



25. Workshop Computer-Bildanalyse in der Landwirtschaft

17. April 2019, Bonn



Bornimer Agrartechnische Berichte

Heft 102

Potsdam / Bonn 2019

25. Workshop Computer-Bildanalyse in der Landwirtschaft

17. April 2019, Bonn



Bornimer Agrartechnische Berichte
Heft 102

Potsdam / Bonn 2019

Herausgeber:

Leibniz-Institut für Agrartechnik und Bioökonomie e.V.
Max-Eyth-Allee 100
D-14469 Potsdam
Tel.: (0331)-5699-0
Fax.: (0331)-5699-849
E-mail: atb@atb-potsdam.de
Internet: <http://www.atb-potsdam.de>

April 2019

Redaktion:

Michael Pflanz
Jan Behmann
Lasse Klingbeil
Michael Schirrmann
Marius Hobart
Ulrike Praeger

Typografische Gestaltung:

Beate Spehr

Der Text dieser Publikation wird unter der Lizenz Creative Commons Namensnennung 4.0 International (CC BY 4.0) veröffentlicht. Den vollständigen Lizenztext finden Sie unter:
<https://creativecommons.org/licenses/by/4.0/legalcode>

Herausgegeben vom Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB) mit Förderung durch das Bundesministerium für Ernährung und Landwirtschaft (BMEL) und das Ministerium für Wissenschaft, Forschung und Kultur des Landes Brandenburg (MWFK).

Für den Inhalt der Beiträge zeichnen die Autoren verantwortlich.

Eine Weiterveröffentlichung von Teilen ist unter Quellenangabe und mit Zustimmung des Leibniz-Instituts für Agrartechnik und Bioökonomie e.V. möglich.

ISSN 0947-7314

© Leibniz-Institut für Agrartechnik und Bioökonomie e.V., 2019

Inhalt

Grusswort	6
Geleitwort	7
Aussteller:	
• CiS GmbH, Rostock	8
• geo-konzept GmbH, Adelschlag	9
• Oceanoptics BV, Ostfildern	10
• insensiv GmbH, Bielefeld	11
• HAIP, Hannover	12
Programm	13
Detektion von Weintrauben in Bildern mit Hilfe von Fully Convolutional Neural Nets	
<i>Laura Zabawa, Anna Kicherer, Lasse Klingbeil, Andres Milioto, Ribana Roscher, Reinhard Töpfer, Heiner Kuhlmann</i>	15
Automatische Baumidentifizierung und Baumhöhenbestimmung zur Erstellung präziser Applikationskarten	
<i>Marius Hobart, Michael Schirrmann, Michael Pflanz</i>	21
Tiefenbezogene, feldbasierte Bodenfeuchtemessung mit Hilfe von NIR-Spektroskopie	
<i>Julian Walter Beck, Marc Heinrich, Stefan Hinck, Vadim Tsukor, Walter Nietfeld, Arno Ruckelshausen</i>	29
Drone-based Land Surface Temperature Retrieval of Agricultural Areas	
<i>Sascha Heinemann, Bastian Siegmann, Uwe Rascher</i>	37
Felddetektion von Blattkrankheiten des Weizens mit Hyperspektralsensoren	
<i>David Bohnenkamp, Jan Behmann, Anne-Katrin Mahlein</i>	39
Erfassung der Vitalität des Deutschen Weidelgrases mit Hilfe von RGB- und NIR-Aufnahmen	
<i>Sandra Münzel, Oswald Blumenstein</i>	44
Detection of Rhizoctonia solani in sugar beet from leaves hyperspectral images on a single plant scale	
<i>Abel Barreto, Stefan Paulus, Mark Varrelmann, Anne-Katrin Mahlein</i>	55
Validierung der teilflächenspezifischen Ertragsprognose auf Basis maschinellen Lernens mit realen Ertragsmessungen auf einem Ackerbaubetrieb	
<i>Sebastian Jerratsch, Andreas Walter Heckmann, Stefan Paulus, Steffen Herbold</i>	62

Herausforderungen und Einschränkungen bei hyperspektralen Messungen im UV-Bereich	
<i>Anna Brugger, Jan Behmann, Stefan Paulus, Ulrike Steiner, Anne-Katrin Mahlein</i>	70
Erkennung von Bodensignalen in 3D Punktwolken einer Apfelplantage	
<i>Kowshik K. Saha, Nikolaos Tsoulas, Manuela Zude-Sasse</i>	76
Validating the accuracy of 3D point cloud reconstruction on standard box and fruit trees in the field	
<i>Nikolaos Tsoulas, Dimitrios S. Paraforos, Spyros Fountas, Manuela Zude-Sasse</i>	84
Ermittlung geeigneter Wellenlängen für das automatische Klassifizieren von Pflanzen und Früchten	
<i>Joachim Intreß und Martin Geyer</i>	86
Automatisierte flugrobotergestützte Unkrautererkennung als Voraussetzung für eine teilflächenspezifische Herbizidbehandlung im Ackerbau	
<i>Michael Pflanz, Michael Schirrmann, Christina Wellhausen, Henning Nordmeyer</i>	95
Low-cost Drohnen Einsatz zur Erkennung von Wurzelunkräutern On-farm	
<i>Maike Krauss, Christoph Hofstetter, Hansueli Dierauer, Frank Liebisch</i>	107
UAV based assessment of influence factors on canopy height and lodging severity using an objective threshold approach	
<i>Norman Wilke, Bastian Siegmann, Lasse Klingbeil, Andreas Burkart, Sascha Heinemann, Uwe Rascher</i>	116
Methode zur Erfassung von Anbaugeräten durch Sensorfusion von Laserdistanzsensoren und Kameras für autonome Kupplungsvorgänge	
<i>Julius Kirfel, Tristan Igelbrink, Jan Roters, Arno Ruckelshausen</i>	118
Multi-wavelength laser line profiling (MWLP) System zur feldbasierten Bestimmung von 3D Strukturen, spektralen Eigenschaften und Wachstumsparametern von Pflanzen	
<i>Christian Scholz, Matthias Igelbrink, Wolfram Strothmann, Arno Ruckelshausen</i>	127
Einsatz von Deep Learning zur Klassifikation landwirtschaftlicher Kulturen auf Basis hyperspektraler Fernerkundungsdaten	
<i>Lucas Wittstruck, Thomas Jarmer und Martin Kanning</i>	136
Quantifying of Wheat Resistance to <i>Fusarium</i> Head Blight with Hyperspectral Imaging	
<i>Elias Alisaac, Jan Behmann, Matheus T. Kuska, Heinz-W. Dehne, Anne-Katrin Mahlein</i>	144
Hyperspektrale Erfassung eines mit unterschiedlichen Wirtschaftsdüngern aus Miscanthus-Häckselgut versorgten Wintergerstenbestandes zum Zeitpunkt der Vollreife	
<i>Michael Stotter, Martin Hamer, David Bohnenkamp, Jan Behmann, Kevin Leitenberger, Ralf Pude</i>	151

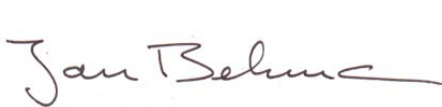
Erkennung und Zählung von Weizenähren mit Hilfe von bodengestützten Bildaufnahmen	
<i>Jana Kierdorf, Laura Zabawa, Lukas Lucks, Lasse Klingbeil, Heiner Kuhlmann</i>	158
UAV-based Field Monitoring for Precision Farming	
<i>Philipp Lottes, Nived Chebrolu, Frank Liebisch and Cyrill Stachniss</i>	168
Biomasseabschätzung im Feldfutterbau mittels SfM-gestützter RGB-Aufnahmen	
<i>Esther Grüner, Thomas Astor, Michael Wachendorf</i>	177
Kombinierbares Routensystem für UAS	
<i>Mirko Bothe, Ludwig Schrenk</i>	182
Unsupervised clustering of remote sensing data from kiwifruit (<i>A. deliciosa</i> <i>var. Hayward</i>) orchards affected by kiwifruit decline	
<i>Francesco Savian, Marta Martini, Paolo Ermacora, Luca Zuliani, Stefan Paulus and Anne-Katrin Mahlein</i>	189
Berechnung des <i>Morisita-Index of dispersion</i> in digitalisierten Feldaufnahmen	
<i>Michael Pflanz und Hannes Hegewald</i>	199
In der Reihe Bornimer Agrartechnische Berichte	
sind bisher erschienen	204

Grusswort

Dass die landwirtschaftliche Produktion vor großen Herausforderungen steht, wird wahrscheinlich seit dem Beginn der Workshopreihe Computer-Bildanalyse (CBA) im Jahre 1995 proklamiert. Doch nie zuvor waren die Veränderungen, die die Digitalisierung und die hohe Verfügbarkeit kostengünstiger neuer Technologien und Sensoren mit sich bringen, so spürbar und zum Greifen nah wie heute. Sie versprechen dabei, die Anforderungen der Zukunft zumindest in Teilen zu lösen. Sensoren stellen seither eine wichtige Verknüpfung zwischen Realität und Computermodell dar, wobei Kameras als günstige und hochauflösende Sensoren inzwischen verstärkt zum Einsatz kommen.

Der Workshop „Computer und Bildanalyse in der Landwirtschaft“ ist seit vielen Jahren eine feste Größe im Jahresablauf. Hier präsentieren und diskutieren Experten aus Wissenschaft und Praxis die neusten Erkenntnisse an der Schnittstelle verschiedener Disziplinen. Wir freuen uns, Sie in diesem Jahr auf dem Forschungscampus Klein-Altendorf der Universität Bonn begrüßen zu dürfen. Auch in diesem Jahr konnten wir aus den zahlreichen Einsendungen ein vielfältiges Programm gestalten, das den Stand der Forschung widerspiegelt: Von vollautomatischen Verfahren zur quantitativen Erfassung von Feldfrüchten für den Bereich der Präzisionslandwirtschaft, über Anwendungen von fliegenden Sensorplattformen zur Erfassung von sichtbaren und unsichtbaren Bestandesparametern, Verfahren zur Krankheitsdetektion basierend auf hyperspektralen Reflektanzmustern bis hin zu neuen Ansätzen für die effiziente Auswertung aktuell verfügbarer Fernerkundungsdaten.

Der diesjährige Workshop in Bonn bereichert das seit Anfang des Jahres geförderte Exzellenzcluster *Phenorob – Robotics and Phenotyping for Sustainable Crop Production*. Der Cluster kombiniert die Expertise aus Agrarwissenschaften, Geodäsie und Informatik, um die Fähigkeiten sowohl fahrender und fliegender Roboter als auch präzidierender Modelle voranzutreiben. Diese ertragreiche Kooperation spiegelt sich gleichermaßen im diesjährigen Organisationsteam wieder. Der 25. CBA-Workshop wird von der Arbeitsgruppe INRES Pflanzenkrankheiten und Pflanzenschutz sowie der IGG Geodäsie in enger Kooperation organisiert. Wie seit vielen Jahren hat das Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB) in Potsdam die Organisation getragen und durch Rat und Tat begleitet. Den Verantwortlichen wollen wir für die langjährige und kontinuierliche Begleitung und Erhaltung der noch immer relevanten Veranstaltung danken. Außerdem danken wir den vielen Helfern und Helferinnen der Uni Bonn, die diesen Workshop erst möglich gemacht haben. Ganz entscheidend waren natürlich Ihre Beiträge, die einen fachlich fundierten Tagungsband und ein interessantes Programm entstehen ließen. In diesem Sinne wünschen wir Ihnen einen spannenden Tag mit aufschlussreichen Diskussionen, außergewöhnlichen Einblicken in die aktuelle Forschung und nicht zuletzt viel Spaß am Forschungscampus Klein-Altendorf.



