspectral Sensing for Yield Prediction in Winter Barley: 1-4.
- OTSU, N., 1979: A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, **9**: 62-66.
- PASK, A., PIETRAGALLA, J., MULLAN, D. M. & REYNOLDS, M. P., 2012: *Physiological Breeding II: A Field Guide to Wheat Phenotyping*.
- R CORE TEAM, 2020: *R: A Language and Environment for Statistical computing*, Foundation for Statistical Computing.
- REYNOLDS, M., CHAPMAN, S., CRESPO-HERRERA, L., MOLERO, G., MONDAL, S., PEQUENO, D. N. L., PINTO, F., PINERA-CHAVEZ, F. J., POLAND, J., RIVERA-AMADO, C., SAINT PIERRE, C. & SUKUMARAN, S., 2020: Breeder friendly phenotyping. *Plant Sci*, **295**: 110396.

- REYNOLDS, M. P., RAJARAM, S. & SAYRE, K. D., 1999: Physiological and Genetic Changes of Irrigated Wheat in the Post-Green Revolution Period and Approaches for Meeting Projected Global Demand. *Crop Sci*, **39**: 1611-1621.
- RISCHBECK, P., ELSAYED, S., MISTELE, B., BARMEIER, G., HEIL, K. & SCHMIDHALTER, U., 2016: Data fusion of spectral, thermal and canopy height parameters for improved yield prediction of drought stressed spring barley. *Eur J Agron*, **78**: 44-59.
- SADRAS, V. O. & LAWSON, C., 2011: Genetic gain in yield and associated changes in phenotype, trait plasticity and competitive ability of South Australian wheat varieties released between 1958 and 2007. *Crop Pasture Sci*, **62**: 533-549.
- SCHMALENBACH, I., KORBER, N. & PILLEN, K., 2008: Selecting a set of wild barley introgression lines and verification of QTL effects for resistance to powdery mildew and leaf rust. *TAG. Theoretical and applied genetics. Theoretische und angewandte Genetik*, **117**: 1093-1106.
- SCHMALENBACH, I., LEON, J. & PILLEN, K., 2009: Identification and verification of QTLs for agronomic traits using wild barley introgression lines. *TAG. Theoretical and applied genetics. Theoretische und angewandte Genetik*, **118**: 483-497.
- SILVA-PEREZ, V., MOLERO, G., SERBIN, S. P., CONDON, A. G., REYNOLDS, M. P., FURBANK, R. T. & EVANS, J. R., 2018: Hyperspectral reflectance as a tool to measure biochemical and physiological traits in wheat. *Journal of experimental botany*, **69**: 483-496.
- TAO, H., FENG, H., XU, L., MIAO, M., YANG, G., YANG, X. & FAN, L., 2020: Estimation of the Yield and Plant Height of Winter Wheat Using UAV-Based Hyperspectral Images. *Sensors*, **20**(4), 1231.
- TARDIEU, F., CABRERA-BOSQUET, L., PRIDMORE, T. & BENNETT, M., 2017: Plant Phenomics, From Sensors to Knowledge. *Curr Biol*, **27**: R770-R783.
- ULLMAN, S., 1979: The interpretation of structure from motion. *Proc R Soc Lond B Biol Sci*, **203**: 405-426.
- WANG, G., SCHMALENBACH, I., KORFF, M. VON, LEON, J., KILIAN, B., RODE, J. & PILLEN, K., 2010a: Association of barley photoperiod and vernalization genes with QTLs for flowering time and agronomic traits in a BC2DH population and a set of wild barley introgression lines. *TAG. Theoretical and applied genetics. Theoretische und angewandte Genetik*, **120**: 1559-1574.
- WANG, J. M., YANG, J. M., MCNEIL, D. L. & ZHOU, M. X., 2010b: Identification and molecular mapping of a dwarfing gene in barley (*Hordeum vulgare* L.) and its correlation with other agronomic traits. *Euphytica*, **175**: 331-342.
- YUE, J. B., YANG, G. J., LI, C. C., LI, Z. H., WANG, Y. J., FENG, H. K. & XU, B., 2017: Estimation of Winter Wheat Above-Ground Biomass Using Unmanned Aerial Vehicle-Based Snapshot Hyperspectral Sensor and Crop Height Improved Models. *Remote Sensing*, **9**(7), 708 9.
- ZAHN, S., KOBLENZ, B., CHRISTEN, O., PILLEN, K. & MAURER, A., 2020: Evaluation of wild barley introgression lines for agronomic traits related to nitrogen fertilization. *Euphytica*, **216**.