Jan Behmann



Lasse Klingbeil



Michael Pflanz

Geleitwort



„Angestoßen von der Bundessenatsarbeitsgruppe II – Qualitätsgerechte und umweltverträgliche Agrarproduktion, übernahm das Institut für Agrartechnik Potsdam-Bornim die Aufgabe, im Jahre 1995 einen Workshop zur Anwendung computergestützter Bildanalyseverfahren in der Landwirtschaft zu organisieren. Die Festlegung auf eine eintägige und kostengünstige Veranstaltung trug dazu bei, dass sich zu diesem spannenden Arbeitsgebiet erfolgreich eine jährlich stattfindende Workshopreihe entwickelte.“

Dr. Bernd Herold, Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB)




„Der Charme dieser Workshop-Reihe liegt darin, neue, vielfach unkonventionelle Ideen und Ansätze in einem frühen Forschungsstadium mit einer überschaubaren Zahl von Fachkollegen zu diskutieren. Auch die landtechnische Industrie entsendet seit einigen Jahren regelmäßig ihre Entwickler als Zuhörer zu den Workshops.“

Dipl.-Inform. Martin Kraft, Thünen-Institut



„Das Gebiet der Computer-Bildanalyse allgemein und insbesondere in der Landwirtschaft hat sich über die Jahre stark weiterentwickelt von einfachen, regelbasierten Ansätzen hin zu Methoden der Künstlichen Intelligenz, z.B. neuronale Netze, und der Geoinformatik unter Einsatz von Flug- und anderen Robotern. Wir freuen uns mit dem 22. Workshop in Wernigerode 2016 ein Teil dieser Geschichte gewesen zu sein und wünschen der Workshop-Serie weiterhin viel Erfolg.“

Prof. Dr. Frieder Stolzenburg und Prof. Dr. Hardy Pundt, Hochschule Harz



„Bildverarbeitung hat sich von einem ‘Orchideen-Thema’ zu einer ‘Hauptkultur-Technik’ in den Agrarwissenschaften entwickelt. Die CBA-Workshop-Reihe hat über die Jahre hinweg viel zu dieser Entwicklung beigetragen. Wir sind stolz, dass auch die ETH Zürich ihren Anteil daran leisten konnte und wir sind überzeugt, dass die Bildanalyse eine Schlüsseltechnik zur Erhöhung der Nachhaltigkeit in der Landwirtschaft darstellt.“

Prof. Dr. Achim Walter, Dr. Frank Liebisch und Dr. Norbert Kirchgessner, ETH Zürich



„Der CBA Workshop unterstützt das Ziel der nachhaltigen Intensivierung in der Produktion frischer Lebensmittel, wobei die Gewinnung von ertragsrelevanten Pflanzeninformationen aus Sensorsignalen, um das Ernteprodukt und die Produktionssysteme besser zu beschreiben und präzise zu steuern, spannende Aufgaben sind. Vielen Dank dafür!“

Dr. habil. Manuela Zude,
Leibniz-Institut für Agrartechnik und Bioökonomie e. V. (ATB)

Variable Hochleistungs-UAS

(45 min, mit Geländemodell)

Diverse Kamera- und Sensorsysteme

2- und 3D-Software für Flugplanung

Flug und Flugauswertung

Applikationen

Individuelle Anpassungen



[CiS-rostock.de](http://cis-rostock.de)



MiniGIS-Counting



UAV-Bilder selbstständig und automatisiert auswerten

Mit MiniGIS-Counting ist im Versuchswesen die Auswertung von hochgenauen Luftbildern möglich. Sie können den Aufgang von Einzelpflanzen objektiv überprüfen oder den Bedeckungsgrad exakt bestimmen. Die weitere Analyse von Ernteprodukten kann u. a. im Gemüsebau genutzt werden.



Vorteile

- Objektive Ergebnisse schnell erzielen
- Dokumentierbare und überprüfbare Resultate
- Unabhängig von UAV- oder Sensorhersteller
- Frei konfigurierbare Software
- Kein Internetzugriff notwendig
- RGB- oder Multispektraldaten möglich

Sprechen Sie uns an! Wir beraten Sie gerne zu Ihren speziellen Anwendungen im Versuchswesen, Gemüsebau oder in Sonderkulturen: Exakt abgestimmt auf Ihre Wünsche!



UNLOCK THE UNKNOWN

ASK

APPLIED SPECTRAL KNOWLEDGE

Equipping people to solve the greatest challenges
for a safer, cleaner, healthier future.



THE END OF GUESSING

www.oceanoptics.com


info@oceanoptics.com • US +1 727-733-2447 • EUROPE +31 26-3190500 • ASIA +86 21-6295-6600

PODCOPTER

KABELGEBUNDENE DROHNE ALS SENSOR-TRÄGERPLATTFORM

Der PodCopter nutzt Bildverarbeitung zum dauerhaften und autonomen Steuern und fliegt zeitlich unbegrenzt in vorgegebener Position zum Fahrzeug. Dies ermöglicht einen Einsatz von vielseitiger Sensorik.

- Automatisierter Start, Flug und Landevorgang
- Automatische Positionierung zum Fahrzeug auch während der Fahrt
- 100% autonom fliegendes System
- Individuelle Positionsvorgabe durch Fahrzeugführer je nach Anwendung
- Unbegrenzte Flugzeit durch Spannungsversorgung via Kabel



Technische Daten:

PodCopter:

- Maße: 105 x 105 x 50 cm
- Gewicht: 6 kg
- Aufbau: Kohlefaser Monocoque
- Zuladungsgewicht Sensorik: 1,5 kg
- Kabellänge: ab 28 m (bis 60 m möglich)
- Fahrgeschwindigkeit: bis 20 km/h
- Bildübertragung & Steuerregulation über Kabel (abhörsicher)

Landeplattform:

- Maße: 110 x 110 x 30 cm
- Gewicht: 50 kg
- Stromanschluss: 12 V / 100 A

Anwendungsbereiche Security:

- Universell einsetzbar für Kameras in der Außenüberwachung
 - **Sicherung von Grenzbereichen & Perimeterschutz**
 - **Überwachung von Sicherheitsbereichen** z.B. Unfallorte
 - **Videoüberwachung** z. B. Großveranstaltungen
- verwendbare Sensoren (auch in Kombination):
 - Wärmebildkamera
 - Zoomkamera
 - 3D Stereokamera

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages


insensiv GmbH
Auf dem Esch 28
D-33619 Bielefeld
Tel: +49 (0) 521 - 32 99 47 - 0
info@insensiv.de
www.insensiv.de





HAIP

Hyperspectral Agricultural Imaging Platform

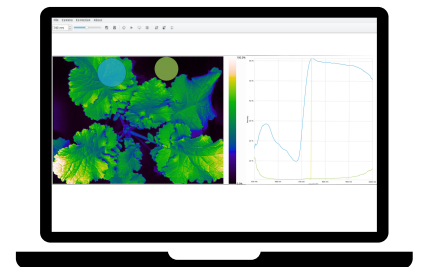


Hyperspektrale Analysebox

Mit der von HAIP entwickelten Box können hochaufgelöste Hyperspektralbilder in kontrollierter Umgebung aufgenommen werden. Durch einen einfachen und intuitiven Workflow bietet diese Lösung die Möglichkeit, große Datensätze in kurzer Zeit aufzubauen.

Auswertungssoftware

HAIP bietet eine Softwarelösung zur Aufnahme und Analyse von Hyperspektraldaten. Es lassen sich Hyperspektralaufnahmen anschaulich darstellen und gezielt Informationen extrahieren, z.B. in Form von Indizes.



Hyperspektrale Drohnensysteme

Zur hochaufgelösten Aufnahme von Hyperspektraldaten in der Fläche bietet HAIP ein leichtes und kompaktes System aus Hyperspektralkamera und Drohne. Mit einem Gesamtgewicht von unter 5 kg wird keine Aufstiegserlaubnis benötigt. Damit wird der Aufwand zur Erstellung von hyperspektralen Karten so gering wie möglich gehalten.



Räumliche Auflösung: 1280 px * 960 px

Wellenlängen: 500 nm bis 1000 nm

Spektrale Auflösung: 1 nm

Website:

www.haip-solutions.com

Email:

contact@haip-solutions.com

Adresse:

HAIP / Kopernikusstr. 14 / 30167 Hannover



Computer-Bildanalyse in der Landwirtschaft 2019, Universität Bonn

Programm, 17.04.2019, Forum, Campus Klein-Altendorf Nord

Zeit	Titel	Person
8:30-9:00	Registrierung	
9:00-9:10	Begrüßung	Heiner Kuhlmann, Uni Bonn
9:10-9:30	Keynote: Exzellenz-Cluster Phenorob	Heiner Kuhlmann, Uni Bonn
9:30-10:30	Session 1: Precision Agriculture	Jan Behmann, Uni Bonn
	Automatisierte flugrobotergestützte Unkrautererkennung als Voraussetzung für eine teilflächenspezifische Herbizidbehandlung im Ackerbau	Michael Pflanz, JKI
	Erkennung und Zählung von Weizenähren mit Hilfe von bodengestützten Bildaufnahmen	Jana Kierdorf, Uni Bonn
	Detection of grapevine in images using Fully Convolutional Neural Nets	Laura Zabawa, Uni Bonn
10:30-10:50	Kaffeepause	
10:50-11:50	Session 2: Fliegende Sensorplattformen	Lasse Klingbeil, Uni Bonn
	UAV-basierte Feld Überwachung für Applikationen in der Präzisionslandwirtschaft	Philipp Lottes, Uni Bonn
	UAV based assessment of influence factors on canopy height and lodging severity using an objective threshold approach	Norman Wilke, FZ Jülich
	Drone-based Land Surface Temperature Retrieval of Agricultural Areas	Sascha Heinemann, FZ Jülich/Uni Bonn
11:50-12:10	Postervorstellung: Impulsvorträge (Eine Minute auf einer Folie)	Lasse Klingbeil, Uni Bonn
12:10-13:00	Mittagessen	
13:00-14:20	Session 3: Pflanzenschutz und Sensorik	Michael Pflanz, ATB Potsdam
	Felddetektion von Gelbrost und Braunrost des Weizens mit Hyperspektralsensoren	David Bohnenkamp, Uni Bonn
	Quantifying of Wheat Resistance to Fusarium Head Blight with Hyperspectral Imaging	Elias Alisaac, Uni Bonn
	Ermittlung geeigneter Wellenlängen für das automatische Klassifizieren von Pflanzen und Früchten	Joachim Intreß, ATB Potsdam
	Multi-wavelength laser line profiling (MWLP) System zur feldbasierten Bestimmung von 3D Strukturen, spektralen Eigenschaften und Wachstumsparametern von Pflanzen	Christian Scholz, HS Osnabrück

14:20-14:40	Kaffeepause	
14:40-16:00	Session 4: Robotik und Fernerkundung	Stefan Paulus, IfZ Göttingen
	Validating the accuracy of 3D point cloud reconstruction on standard box and fruit trees in the field	Nikos Tsoulias, ATB Potsdam
	Methode zur Erfassung von Anbaugeräten durch Sensorfusion von Laserdistanzsensoren und Kameras für autonome Kupplungsvorgänge	Julius Kirfel, HS Osnabrück
	Wheat crop prediction through satellite images	Sebastian Jerratsch, Uni Göttingen
	Einsatz von Deep Learning zur Klassifikation landwirtschaftlicher Kulturen auf Basis hyperspektraler Fernerkundungsdaten	Lucas Wittstruck, Uni Osnabrück
16:00-17:30	Führung: Forschungsstation Klein-Altendorf	Torsten Kraska, Uni Bonn
17:30	Umtrunk	

Poster

	Titel	Person
	Herausforderungen und Einschränkungen bei hyperspektralen Messungen im UV-Bereich	Anna Brugger, Uni Bonn
	Removing ground point from 3D point cloud in apple orchard	Nikos Tsoulias, ATB Potsdam
	Low-cost Drohnen Einsatz zur Erkennung von Wurzelunkräutern On-farm	Maike Krauss, FiBL
	Hyperspektrale Erfassung eines mit unterschiedlichen Wirtschaftsdüngern aus Miscanthus-Häckselgut versorgten Wintergerstenbestandes zum Zeitpunkt der Vollreife	Michael Stotter, HS Bonn Rhein-Sieg
	Erfassung der Vitalität des Deutschen Weidelgrases mit Hilfe von RGB- und NIR-Aufnahmen	Sandra Münzel, Uni Potsdam
	Detection and quantification of Rhizoctonia solani in sugar beet from hyperspectral images on a single plant scale	Abel Andree Barreto Alcantara, IfZ Göttingen
	Tiefenbezogene, feldbasierte Bodenfeuchtemessung mit Hilfe von NIR-Spektroskopie	Stefan Hinck, HS Osnabrück
	Flugrobotergenerierte 3D-Oberflächenmodelle präzisieren den Pflanzenschutz im Erwerbsobstbau	Marius Hobarth, ATB Potsdam

Detektion von Weintrauben in Bildern mit Hilfe von Fully Convolutional Neural Nets

Detection of grapevine in images using Fully Convolutional Neural Nets

Laura Zabawa¹, Anna Kicherer², Lasse Klingbeil¹, Andres Milioto³, Ribana Roscher⁴, Reinhard Töpfer², Heiner Kuhlmann¹

¹Bonn University, Department of Geodesy, Institute of Geodesy and Geoinformation

²Julius Kühn-Institut, Federal Research Centre of Cultivated Plants, Institute for Grapevine Breeding Geilweilerhof

³Bonn University, Department of Photogrammetry, Institute of Geodesy and Geoinformation

⁴Bonn University, Remote Sensing Group, Institute of Geodesy and Geoinformation
E-Mail: zabawa@igg.uni-bonn.de

Zusammenfassung: Die Ertragsabschätzung und -vorhersage ist für Winzer eine Herausforderung, um gesteckte Produktionsziele (Menge-Güte Relation) zu erreichen. Die Detektion von Weintrauben in Bildern stellt hierbei eine günstige und schnelle Alternative zu den anerkannten aber zeitintensiven und subjektiven Methoden dar. Statt einer Extrapolation von kleinen Stichproben wenden wir ein neuronales Netz auf Bilder der Weinreben an, die mit einer Phänotypisierungsplattform, dem Phenoliner, aufgenommen wurden. Dabei steht die Erkennung weißer Beeren im Mittelpunkt, da ihre grüne Farbe vor den ebenfalls grünen Blättern eine anspruchsvolle Klassifikationsaufgabe darstellt. Wir formulieren die Erkennung von Beeren als ein 3-Klassen-Problem: Kante, Beere und Hintergrund. Das Netz wurde mit 60 Bildern der Sorte Riesling, in unterschiedlichen Erziehungssystemen, in denen die Beeren manuell markiert wurden, ausgewertet. 30 Bilder zeigen Pflanzen im Spalierschnitt (VSP) und 30 im Minimalschnitt im Spalier (SMPH). Wir sind in der Lage 94,0% im VSP und 85,6% der markierten Beeren im SMPH korrekt zu detektieren.

Deskriptoren: Deep Learning, Objekterkennung, Zählung, Wein

Abstract: Yield estimation and prediction are of special interest in the field of grapevine breeding and cultivation. Berry detection in images offers a cheap and fast alternative to the otherwise time consuming and subjective on site analysis by experts. Extrapolation from small samples and historic data are used to estimate the expected yield at the end of a season. We apply fully convolutional Neural Nets on images recorded from the Phenoliner, a field phenotyping platform. We address especially the recognition of white grapes directly in the vineyard. They present a challenging detection task due to their similar colour compared to the surrounding leaves. The recognition of single berries was

formulated as a three-class problem. Individual berries were separated by the classes berry, edge and background. A connected component algorithm is applied to determine the number of berries in one image. We compared the automatically counted number of berries with the manually detected berries in 60 images showing Riesling plants in vertical shoot positioned trellis (VSP) and semi minimal pruned hedges (SMPH). We are able to detect berries correctly within the VSP system with an accuracy of 94.0 % and for the SMPH system with 85.6 %.

Keywords: Deep Learning, Object detection, Counting, Wine

1 Einleitung

Die Weinrebe ist eine der ältesten und ökonomisch bedeutendsten Nutzpflanzen. Sie wird von eingeschleppten Schadpilzen (Echter Mehltau und Falscher Mehltau) massiv bedroht. Daher steht die Züchtung neuer, robuster Sorten und ihre Effizienzsteigerung im Fokus vieler Forschungsprojekte. Beispiele sind die Anwendung phänotypischer Indikatoren zur Beschreibung des Ertrags oder der Entwicklung der Pflanzen. Die Beschreibung und Erfassung der Merkmale erfolgt an mehrjährigen Pflanzen im Weinberg und ist sehr zeit- und arbeitsaufwändig. Die BBCH Skala (LORENZ 1995) oder OIV Deskriptoren (OIV 2011), dienen der Standardisierung der Merkmalerfassung und -einteilung in verschiedene Boniturklassen. Diese Methoden können sehr subjektiv und damit fehleranfällig sein. Die Analyse von Bildern bietet dagegen eine objektive und schnelle Alternative zu den traditionellen Methoden. Untersuchungen zur automatischen Bestimmung des Beerendurchmessers wurden von ROSCHER *et al.* (ROSCHER 2014) vorgestellt. Als Datengrundlage dienen Bilder, die mit einer Spiegelreflexkamera manuell aufgenommen wurden. ROSCHER *et al.* benutzen eine Hough Transformation um runde Objekte zu detektieren. Diese wurden anschließend als Beere oder nicht Beere mittels eines *Random Fields* klassifiziert.

NUSKE *et al.* (2011) führte erstmals eine großangelegte Studie in realistischen Bedingungen durch. Über mehrere Jahre wurden hunderte Pflanzen überwacht. NUSKE *et al.* (2011) befestigten ein Kamerasystem auf einer beweglichen Plattform und statteten diese mit Beleuchtung aus. Sie nutzen ebenfalls eine Hough Transformation zur Detektion runder Objekte mit einer folgenden Klassifikation. Eine App für mobile Anwendungen zur Zählung wurde von AQUINO *et al.* (2016) präsentiert. Sie nutzen eine schwarze Box als Hintergrund, vor dem grüne Weintrauben über runde Reflektionen, die anschließend mit einem neuronalen Netz klassifiziert wurden, erkannt werden konnten. In einer folgenden Studie (AQUINO 2017) wurde der Ansatz verstärkt automatisiert und die manuelle Selektion der Trauben über die Box überwunden.

RUDOLPH *et al.* (2018) konzentrierten sich auf die Detektion von Blüten in Bildern. Auch sie verwendeten eine Hough Transformation, kategorisierten die Ergebnisse aber anschließend mit einem neuronalen Netz. Im Gegenzug zu all diesen Arbeiten versuchen wir, die Detektion der Beeren in Bildern komplett mittels eines neuronalen Netzes zu klassifizieren.

2 Material und Methoden

Das zur Verfügung stehende Bildmaterial wurde mit dem Phenoliner (KICHERER 2017) aufgenommen. Der Phenoliner ist ein entkernter Traubenvollernter, der mit einem Kamerasystem ausgestattet ist (**Abbildung 1**). Es sind drei Kameras vertikal übereinander und drei nebeneinander montiert. Für diesen Versuch werden nur die drei vertikalen Kameras genutzt.



Abbildung 1: Phenotyping Plattform Phenoliner (KICHERER, 2017). Links: Einsatz des Systems bei einer Reihe von Weinstöcken. Rechts: Kamerasystem mit über- und nebeneinander angeordneten Kameras

Es wurden Aufnahmen zu drei Zeitpunkten gemacht, vor der Ausdünnung, nach der Ausdünnung sowie kurz vor der Lese. Die Rebsorten 'Riesling', 'Regent' und 'Felicia' wurden in den Anbausystemen Spalier (VSP) und Minimalschnitt im Spalier (SMPH) untersucht. Wir konzentrieren uns in diesem Beitrag auf 'Riesling' und 'Felicia', wobei für jede Rebsorte 10 Referenzstöcke im VSP und 10 im SMPH genauer untersucht werden. Für jeden dieser Referenzstöcke liegen manuelle Zählungen der sichtbaren Beeren vor.

Für das Training wurden 25 manuell annotierte Bilder aus beiden Anbausystemen und von allen Sorten verwendet. Die Anbausysteme haben dabei unterschiedliche Schwierigkeitsgrade für die Detektion von Beeren. Im VSP sind die Beeren gut sichtbar und relativ homogen in ihrer Größe. Im SMPH verdeckt das Blattwerk große Teile der Beeren und die Beeren an sich haben eine inhomogene Größe.

3 Methodenentwicklung

Die Erkennung einzelner Beeren in Bildern wird über ein Drei-Klassen-Problem gelöst. Die Klasse „Beere“ an sich stellt dabei die interessanteste Klasse dar, die Trennung zwischen den Beeren wird über die Klasse „Kante“ realisiert. Alles andere wird als „Hintergrund“ zusammengefasst und ist für alles Weitere nicht relevant. Beispiele für annotierte Beeren sind in **Abbildung 2** erkennbar.

Die Klassifikation an sich wird mittels eines neuronalen Netzes realisiert (nach MILIOTO *et al.*, 2018). Dabei ist das MobileNetV2 (SANDLER 2019) Rückgrat des Netzes und „deeplabv3+“ der Encoder (CHEN 2018). Das MobileNetV2 ist eine effiziente Konstruktion, die für mobile Anwendungen gedacht ist. Dabei nutzt sie *inverted residuals* und *linear bottlenecks* um die einzelnen Layer effizient zu gestalten. Das deeplabv3+ verfeinert die Ergebnisse der Segmentierung. Das Netz lernt aus überlappenden Bildausschnitten. Im Vergleich zu dem originalen Bild (2048 x 2592 Pixel) sind die Bildausschnitte deutlich kleiner (384 x 512 Pixel) was die Lernzeit erheblich verkürzt und zu zufriedenstellenden Ergebnissen führt. Die Lernrate für das Netz liegt bei 0,001, das Momentum bei 0,9. Nach fünf Epochen wird die Lernrate um 0,99 angepasst.




Abbildung 2: Klassifizierungspipeline. (1) überlappende Sliding-Windows über original Bild und Anwendung des Netzwerks auf die Bild-Schnipsel, (2) Rekonstruktion der Maske für das gesamte Bild über Mittelung der Überlappungsbereiche, (3) Überlagerung der Maske mit dem originalen Bild für eine Visuelle Inspektion, (3) Auswertung der Ergebnisse mit der Manuellen Zählung, grüne Flächen sind detektierte Beeren, die auch manuell als Beere gekennzeichnet wurden, schwarze Flächen wurden als Beere detektiert, sind aber keine. pinke Punkte zeigen manuell gekennzeichnete Beeren, die sich mit einer detektierten Fläche überlagern, dunkle in Quadraten sind nicht gefundene aber manuell gekennzeichnete Beeren.

Die Pipeline für die Klassifikation ist in **Abbildung 2** zu sehen. Die Bilder werden mittels eines *Sliding Window* Verfahrens in überlappende Bildausschnitte geteilt (1). Jeder Bildausschnitt wird mit dem Neuronalen Netz klassifiziert. Aus diesen wird eine Maske für

das gesamte Bild rekonstruiert (2) und kann mit dem Originalbild für eine visuelle Inspektion überlagert werden (3). Die Evaluation erfolgt über Bilder in denen manuell alle sichtbaren Beeren über einen Punkt in ihrem Zentrum markiert wurden. In (4) ist dies beispielhaft dargestellt. Die grünen Flächen beinhalten eine manuelle Markierung und sind somit korrekt als „Beere“ identifiziert worden. Die schwarzen Flächen beinhalten keine Markierung und sind somit fälschlicherweise als „Beere“ klassifiziert. Schwarze Punkte in Quadraten sind Beeren, die von dem Netzwerk nicht erkannt worden sind. Die Kanten der Beeren werden momentan nicht berücksichtigt, da nur eine Zählung der Beeren erfolgt. Die Zählung erfolgt über einen *Connected Component* Algorithmus, der zusammenhängende Komponenten erkennt und auflistet. Diese werden anschließend gezählt.

4 Diskussion

Die Evaluation der Ergebnisse erfolgt getrennt für die Rebsorten und Anbausysteme. Es werden nur die Flächen untersucht, die als „Beere“ klassifiziert wurden. Für 'Riesling' im VSP konnten 94,2 % der manuell markierten Beeren korrekt detektiert werden. Allerdings sind 24,8 % der detektieren Objekte fälschlicherweise als Beeren erkannt. Für 'Riesling' im SMPH liegt die Erkennungsrate der Beeren bei 85,7 %, sowie bei 24,1 % für die falsch klassifizierte Objekte.

Beispiele für falsch erkannte Beeren sind Blattränder oder Ranken, die sich zu runden Strukturen formen (**Abbildung 3**). Ein weiteres Problem entsteht, wenn das Netz einzelne Komponenten nicht korrekt trennt und mehrere Beeren zusammenfasst.



Abbildung 3: Beispiele für fehlklassifizierte Objekte. Links: Ranken, die runde Strukturen ausbilden. Mitte: Blattränder. Rechts: Mehr als eine Beere wird in einer Komponente zusammengefasst.

Zusammenfassend kann gesagt werden, dass Regionen, die Beeren enthalten, mit einer hohen Zuverlässigkeit entdeckt werden. Das Netz neigt jedoch dazu, auch andere Objekte zu klassifizieren und Beeren teilweise zu untersegmentieren. Meist werden einzelne Beeren jedoch auch als solche erkannt. Die falsch erkannten Komponenten sind visuell oft von richtigen Beeren unterscheidbar, aus diesem Grund ist für die Zukunft eine Filterung der Ergebnisse vorgesehen. Die Untersegmentierung der Beeren könnte über Miteinbeziehung der Kanten in die Zählung verbessert werden.

Literaturverzeichnis

- AQUINO A., DIAGO M. P., MILLAN B., TARDAGUILA J. (2016):** A new methodology for estimating the grapevine-berry number per cluster using image analysis. *Biosystems Engineering* 159, pp. 80–95.
- AQUINO A., MILLAN B., DIAGO M.-P., TARDAGUILA J. (2018):** Automated early yield prediction in vineyards from on-the-go image acquisition. *Computers and Electronics in Agriculture* 144, pp. 26–36 B.
- CHEN L.-C., ZHU Y., PAPANDREOU G., SCHROFF F., ADAM H., (2018):** Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, In: FERRARI, V., HEBERT, M., SMINCHISESCU, C., WEISS, Y. (Eds.), *Computer Vision – ECCV 2018*. Springer International Publishing, Cham, pp. 833–851. https://doi.org/10.1007/978-3-030-01234-2_49.
- KICHERER A., HERZOG K., BENDEL N., KLÜCK H.-C., BACKHAUS A., WIELAND M., ROSE J. C., KLINGBEIL L., LÄBE T., HOHL C., PETRY W., KUHLMANN H., SEIFFERT U., TÖPFER R. (2017):** Phenoliner: A New Field Phenotyping Platform for Grapevine Research. *Sensors*, 17(7): 1625.
- LONG J., SHELHAMER E., DARELL T. (2015):** Fully convolutional networks for semantic segmentation. *Proceedings in the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 3431–3440.
- LORENZ, D.H., EICHHORN, K.W., BLEIHOLDER, H., KLOSE, R., MEIER, U. und WEBER, E. (1995):** Growth Stages of the Grapevine: Phenological growth stages of the grapevine (*Vitis vinifera* L. ssp. *vinifera*)-Codes and descriptions according to the extended BBCH scale. *Australian Journal of Grape and Wine Research* 1:100–103.
- MILIOTO A., STACHNISS C. (2018):** Bonnet: An Open-Source Training and Deployment Framework for Semantic Segmentation in Robotics using CNNs. In: *ArXiv e-prints*, 2018.
- NUSKE S., ACHAR S., BATES T., NARASIMHAN S. und SINGH S. (2011):** Yield estimation in vineyards by visual grape detection, 2011 IEEE/RSJ International Conference on Intelligent Robots and Systems, pp. 2352–2358.
- NUSKE S., WILSHUSEN K., ACHAR S., YODER L., NARASIMHAN S., SINGH S. (2014):** Automated Visual Yield Estimation in Vineyards. In: *Journal of Field Robotics*, 31, pp. 837–860.
- OIV (2001):** 2nd Edition of the Oiv Descriptor List for Grape Varieties and *Vitis* Species (<http://www.oiv.int>).
- RUDOLPH R., HERZOG K., TÖPFER R., STEINHAGE V. (2018):** Efficient identification, localization and quantification of grapevine inflorescences in unprepared field images using Fully Convolutional Networks. *CoRR*.
- ROSCHER R., HERZOG K., KUNKEL A., KICHERER A., TÖPFER R., FÖRSTNER W. (2014):** Automated image analysis framework for high throughput determination of grapevine berry size using conditional random fields. In: *Computers and Electronics in Agriculture*, 2014, vol. 100, pp. 148–158.
- SANDLER M., HOWARD A.G., ZHU. M., ZHMOGINOV A., CHEN L.-C. (2018):** Inverted Residuals and Linear Bottlenecks: Mobile Networks for Classification, Detection and Segmentation. *CoRR*.

Automatische Baumidentifizierung und Baumhöhenbestimmung zur Erstellung präziser Applikationskarten

Automatic tree identification and tree height determination for creating precise application maps

Marius Hobart¹, Michael Schirrmann¹, Magdalena Proske², Christian Scheer²,
Ludwig Schrenk³, Michael Pflanz¹

¹Leibniz-Institut für Agrartechnik und Bioökonomie (ATB), Max-Eyth-Allee 100, 14469 Potsdam

²Stiftung Kompetenzzentrum Obstbau-Bodensee (KOB), Schuhmacherhof 6,
88213 Ravensburg

³CiS GmbH, Hansestraße 21, 18182 Rostock
E-Mail: mhobart@atb-potsdam.de

Zusammenfassung: Pflanzenschutz in Raumkulturen findet aktuell überwiegend flächeneinheitlich statt. Um Einsparerfolge der Präzisionslandwirtschaft in den Obstbau zu übertragen, sind hoch aufgelöste dreidimensionale Strukturinformationen der Anlagen nötig. Ein Ansatz ist die Aufnahme von sich überlappenden Luftbilddaufnahmen mit einer Drohne, um räumliche Strukturparameter der Bäume durch Photogrammetrie aus den Bildern abzuleiten. Die errechneten 3D-Punktwolken dienen dann als Grundlage zur Erstellung von Applikationskarten. Zeitlich davon abgesetzt findet die teilraumspezifische Applikation statt – der sogenannte offline-Ansatz.

Dieser Beitrag zeigt die automatisierte Erkennung von Bäumen in einer 3D-Punktwolke sowie die Ableitung baum-individueller Kronenhöhen. Referenziert wird das Ergebnis mittels manuell aufgenommener Baumhöhen sowie einem strukturellen Vergleich der Punktwolke mit einer *Light Detection and Ranging* (LiDAR)-Messung.

Deskriptoren: Obstbau, Präzisionspflanzenschutz, Drohnen, 3D-Punktwolken, Baumstrukturparameter

Abstract: *Plant protection in fruticulture is currently predominantly carried out on a uniform basis. In order to transfer saving successes of precision agriculture to orchards, high-resolution three-dimensional structural information of the plants is required. A quick method is to fly over the plant with an unmanned aerial vehicle (UAV), which takes high-resolution, overlapping aerial images. Using the structure-from-motion approach, 3D point clouds can be calculated, which serve as the basis for creating application maps. The precise application will be conducted at a later date than in the calculation, this is the offline approach.*

This article shows the automated recognition of trees in a 3D point cloud as well as the individual tree height derivation. The result is referenced by manually recorded tree heights and a structural comparison of the point cloud with a Light Detection and Ranging (LiDAR) measurement.

Keywords: *Fruticulture, precise plant protection, unmanned aerial vehicle (UAV), 3D-point-cloud, Tree structural parameter*

1 Einleitung

Bereits nach einigen Vollertragsphasen können Obstplantagen hinsichtlich ihrer strukturellen und morphologischen Parameter eine bisher gering beachtete räumliche Heterogenität aufweisen (AGGELOPOULOU *et al.* 2010). Dies wird bei der Ausbringung von Pflanzenschutzmitteln aktuell nur unzureichend berücksichtigt, sodass die Anwendung im Wesentlichen flächeneinheitlich erfolgt. Eine teilraumspezifische Ausbringung angepasst an den Laubwandabschnitt könnte dagegen zu Ressourceneinsparungen, einer erhöhten Anwendersicherheit sowie einer besseren Umweltverträglichkeit (HERRINGTON *et al.* 1981) führen.

Durch neue Technologien der Präzisionslandwirtschaft ist es inzwischen möglich, die räumliche Variabilität von Umweltvariablen zu erfassen und auf sie zu reagieren (DAMMER *et al.* 2009; SCHIRRMANN *et al.* 2011). Auch im Erwerbsobstbau wird der Einsatz sensorgestützter Verfahren zur automatischen Datenerhebung räumlicher Information diskutiert und erste methodische Lösungen wurden vorgestellt (ZARCO-TEJADA *et al.* 2014; MEJIA-AGUILAR *et al.* 2015). Im Online-Verfahren werden beispielsweise die Blattwandfläche, das Kronenvolumen oder der Pflanzabstand mittels LiDAR-, Ultraschall- und Infrarotkamera-Sensoren während der Anwendung erfasst und verarbeitet (GIL *et al.* 2007; BALSARI *et al.* 2009; LLORENS *et al.* 2011; WALKLATE *et al.* 2011; PFLANZ *et al.* 2013). Eine durch sensorgestütztes Abschalten einzelner Spritzdüsen reduzierte Ausbringungsmenge führt allerdings nicht zwangsläufig zu Einsparungen insgesamt, da das Einsparpotential einer Obstanlage vor der Behandlung nicht bekannt ist und somit bei der Berechnung der Aufwandmenge nicht berücksichtigt werden kann. Folglich verbleiben Restmengen an Spritzbrühe im Tank, die nicht oder nur zeitlich begrenzt wiederverwendet werden können. Darüber hinaus ist beim Online-Ansatz mit einem erhöhtem Wartungsaufwand der Sensorik zu rechnen (durch Ausfall oder Verschmutzung).

Im hier gezeigten Offline-Verfahren geschieht die Datenaufnahme und -verarbeitung zeitlich abgesetzt zur Ausbringung. Da erforderliche Aufwandmengen bereits vor der Ausbringung kalkuliert werden können, kann die Applikationsmenge präzise an den Bedarf der gesamten Anlage angepasst werden. Restmengen werden auf ein Minimum reduziert. Auch die anfällige Sensortechnik an der Spritze entfällt, bis auf die Navigationseinheit (GNSS) zur Bestimmung der exakten Position der Spritze. Zusätzlich wird die Anwendungssicherheit beim hier vorgestellten Offline-Verfahren gegenüber der Online-Methodik erhöht, da eine Dokumentation der Applikation nach Verarbeitung der Daten erfolgen kann.

Eine kostengünstige und zeitsparende Methode zur Datenerhebung für die Berechnung von teilraumspezifischen Applikationskarten ist das Befliegen von Plantagen mittels UAS (unmanned aerial system). Mit einer handelsüblichen RGB-Kamera ausgestattet werden sich überlappende, hochauflösende Photos aus einer geeigneten Flughöhe aufgenommen. Mittels Photogrammetrieverfahren werden anschließend dreidimensionale Punktwolken errechnet und analysiert (TORRES-SANCHEZ *et al.* 2018; DIAZ-VARELA *et al.* 2015).

Die hier vorgestellte Studie versucht Baumstrukturelle Parameter automatisch aus diesen Punktwolken abzuleiten. Später kann diese Auswertung dann zur Applikationskartenerstellung genutzt werden.

2 Material und Methoden

Für die Generierung von Applikationskarten wurden UAS-Befliegungen Messungen in einer Apfelplantage der Sorte 'Kanzi' auf dem Gelände des Kompetenzzentrums Obstbau am Bodensee (KOB) am 26.04.2018 durchgeführt. Die Baumstruktur war sehr heterogen, da die Versuchsanlage auf Grund von Obstbaumkrebs zum Teil gerodet bzw. auf halber Baumhöhe geschnitten worden war (**Abbildung 1**). Für die Luftbildaufnahmen wurde ein automatischer, kameratragender Flugroboter (Oktokopter, CiS GmbH, Deutschland) mit einer handelsübliche RGB-Kamera (alpha-6000, Sony, Japan) ausgestattet. Aufgenommen wurde mit einer Brennweite von 16 mm und einer Auflösung von 4000 x 6000 px (APS-C Sensor). Die Flughöhe betrug 10 m für Detailflüge über den Reihen bzw. 20 m für einen Kontourflug. Die hieraus resultierende Pixeldichte auf der vordersten Baumwandfläche lag zwischen 2,3 und 4,6 mm pro Pixel. Als Voraussetzung zur Erstellung der 3D-Punktwolken wurden die Luftbilder um bis zu 90 % überlappend aufgenommen und anschließend mittels *structure-from-motion* Verfahren verrechnet (Photoscan Version 1.4.5, Agisoft, Russland). Zur späteren Georeferenzierung wurden in der Anlage Markerplatten ausgelegt und mittels eines GPS-RTK-Systems (HiPer Pro, Topcon, Tokio) eingemessen. Über die in den Luftbildaufnahmen abgebildeten Platten konnten die 3D-Punktwolken später verortet werden.

Die Analyse der photogrammetrisch erstellten Punktwolken erfolgte mittels CloudCompare (EDF, Paris) und R (R Core Team). Mit der Bibliothek lidR (ROUSSEL *et al.* 2019) wurden die Baumpunkte in den Punktwolken zunächst vom Boden getrennt und dann einzelne Baumhöchstpunkte, mittels eines fensterbasierten Filters zur Bestimmung lokaler Maxima (POPESCU & WYNNE 2004), identifiziert.

Als Referenz wurden Baumstrukturen mit Hilfe eines traktorgebundenen LiDAR-Systems (LD MRS 400001, Sick, Germany) bei einer Fahrgeschwindigkeit von 0.4 ms^{-1} aufgenommen. Dieses war in einer Höhe von 2 m angebracht. Die Bäume wurden lateral mit einem voreingestellten Winkel von 0° und einer Frequenz von 25 Hz abgetastet. Die erreichte Auflösung betrug 1,6 cm entlang der Spur.



Abbildung 1: Messquartier 15.1+2 (KOB) mit gezeigten Baumrücken (orange) und Beschnitt auf halber Baumhöhe (gelb), Stand März 2018

3 Ergebnisse

Die in **Abbildung 2** gezeigte Punktwolke stellt das Ergebnis der beschriebenen Messflüge dar. Drei Reihen des Quartiers 15.1+2 des KOB sind mittig in der Abbildung dargestellt. Visuell lässt sich die Laubwand der einzelnen Reihen erkennen, welche durch eine Fahrspur unterbrochen ist. Auch die zum Messtermin deutlich blütenreichere Apfelsorte in der rechten Reihe ist klar unterscheidbar.



Abbildung 2: Punktwolke dreier Reihen des Quartiers 15.1+2 des KOB nach photogrammetrischem Ansatz

Aus den mittels der beschriebenen Drohnenbefliegung erstellten 3D-Punktwolken konnten strukturelle Baumparameter abgeleitet werden. Sie werden den reihenweise aufgenommenen LiDAR-Punktwolken in **Abbildung 3** gegenübergestellt.




Abbildung 3: Punktwolken einer Baumreihe aufgenommen mittels LiDAR- (oben) und photogrammetrischem Ansatz (unten) des Quartiers 15.1 vom KOB

Es lässt sich feststellen, dass die 3D-Modelle aus LiDAR- und Photogrammetriemessungen deutliche Gemeinsamkeiten in den Baumstrukturen aufweisen. Bäume, auftretende Lücken als auch das Bodenprofil werden in dem UAS-Modell erkennbar abgebildet. Weiter bieten sich Auswertemöglichkeiten durch Verwendung der RGB-Informationen im UAS-Modell. Allerdings bildet der photogrammetrische Ansatz schmale Objekte, wie dünne Äste und Holzpfähle, deutlich schlechter ab als die hochaufgelöste LiDAR-Punktwolke. Auch bodennahe Äste und Halbbäume werden in der UAS-Datenaufnahme schlechter abgebildet als durch die bodengestützte LiDAR-Messung.

In der weiteren Datenverarbeitung sollten die Bäume sicher erkannt und daran Baumhöhen abgeleitet werden. **Abbildung 4** zeigt die drei aufgenommenen Reihen, wobei die unterste der Punktwolken der aus **Abbildung 3** entspricht.




Abbildung 4: Baumidentifikation und abgeleitete Baumhöhen aus der photogrammetrisch erstellten Punktwolke des Quartiers 15.1 vom KOB

Es zeigt sich, dass die Einzelbäume aus den Punktwolken automatisch erkannt und so von den Bodenpunkten separiert werden können. Danach werden Kronenhöhenpunkte für jeden Baum erkannt und in einem zweiten Schritt können Höhendistanzen zu einer durch die Bodenpunkte gelegten Referenzfläche berechnet werden. Allerdings werden auf diese Weise auch alle in der Anlage befindlichen Holzpfähle als Krone erkannt. Weiterhin treten Schwierigkeiten mit Raumpunkten unterhalb des Bodenhorizontes auf.

4 Diskussion

In dieser Studie werden hochauflösende Luftbildaufnahmen bei geringer Flughöhe aufgenommen und zu 3D-Punktwolken verrechnet, welche zur Ableitung von baumstrukturellen Parametern herangezogen werden. Studien zeigten, dass eine Baumidentifizierung (TORRES-SANCHEZ *et al.* 2018) und Baumstrukturen (DIAZ-VARELA *et al.*

2015; TORRES-SANCHEZ *et al.* 2015) auch dann möglich ist, wenn bei einer Flughöhe von 50 bis 100 m Nadir-Aufnahmen ausgewertet werden. Auch bei größeren Flughöhen konnten Parameterbestimmungen einer adulten Olivenbaumfruchtwand, wie Fruchtwandstärke und -oberfläche aus photogrammetrischen Punktwolken errechnet werden (ESCOLÀ *et al.* 2017).

Durch einen geeigneten Aufnahmewinkel konnte die Aufnahmeperspektive verbessert und damit eine Mehrinformation aus der seitlichen Ansicht der Fruchtwand generiert werden. So könnten für künftige Anwendungsfelder weitere obstbautypische Kulturparameter erhoben werden.

Im Gegensatz zur LiDAR-Messung hat das photogrammetrisch erstellte Modell eine geringere Auflösung, ermöglicht jedoch ggf. eine zusätzliche wenn auch limitierte spektrale Differenzierung durch die RGB-Aufnahmen. Darüber hinaus wurden die in der vorliegenden Studie verwendeten LiDAR-Daten nicht praxisüblich bei geringer Fahrgeschwindigkeit aufgezeichnet und dienten folglich als Referenz. In folgenden Untersuchungen wird getestet, ob mit dem photogrammetrischen Ansatz unter optimalen Bedingungen höher auflösende Punktwolken erzeugt werden können (vgl. DANDOIS *et al.* 2017). Zukünftig ist abzuschätzen, welche räumliche Auflösung für die angestrebte Anwendung im Erwerbsobstbau erforderlich ist.

Danksagung

Die Förderung des Vorhabens „Corona-PRO“ erfolgt aus Mitteln des Bundesministeriums für Ernährung und Landwirtschaft (BMEL) aufgrund eines Beschlusses des deutschen Bundestages. Die Projektträgerschaft erfolgt über die Bundesanstalt für Landwirtschaft und Ernährung (BLE) im Rahmen des Programms zur Innovationsförderung. Die Autoren des Beitrags danken Frau Konni Biegert vom Kompetenzzentrum Obstbau-Bodensee für die umfangreichen Lasermessungen in der Obstanlage.

Literaturverzeichnis

- AGGELOPOULOU K.D., WULFSOHN D., FOUNTAS S., GEMTOS T.A., NANOS G.D. & BLACKMORE S. (2010):** Spatial variation in yield and quality in a small apple orchard. – *Precision Agriculture*, 11 (5): 538–556 <https://doi.org/10.1007/s11119-009-9146-9>.
- BALSARI P., MARUCCO P. & TAMAGNONE M. (2009):** A crop identification system (CIS) to optimise pesticide applications in orchards. – *Journal of Horticultural Science & Biotechnology*: 113–116.
- DAMMER K.-H., THÖLE H., VOLK T. & HAU B. (2009):** Variable-rate fungicide spraying in real time by combining a plant cover sensor and a decision support system. – *Precision Agriculture*, 10 (5): 431–442 <https://doi.org/10.1007/s11119-008-9088-7>.
- DANDOIS J., BAKER M., OLANO M., PARKER G. & ELLIS E. (2017):** What is the Point? Evaluating the Structure, Color, and Semantic Traits of Computer Vision Point Clouds of Vegetation. – *Remote Sensing*, 9 (4): 355 <https://doi.org/10.3390/rs9040355>.
- DÍAZ-VARELA R., DE LA ROSA R., LEÓN L. & ZARCO-TEJADA P. (2015):** High-Resolution Airborne UAV Imagery to Assess Olive Tree Crown Parameters Using 3D Photo Reconstruction: Ap-

plication in Breeding Trials. – Remote Sensing, 7 (4): 4213–4232
<https://doi.org/10.3390/rs70404213>.

- ESCOLÀ A., MARTÍNEZ-CASASNOVAS J.A., RUFAT J., ARNÓ J., ARBONÉS A., SEBÉ F., PASCUAL M., GREGORIO E. & ROSELL-POLO J.R. (2017):** Mobile terrestrial laser scanner applications in precision fruticulture/horticulture and tools to extract information from canopy point clouds. – Precision Agriculture, 18 (1): 111–132 <https://doi.org/10.1007/s11119-016-9474-5>.
- GATZIOLIS D., LIENARD J.F., VOGS A. & STRIGUL N.S. (2015):** 3D Tree Dimensionality Assessment Using Photogrammetry and Small Unmanned Aerial Vehicles. – PLOS ONE, 10 (9): e0137765 <https://doi.org/10.1371/journal.pone.0137765>.
- GIL E., ESCOLA A., ROSELL J.R., PLANAS S. & VAL L. (2007):** Variable rate application of plant protection products in vineyard using ultrasonic sensors. – Crop Protection, 26 (8): 1287–1297 <https://doi.org/10.1016/j.cropro.2006.11.003>.
- HERRINGTON, P. J., MAPOTHER, H. R., & STRINGER, A. (1981):** Spray retention and distribution on apple trees. – Pesticide Science, 12(5), 515–520.
- LLORENS J., GIL E., LLOP J. & ESCOLÀ A. (2011):** Ultrasonic and LIDAR Sensors for Electronic Canopy Characterization in Vineyards: Advances to Improve Pesticide Application Methods. – Sensors, 11 (12): 2177–2194 <https://doi.org/10.3390/s110202177>.
- MEJIA-AGUILAR A., TOMELLERI E., VILARDI A. & ZEBISCH M. (2015):** UAV based tree height estimation in apple orchards: potential of multiple approaches. – In: EGU General Assembly Conference Abstracts. – p. 7082.
- PFLANZ M., RALFS J.P. & PELZER T. (2013):** Site-specific plant protection using precise canopy gap detection. – In: GARCIA, E.M., MANTEROLA, L.V., PEREZ, F.J., ADELL, P.C. & FIGUEROA: Book of Abstracts 12th Workshop on Spray Application Techniques in Fruit Growing, Valencia. – pp. 68–70.
- POPESCU S.C. & WYNNE R.H. (2004):** Seeing the trees in the forest. – Photogrammetric Engineering & Remote Sensing, 70 (5): 589–604.
- ROUSSEL, J., AUTY, D., DE BOISSIEU, F., MEADOR, A. S. (2019):** Airborne LiDAR Data Manipulation and Visualization for Forestry Applications. <https://github.com/Jean-Romain/lidR> (14.03.2019; 16:04 MEZ).
- SCHIRRMANN M., GEBBERS R., KRAMER E. & SEIDEL J. (2011):** Soil pH Mapping with an On-The-Go Sensor. – Sensors, 11 (1): 573–598 <https://doi.org/10.3390/s110100573>.
- TORRES-SÁNCHEZ J., LÓPEZ-GRANADOS F., SERRANO N., ARQUERO O. & PEÑA J.M. (2015):** High-Throughput 3-D Monitoring of Agricultural-Tree Plantations with Unmanned Aerial Vehicle (UAV) Technology. – PLOS ONE, 10 (6): e0130479 <https://doi.org/10.1371/journal.pone.0130479>.
- TORRES-SÁNCHEZ J., LÓPEZ-GRANADOS F., BORRA-SERRANO I. & PEÑA J.M. (2018):** Assessing UAV-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. – Precision Agriculture, 19 (1): 115–133 <https://doi.org/10.1007/s11119-017-9502-0>.

WALKLATE P.J., CROSS J.V. & PERGHER G. (2011): Support system for efficient dosage of orchard and vineyard spraying products. – *Computers and Electronics in Agriculture*, 75 (2): 355–362 <https://doi.org/10.1016/j.compag.2010.12.015>.

ZARCO-TEJADA P.J., DIAZ-VARELA R., ANGILERI V. & LOUDJANI P. (2014): Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. – *European Journal of Agronomy*, 55: 89–99 <https://doi.org/10.1016/j.eja.2014.01.004>.

Tiefenbezogene, feldbasierte Bodenfeuchtemessung mit Hilfe von NIR-Spektroskopie

Depth-related, field-based soil moisture measurement using NIR spectroscopy

Julian Walter Beck¹, Marc Heinrich¹, Stefan Hinck¹, Vadim Tsukor¹, Walter Nietfeld²,
Arno Ruckelshausen¹

¹Hochschule Osnabrück, Fakultät I&I, Sedanstraße 26, 49076 Osnabrück

²Bodenprobetechnik Nietfeld GmbH, Nietfeldsweg 25, 49635 Badbergen

E-Mail: s.hinck@hs-osnabrueck.de

Zusammenfassung: Mit Hilfe der NIR-Spektroskopie soll die Bodenfeuchte online tiefenbezogen im Feld gemessen werden. Für diesem Zweck sind vorbereitende Untersuchungen im Labor an unterschiedlich feuchten und ungestörten Bodenproben mit unterschiedlichen Bodenarten durchgeführt worden. Es zeigt sich, dass der entwickelte spektrale Wasserindex (Quotient: 1450 nm / 1230 nm) einen guten Zusammenhang zur gravimetrischen bestimmten Bodenfeuchte aufweist.

Deskriptoren: NIR-Spektroskopie, tiefenbezogene Online-Bodenfeuchtemessung, Bodenart, Feldmessung

Abstract: *NIR spectroscopy will be used to measure depth-related soil moisture online directly at the field. For this purpose, preparatory laboratory tests have been conducted on different soil samples with different moisture contents and soil texture. It is shown that the spectral water index (ratio: 1450 nm / 1230 nm) is well related to manual detected soil moisture.*

Keywords: *NIR spectroscopy, depth-related online soil moisture measurement, soil texture, field based measurement*

1 Einleitung

Die Messungen mit V-NIR- und NIR-Spektroskopie bieten die Möglichkeit berührungslos die Spektraleigenschaften eines Stoffes bzw. eines Stoffgemisches zu erfassen. Bei der Bestimmung von z.B. Bodeneigenschaften weist eine NIR-Messung die Oberflächen-Spektraleigenschaften der Bodenpartikel aus, es werden in aller Regel die reflektierten Wellenlängen erfasst. (MUKHERJEE & LASKAR 2019)

Somit ermöglicht der Einsatz von V-NIR- und NIR-Spektroskopie in der Bodenkunde bzw. in der Bodenanalytik eine Vielzahl von Bodenparametern gleichzeitig zu bestim-

men. Ein weiterer sehr großer Vorteil ist, die Messung kann direkt auf dem Feld erfolgen. Als eine interessante Option ist es möglich, dass das optische Fenster mit Hilfe eines Gestänges direkt in den Boden für die Messung eingeführt werden kann (MILTZ 2016).

Bereits sicher zu erfassende Bodenparameter mit V-NIR- und NIR-Spektroskopie sind der Humusgehalt des Bodens (MILTZ 2016, KWEON & MAXTON 2013) und die Bodenfeuchte (SIMS und GAMON 2002, HUMMEL *et al.* 2001) oder auch der Wassergehalt im Pflanzenblatt (THIEL 2018). Das Wasser absorbiert im nahen Infrarotbereich in verschiedenen Wellenlängenbereichen. Diese liegen bei den Wellenlängen: 970 nm, 1200 nm, 1450 nm, 1950 nm und 2250 nm. Die Absorption ist dabei in den Bereichen um 1450 nm und 1950 nm am höchsten. Absolute Feuchtigkeitswerte können bspw. über den Vergleich der Intensitäten zweier Wellenlängen ermittelt werden. Dabei wird eine Wellenlänge gewählt, bei der Wasser nicht absorbiert, und eine Wellenlänge in der es stark absorbiert (SIMS und GAMON 2002).

Weitere wichtige bodenkundliche und pflanzenbauliche Bodenparameter, z.B. Tongehalt, pflanzenverfügbare oder totale Nährstoffgehalte im Boden können ebenfalls mit Hilfe der V-NIR- und NIR-Spektroskopie erfasst werden (LUDWIG *et al.* 2018, SORENSON *et al.* 2017, SORIANO-DISLA *et al.* 2014). Mobile Messsysteme ermöglichen den Messeinsatz direkt auf dem Feld durchzuführen und die gewünschten Bodenparameter *in situ* und ggf. tiefenbezogen zu erfassen (MILTZ 2016, PHOHL 2016, BAHAROM *et al.* 2015). Wobei es zu beachten gilt, dass die Messmethode im Feld – im Gegensatz zur Messung im Labor – nicht standardisiert und nicht validiert ist. Auch sollte die NIR-Messung als indirekte Analysemethode verstanden werden. Die erfassten Spektren können anhand eines Modells in den gesuchten Bodenparameter umgerechnet werden (MILTZ 2016).

Bereits die aktuelle Bodenfeuchte ist, für sich alleine betrachtet, eine wichtige Kenngröße sowohl bei der Bewirtschaftung (MOUAZEN *et al.* 2005) und auch als Einflussgröße auf weitere Messgrößen, z.B. Eindringwiderstand. So ist z.B. bei der Ermittlung des Bodeneindringwiderstands die aktuelle Bodenfeuchte zu berücksichtigen. Weiter ist die aktuelle Bodenfeuchte ein unerlässlicher Verrechnungsfaktor u.a. bei der Bestimmung der Bodennährstoffgehalte. Die Bodenprobe ist bei der Ermittlung der Nährstoffgehalte erforderlich, um deren aktuelle Feuchte zu korrigieren. In der Landtechnik wird V-NIR- und NIR-Spektroskopie z.B. genutzt um bei der Aussaat die Bodenfeuchte und Pflanzenrückstände in der Saatreihe zu erkennen, um ggf. die Aussaatstärke oder -tiefe online zu verändern (z.B. Veris iScan von Veris Inc., Salina / USA; SmartFirmer von Precision Planting, Tremont / USA). Insbesondere bei online-fähigen Prozessen gilt es, eine berührungslose, schnelle und zuverlässige Messung z.B. der Feuchte in einem Prozessablauf zu implementieren, um diesen wichtigen Parameter in Echtzeit zur Verfügung zu stellen (KRONSBELN *et al.* 2013).

Im Rahmen des interdisziplinären Forschungsprojektes „soil2data“ wird ein mobiles Feldlabor entwickelt, welches eine Bodennährstoffanalyse direkt auf dem Feld ermöglicht. Hierfür ist es notwendig die Bodenfeuchte über den gesamten Bereich der Boden-

probenentnahmetiefe zu kennen. Eine oberflächliche Messung bis z.B. in 5 cm bis 10 cm Tiefe ist nicht aussagekräftig, da der Feuchte-Tiefengradient deutlich variieren kann (**Abbildung 1**).

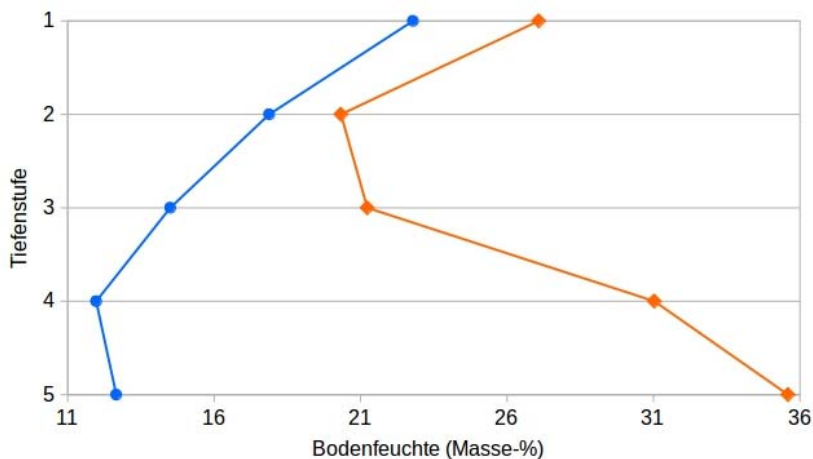


Abbildung 1: Exemplarische Darstellung zweier tiefenbezogene Bodenfeuchteverläufe auf einer Fläche, blaue Linie präsentiert einen lehmigen Sand, orange Linie präsentiert einen sandigen-lehmigen Ton, Tiefenstufen: 1 = 0–10 cm Tiefe, 2 = 10 – 20 cm Tiefe, 3 = 20–30 cm Tiefe, 4 = 30–40 cm Tiefe, 5 = 40–50 cm Tiefe, Messtermin: 27.02.2019

Zur Bestimmung der Bodenfeuchte kann z.B. das optische Fenster des NIR-Spektroskops in den Boden eingeführt werden. Eine weitere Möglichkeit ist, dass Bodenproben mit Hilfe eines Bohrstocks entnommen werden. Beim Herausziehen des Bohrstocks verbleibt die Bodenprobe in der Nut des Bohrstocks und kann somit zur Messung am optischen Fenster des NIR-Messsystems vorbeigeführt werden. Zur Evaluation des letzteren Ansatzes sind Untersuchungen im Labor an ungestörten Bodenproben zur Bestimmung der Bodenfeuchte mit Hilfe von NIR-Spektroskopie-Messungen durchgeführt worden. Des Weiteren ist ein technischer Messaufbau für einen kommerziell verfügbaren Bodenprobennehmer der Firma Bodenprobetechnik Nietfeld GmbH realisiert worden.

2 Material und Methoden

Für die Reflexionsmessungen im NIR Wellenlängenbereich unter Laborbedingungen wurde ein MultiSpec® Desktop Spektrometer von der Firma tec5 AG verwendet. In diesem Gerät sind ein Spektrometer und eine Lichtquelle integriert. Die Wolfram-Halogen-Lampe emittiert in einem Wellenlängenbereich von 360 nm bis 2200 nm und ist damit für die Feuchtigkeitsmessung geeignet. Das Spektrometer ermöglicht Messungen mit einer Integrationszeit von 1,5 ms bis 6 s in einem Messbereich von 895 nm bis 2210 nm (Auflösung <16 nm). Zur Detektion des Wassergehalts des Bodens wurde ein spektraler Wasserindex (WI) als Spektralquotient gebildet. Die Verwendung des WI auf Basis diskreter Spektralbanden stellt eine einfache Methode zur Wassergehaltsanalyse dar. Dazu sollten zwei einzelne Wellenlängen als Quotient verwendet werden – die erste

Spektrallinie repräsentiert den Einfluss der Wasserabsorption, die zweite Spektrallinie diente der Intensitätsnormierung und sollte daher eine möglichst geringere Empfindlichkeit zu den Wasserabsorptionsbänden aufweisen. Auf Basis der Laboruntersuchungen und den in der Literatur benannten spektralen Wasserabsorptionsbänden wurde ein Spektral-Quotient WI (spektraler Wasserindex) eingeführt, der die Reflexion der Wasserabsorptions-Bände bei 1450 nm auf die Reflexionsintensität von 1230 nm normiert.

$$WI = \frac{Intensity(1450nm)}{Intensity(1230nm)}$$

Formel 1: Berechnung des spektralen Wasserindex

Um ungestörte Bodenproben mit unterschiedlichen Wassergehalten zu erhalten, sind Bodenproben im Stechzylinder präpariert und aufgewässert worden. Damit wird erreicht, dass sich bei ungestörten Bodenproben, deren charakteristischer Wassergehalt einstellt werden kann. Die aufgewässerten Bodenproben wurden mit dem MultiSpec® gemessen (**Abbildung 2**) und anschließend gewogen. Nach der Messung wurden die Bodenproben in abgedeckten Stechzylindern zur Entwässerung auf ein Sandbett gesetzt. Nach einem Tag wurde die Messung wiederholt, die Bodenprobe erneut gewogen und anschließend wurden die Bodenproben zur weiteren Entwässerung erneut auf das Sandbett gesetzt. Es sollte eine gleichmäßig durchfeuchtete ungestörte Bodenprobe mit verschiedenen Feuchtestufen zu den Messungen vorliegen. Diese Prozedur wurde insgesamt achtmal wiederholt. Nach der letzten Messung wurden die Bodenproben bei 105° Grad für 24 Stunden im Trockenofen getrocknet, nach der Abkühlung gewogen und abschließend mit dem MultiSpec® vermessen. Durch Rückrechnung der Taragewichte zu den verschiedenen Feuchtestufen wird die entsprechende Bodenfeuchtigkeit gravimetrisch ermittelt.

$$\text{Wassergehalt der Probe} = \frac{\text{Probengewicht(feucht)} - \text{Probengewicht(trocken)}}{\text{Probengewicht(trocken)}} \cdot 100$$

Formel 2: Berechnung des Wassergehalts der Bodenproben

Der gebildete spektrale Wasserindex (**Formel 1**) und die gravimetrisch ermittelte Bodenfeuchte (**Formel 2**) wurden abschließend bei der Analyse in Beziehung gesetzt.



Abbildung 2: Messaufbau im Labor, die ungestörte Bodenprobe im Stechzylinder wurde unterhalb des optischen Fensters platziert, die rechte Abbildung zeigt im Detail den Abstand zwischen optischem Fenster und der Bodenprobeoberfläche

3 Ergebnisse

Die durchgeführten Labormessungen haben bestätigt, dass die NIR-Spektroskopiemessung zur Bestimmung der Bodenfeuchte an ungestörten Bodenproben grundsätzlich geeignet ist. Mit Hilfe des gebildeten WI konnten unterschiedliche Feuchtestufen an den Bodenproben ermittelt werden. Mit steigendem Wassergehalt sinkt die Intensität im Wellenlängenbereich von 1450 nm ab. Im Vergleich dazu bleibt der Wellenlängenbereich im Bereich von 1230 nm unbeeinflusst (**Abbildung 3**).

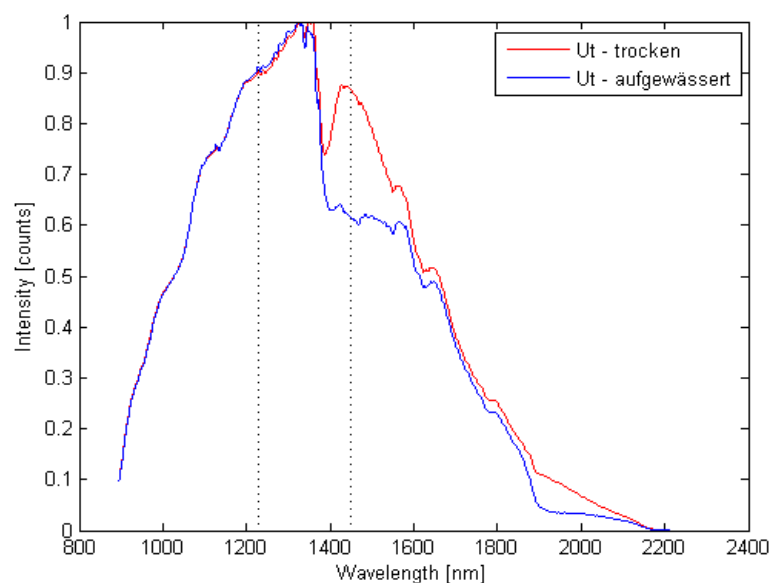


Abbildung 3: Vergleich der Kurvenverläufe einer aufgewässerten und ofentrockene Bodenprobe mit ausgewählten Wellenlängen für die WI-Bildung (1230 nm und 1450 nm)

Wird der spektrale Wasserindex anhand der beiden Wellenlängenbereiche 1230 nm und 1450 nm errechnet und in Beziehung zu den ermittelten Bodenfeuchtigkeitsgehal-

ten gesetzt, zeigt sich ein guter Zusammenhang zwischen dem gebildeten WI und der gravimetrisch ermittelte Bodenfeuchte (**Abbildung 4**). Mit sinkender Bodenfeuchte steigt der spektrale Wasserindex. Die Labormessdaten zeigen, dass die Bodenart keinen Einfluss auf die Messung in den gewählten Wellenbereichen hat.

4 Diskussion

Die Messung der Bodenfeuchtigkeit mit Hilfe von NIR-Spektroskopie an ungestörten Bodenproben ist möglich. Hierzu liegen umfangreiche Literaturquellen vor (z.B. SIMS & GAMON 2002, HUMMEL *et al.* 2001). Ziel dieser Untersuchung war es, einen modellhaften Messaufbau im Labor zu entwickeln, welcher an den praxisüblichen Bodenprobennehmer implementiert werden kann. Des Weiteren ist der Messaufbau in Bezug auf die Messanordnung für die Messung an ungestörten Bodenproben im Labor zu evaluieren. Dieses ist erwartungsgemäß erfolgreich gelungen und somit ist eine entscheidende Voraussetzung für eine online-Messung direkt im Feld für mobile Anwendungen erfüllt.

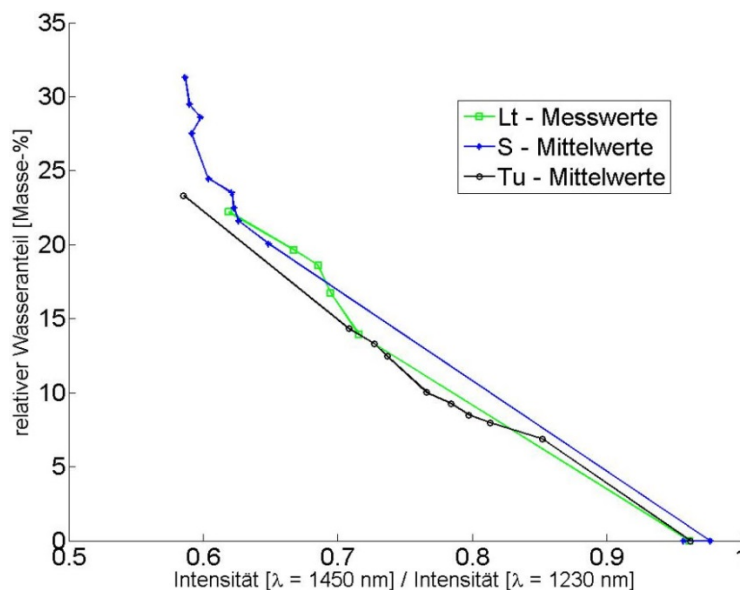


Abbildung 4: Darstellung der Kurvenverläufe des Zusammenhangs des WI und Bodenfeuchte für 3 ausgewählte Bodenarten, Bodenarten: S = Sand, Lt = toniger Lehm, Tu = schluffiger Ton

Es wurde bereits ein Konzept für ein NIR-Bodenfeuchtigkeitmesssystem für die Feldmessungen entwickelt und als Aufbau auf Basis einer kommerziell verfügbaren Bodenbeprobung-Plattform der Fa. Bodenprobetechnik Nietfeld GmbH implementiert (**Abbildung 5**). Hierzu soll die Messung an entnommenem Bodenmaterial durchgeführt werden. Dazu ist eine spezielle Messkammer entwickelt und am Fuße des Bodenprobennehmers montiert worden. Durch diese Messkammer wird der Bohrstock geführt. Der Bohrstock wird automatisch in den Boden getrieben und anschließend wieder automatisch hochgezogen. Das entnommene Bodenmaterial befindet sich in der Nut des Bohrstockes. Das Bodenmaterial in der Nut des Bohrstockes wird beim Hochziehen des

Bohrstockes am NIR-Messsystem vorbeigeführt und zeitgleich gemessen. Dazu wird die NIR-Messung mit der vordefinierte Messtiefe sowie die georeferenzierte Position mit Hilfe von GNSS-Daten abgespeichert.




Abbildung 5: Technische Umsetzung für eine NIR-Spektroskopie Anwendung als mobile Lösung für den Feldeinsatz; linke Abbildung zeigt die Messkammer; rechte Abbildung zeigt die Messkammer an einem praxisüblichen Bodenprobennehmer montiert, das Bodenmaterial im Bohrstock wird beim Hochziehen des Bohrstock gemessen.


Danksagung

Die Förderung des Vorhabens „soil2data“ erfolgt aus Mitteln des Bundesministeriums für Ernährung und Landwirtschaft (BMEL) aufgrund eines Beschlusses des deutschen Bundestages. Die Projektträgerschaft erfolgt über die Bundesanstalt für Landwirtschaft und Ernährung (BLE) im Rahmen des Programms zur Innovationsförderung.

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages



Literaturverzeichnis

- BAHAROM S.N.A., SHIBUSAWA S., KODAIRA M., KANDA R. (2015):** Multiple-depth mapping of soil properties using a visible and near infrared real-time soil sensor for a paddy field. *Engineering in Agriculture, Environment and Food*, 8(1), S. 13–17.
- HUMMEL J.W., SUDDUTH K.A., HOLLINGER S.E. (2001):** Soil moisture and organic matter prediction of surface and subsurface soils using an NIR soil sensor. *Computers and electronics in agriculture*, 32(2), S. 149–165.
- KRONSBELN C.F., VOLKE F., SCHMITT D., BENECKE M., SCHNIEDERBRUNS B., BERGHAUS A., MARTINEZ J., HUFENDIEK H., RUCKELSHAUSEN A. (2013):** Magnetische Resonanz- und Nah-

Infrarot-Sensorsysteme zur Online-Messung der Feuchte bei Erntegütern. In: Massendatenmanagement in der Agrar- u. Ernährungswirtschaft, 33. GIL-Jahrestagung, S. 175–178.

KWEON G., MAXTON C. (2013): Soil organic matter sensing with an on-the-go optical sensor. *Biosystems engineering*, 115(1), S. 66–81.

LUDWIG B., MURUGAN R., PARAMA V.R., VOHLAND M. (2018): Use of different chemometric approaches for an estimation of soil properties at field scale with near infrared spectroscopy. *Journal of Plant Nutrition and Soil Science*, 181(5), S. 704–713.

MILTZ J. A. (2016): Analysing soil organic carbon using near infrared spectroscopy in the laboratory and in the field on-line. Dissertation an der Technischen Universität Carolo-Wilhelmina zu Braunschweig.

MOUAZEN A.M., DE BAERDEMAEKER J., RAMON H. (2005): Towards development of on-line soil moisture content sensor using a fibre-type NIR spectrophotometer. *Soil and Tillage Research*, 80(1–2), S. 171–183.

MUKHERJEE S., LASKAR S. (2019): Vis–NIR-based optical sensor system for estimation of primary nutrients Soil. *Journal of Optics*, S. 1–17. (<https://doi.org/10.1007/s12596-019-00517-1>).

PHOHL P. (2016): Soil Quality of kikuyu, ryegrass and clover pasture mixtures in the Tsitsikamma. Master-Thesis an der Fakultät Natural and Agriculture Sciences, Universität Free State Blomstein, Südafrika.

SIMS D.A. und GAMON J.A. (2002): Estimation of vegetation water content and photosynthetic tissue area from spectral reflectance: a comparison of indices based on liquid water a. chlorophyll absorption features. *Remote Sensing of Environment*, 84, S. 526–537.

SORENSEN P.T., SMALL C., TAPPERT M.C., QUIDEAU S.A., DROZDOWSKI B., UNDERWOOD A., JANZ A. (2017): Monitoring organic carbon, total nitrogen, and pH for reclaimed soils using field reflectance spectroscopy. *Canadian Journal of Soil Science*, 97(2), S. 241–248.

SORIANO-DISLA J.M., JANIK L.J., VISCARRA ROSSEL R.A., MACDONALD L.M., McLAUGHLIN M.J. (2014): The performance of visible near-and mid-infrared reflectance spectroscopy for prediction of soil physical, chemical and biological properties. *Applied Spectroscopy Reviews*, 49, S. 139–186.

THIEL M. (2018): Bildgebende NIR-Hyperspektral-Technologie zur in-situ Erfassung des Blattwassergehalts. Dissertation an der Gottfried Wilhelm Leibniz Universität zu Hannover.

Internet-Adressen

Veris Inc.: iScan. <https://www.veristech.com/the-sensors/iscan--2> (letzter Aufruf: 01.03.2019)

Precision Planting: Smart Firmer.

<https://www.precisionplanting.com/products/product/smartfirmer> (letzter Aufruf: 01.03.2019)

Drone-based Land Surface Temperature Retrieval of Agricultural Areas

UAV-basierte Ableitung der Landoberflächen-Temperatur von Agrarflächen

Sascha Heinemann, Bastian Siegmann, Uwe Rascher

Forschungszentrum Jülich GmbH / Universität Bonn, IBG-2, Vivatsgasse 8, 53111 Bonn

E-Mail: s.heinemann@uni-bonn.de

Zusammenfassung: Die fernerkundliche Erfassung der Landoberflächentemperatur (LST) ist für das Verständnis der Wechselwirkungen zwischen turbulenter Wärmeflüsse und langwelliger Infrarotstrahlung auf lokaler und regionaler Raumskala von entscheidender Bedeutung. Daraus abgeleitete biophysikalische Zusammenhänge bilden die Grundlage für verschiedene Umweltfragestellungen und Anwendungen in der Landwirtschaft, dazu zählt die Abschätzung der Evapotranspiration (ET), das Bewässerungsmanagement und die Präzisionslandwirtschaft (*precision farming*). Um möglichst präzise Oberflächentemperaturen zu abzuleiten, ist die genaue und zeitnahe Bestimmung des spezifischen Emissionsgrads der Landoberfläche (LSE) erforderlich. Aufgrund der sich ändernden Landnutzung und Landbedeckung (LULC) jedoch ist der Emissionsgrad stark variabel. Dadurch kommt es in Regionen mit hochdynamischem Emissionsgrad zu großen Diskrepanzen zwischen abgeleiteten LST- und Felddaten, diese zu überwinden, die derzeitige Herausforderung in der thermalen Fernerkundung bildet. Wir stellen hier eine auf definierte Schwellenwerte des normalisierten Differenz-Vegetationsindex (NDVI) basierende Methode vor, bei der der Emissionsgrad pixelweise bestimmt wird, um zwischen verschiedenen Landoberflächentypen zu unterscheiden. Zu diesem Zweck haben wir einen unbemannten Starrflügler (*unmanned aerial vehicle, UAV*) mit einem dualen Sensorsystem ausgestattet, der simultan sowohl multispektrale sichtbare und Nahinfrarot- (VNIR) als auch thermische Infrarot-Bilder (TIR) erfasst. Mit diesem UAV wurden über einem Forschungscampus in Deutschland (Campus Klein-Altendorf) Flug-Kampagnen unternommen, um die heterogenen und vielfältigen landwirtschaftlichen Pflanzensysteme abzubilden. Wir entwickelten eine umfangreiche Prozesskette zur Erzeugung von Ortho-Mosaiken aus den aufgenommen VNIR- und TIR-Daten, um daraus LST- und LSE-Karten des gesamten Untersuchungsgebiets zu generieren. Darüber hinaus wurden atmosphärische Korrekturen durchgeführt und die thermische Reflexion berücksichtigt, um die Unsicherheiten der Ergebnisse zu minimieren. Durch Analysen der korrigierten LST, im Vergleich zur nichtkorrigierten Helligkeitstemperatur am Sensor (*brightness temperature, BT*), haben wir die Notwendigkeit einer exakten Bestimmung

der LSE verdeutlicht, um potentielle Fehler zu vermeiden, und die Konsequenzen aufgezeigt, wenn essentielle Parameter zur Korrektur der LST unberücksichtigt bleiben. Schließlich nutzten wir die LST, um den Zustand eines Rapsfeldes zu untersuchen. Dabei zeigte sich, dass definierte Temperaturschwellenwerte zur Erkennung von gestressten Getreidevarietäten verwendet werden können.

Deskriptoren: UAV, Thermalinfrarot, Multispektral-VNIR, LST, LSE, NDVI-Schwellenwerte, landwirtschaftliche Kartierung

Abstract: *Observations of land surface temperature (LST) play a critical role in understanding interactions of turbulent heat fluxes and long-wave infrared radiation from local to global scale. This knowledge is fundamental for various environmental studies and applications in agriculture, such as evapotranspiration (ET) estimation, irrigation management, and precision farming. Due to changing land use and land cover (LULC), land surface emissivity (LSE) is highly variable. Thus, in regions with highly dynamic emissivity the current challenge for remote sensing approaches is to overcome larger deviations between retrieved LST and field data. Hence, an accurate and timely determination of LSE is required to retrieve precise LST. We here present a procedure, where we constrained LSE per pixel based on thresholds of the normalized difference vegetation index (NDVI) to distinguish between different land surface attributes. We used a fixed-wing unmanned aerial system (UAS), which was equipped with a dual sensor configuration that simultaneously acquires multispectral visible and near-infrared (VNIR) and thermal infrared (TIR) images. This UAS was applied to map the heterogeneous and diverse agricultural crop systems of a research campus in Germany. We developed a processing chain to generate TIR and VNIR ortho-mosaics, which were then used to compute LST and LSE maps of the entire study site. We also performed atmospheric correction and included thermal reflectance to minimise uncertainties. In analysis of the corrected LST, we indicated the importance of accurately estimating LSE to avoid errors and the consequences of omitting essential parameters to correct the retrievals. We finally used LST to study the state of a rapeseed field and to demonstrate the benefit of certain temperature thresholds, which can be used to detect stressed crop.*

Keywords: UAV, thermal infrared, multispectral VNIR, LST, LSE, NDVI thresholds, agricultural mapping

Felddetektion von Blattkrankheiten des Weizens mit Hyperspektralsensoren

Field-detection of wheat foliar diseases using hyperspectral sensors

David Bohnenkamp¹, Jan Behmann¹, Anne-Katrin Mahlein²

¹Universität Bonn, Institut für Nutzpflanzenwissenschaften und Ressourcenschutz,
Pflanzenkrankheiten und Pflanzenschutz, Nussallee 9, 53115 Bonn

²Institut für Zuckerrübenforschung (IfZ), Holtenser Landstraße 77, 37079 Göttingen
E-Mail: davidb@uni-bonn.de

Zusammenfassung: Im Sinne des Integrierten Pflanzenschutzes ist es von großer Bedeutung innovative Verfahren zu erproben, um den Einsatz von Pflanzenschutzmitteln zielorientiert und bedarfsgerecht zu gestalten. In diesem Projekt nutzen wir Hyperspektralkameras, um Blattkrankheiten des Weizens unter Feldbedingungen zu detektieren. In der Vegetationsperiode 2018 wurde ein Feldversuch mit Winterweizensorten verschiedener Anfälligkeiten gegenüber Blattkrankheiten durchgeführt. Die auf dem Standort „Campus Klein-Altendorf“ der Universität Bonn vorherrschende Witterung begünstigte das Auftreten und die Ausbreitung der beiden Rostkrankheiten Gelbrost und Braunrost. Mit wöchentlichen Hyperspektralmessungen wurde die spektrale Dynamik des Pflanzenbestandes unter Krankheitsdruck über die Vegetationsperiode dokumentiert. Die Hyperspektralsensoren wurden hierfür auf einer Messplattform direkt über den Pflanzenbestand über den Feldversuch bewegt. Die genutzte Sensorik deckte den Bereich des sichtbaren und des Nahinfrarotlichtes (400–1000 nm) ab. Die Definition von Messprotokollen und die Charakterisierung von Eigenschaften der Messplattformen war ein zentraler Punkt der Arbeit, um vergleichbare und reproduzierbare Ergebnisse multitemporal generieren zu können. Moderne Analyseverfahren zur Verarbeitung von Hyperspektraldaten wurden genutzt, um das generelle Auftreten von Pflanzenkrankheiten zu erkennen und diese Pflanzenkrankheiten zu identifizieren.

Das generierte Wissen soll der Entwicklung von robusten Krankheitserkennungsroutinen dienen, die das Potential haben, den Pflanzenschutz präziser und ressourcenschonender zu gestalten.

Deskriptoren: Hyperspektralkameras, Blattkrankheiten, Felddetektion, teilflächenspezifisch

Abstract: *For the purpose of integrated plant protection, it is of high relevance to include recent and future innovations into plant protection management. We assume that*

hyperspectral sensors are promising for a site specific detection of disease dynamics in field crops. In the vegetation period 2018 a field trial was conducted at the location "Campus Klein Altendorf" in Meckenheim, Germany. During the vegetation period prevalent weather conditions favored the occurrence and spread of the wheat diseases yellow rust and brown rust. Hyperspectral sensors were used to detect foliar diseases on winter wheat cultivars with differing susceptibilities. Measurements were carried out weekly to document the spectral dynamic of a wheat canopy under disease pressure during vegetation period. The hyperspectral cameras were mounted and moved on a field platform directly above the plant canopy. The sensors covered the spectral range from the visible to the near infrared light (400–1000 nm). To gain comparable and reproducible (multi-temporal) measurement results, the definition of measurement protocols and the design of the sensor platform was a central point of this work. First results of in-field detection and classification of rust diseases will be presented, covering different stages of plant and disease development. The gathered information will be used to develop robust disease detection routines with the potential to develop future plant protection measures more resource-conserving.

Keywords: *hyperspectral cameras, foliar diseases, field-detection, site-specific*

1 Einleitung

Spektrale Veränderung des Pflanzenbestandes im Freiland können vielfältige Ursachen haben, z.B. natürliche Wachstumsprozesse während der Vegetationsperiode, abiotische Stressoren oder aber Krankheiten. In vielen wissenschaftlichen Arbeiten wurde gezeigt, dass Hyperspektralsensoren in der Lage sind, im Verlauf der Pathogenese zwischen einer Kulturpflanze und einem pilzlichen Erreger von Pflanzenkrankheiten spezifische Veränderungen zu detektieren (MAHLEIN 2016). Der Einsatz von Hyperspektralsensoren im Feld ist jedoch komplex und stellt höchste Ansprüche an das Equipment und Umweltbedingungen. Konstante Wetterbedingungen, sowie die Möglichkeit Daten zu prozessieren und in einheitlicher Form aufzubereiten sind hierfür von zentraler Bedeutung (BRAVO *et al.* 2003; BRAVO *et al.* 2004). Ziel dieser Arbeit ist es, die durch Rostkrankheiten des Weizens verursachten Veränderungen des Pflanzenbestandes zu charakterisieren und für eine Krankheitsdetektion in einer Datenbank nutzbar zu machen. Eine automatisierte spektrale Detektion von Pflanzenkrankheiten birgt einen nächsten Schritt in die Richtung, im Feld auf bekämpfungswürdigen Befall zu reagieren und teilflächenspezifisch zu bekämpfen, um somit ökonomische und ökologische Vorteile durch Mitteleinsparungen zu erzielen (WEST *et al.* 2003; MAHLEIN *et al.* 2018).

2 Material und Methoden

In der Vegetationsperiode 2017/18 wurde ein Feldversuch mit Winterweizen (*Triticum aestivum* L.) auf dem Versuchsgut der Universität Bonn, Campus Klein-Altendorf in Meckenheim angelegt. Die Sorten 'Asano' (gelbrostanfällig) und 'Bussard' (braunrostanfällig) wurden aufgrund unterschiedlicher Anfälligkeit gegen Rostkrankheiten ausgewählt.

So konnten die Krankheiten getrennt voneinander auf verschiedenen Sorten betrachtet und Mischinfektionen weitgehend vermieden werden. Der Feldversuch wurde als randomisierter Parzellenversuch angelegt. Um das Auftreten von Rostkrankheiten zu fördern, wurden Parzellen zusätzlich mit den Pathogenen *Puccinia triticina* und *P. striiformis* inokuliert. Die Entwicklung der Rostkrankheiten wurde im Verlauf der Vegetationsperiode durch wöchentliche Krankheitsbonituren erfasst. Die Hyperspektralsensoren wurden auf einer Feldmessplattform befestigt, die manuell einmal pro Woche über den Versuch bewegt wurde. Als Hyperspektralkameras wurden die Specim V10e (Specim, Finnland) und die Rikola-Hyperspektralkamera (Rikola Ltd Oy, Finnland) verwendet. Für die Auswertung von Hyperspektralbildern wurden überwachte Klassifikationen eingesetzt. Diese Klassifikationen wurden mit *Support Vector Machines* (SVM) und dem *Spectral Angle Mapper* (SAM) durchgeführt. Um die Klassifikatoren zu trainieren, wurden Hyperspektralbilder annotiert und die spektrale Information als *Endmember* für die überwachte Klassifikation genutzt.

Die Verwendung von SVM stellt eine überwachte Klassifikationsmethode dar, die eine Reihe von Objekten so in Klassen unterteilt, dass die Grenzbereiche um die einzelnen Klassen herum maximiert werden. Die SVM nutzt das Spektrum jedes Pixels und bildet keinen Mittelwert aus einer Menge von Spektren einer Gruppe. Der SAM ermittelt das Maß der spektralen Ähnlichkeit zwischen einem Referenzspektrum und dem zu klassifizierenden Pixel über den Winkel der Vektoren zueinander. Anhand von Mittelwerten, die aus den Trainingsdaten abgeleitet werden, unterteilt er die Pixel in unterschiedliche Klassen.

3 Ergebnisse

Die klimatischen Bedingungen am Untersuchungsstandort begünstigten die Entwicklung von Gelbrost. Über mehrere Wochen konnte die Ausbreitung der Krankheit dokumentiert werden. Die Befallsgrade rangierten in den unbehandelten Varianten in einem Bereich von bis zu 90 % auf F-4 und bis zu 20 % auf F, wobei (an späteren Messterminen) das Fahnenblatt und F-1 bezogen auf die sichtbare Blattfläche im Bild eine größere Anteilsgewichtung ausmachten als F-2-4. Zur Evaluation der Daten wurde ein im Bild sichtbarer Befall als gewichtetes Mittel der Blattetagen gebildet. Braunrost trat ab dem 23.05.–05.06. mit 15-20 % befallener Blattfläche auf. Die kurze Vegetationsperiode bewirkte jedoch eine frühe Abreife, wodurch die weitere epidemiologische Ausbreitung der Krankheit gestoppt wurde.

Die Anwendung von Klassifikatoren auf Hyperspektralbildern zeigte, dass mittels SVM und SAM Rostkrankheiten detektiert werden konnten. Die SVM zeigte hierbei ein großes Potential für die Detektion von Gelbrost. Gelbrostsymptome wurden sicher erkannt und klassifiziert (**Abbildung 1**). Die Klassifikation des SAM zeigte, dass der Algorithmus Symptome auf den unteren Blättern als Krankheit klassifizierte jedoch Probleme mit der richtigen Klassifikation der obersten Pflanzenorgane wie Fahnenblätter und Ähren hatte (**Abbildung 2**).




Abbildung 1: Vergleich der RGB Visualisierung des Hyperspektralbildes mit dem Klassifikationsergebnis der *Support Vector Machine*




Abbildung 2: Vergleich der RGB Visualisierung des Hyperspektralbildes mit dem Klassifikationsergebnis des *Spectral Angle Mapper*

4 Diskussion

Der Einsatz und Erfolg von Hyperspektralkameras ist von vielen Faktoren abhängig. So haben lokale Umweltbedingungen einen bedeutenden Einfluss auf die Messungen und

somit auf die Qualität und Interpretierbarkeit von hyperspektralen Datensätzen. Besonders Wind und sich ändernde Strahlungsintensität der Sonne beeinflussen die Datenqualität auf negative Weise (BRAVO *et al.* 2003; BRAVO *et al.* 2004; WEST *et al.* 2003). Der Abstand der Pflanze zur Kamera hat ebenfalls einen großen Einfluss. Die deutlich helleren Fahnenblätter und Ähren des Weizenbestandes führten beim SAM zu Falschklassifikationen in den oberen Bereichen, da die Reflektionsintensität deutlich höher ist, als die der unteren Blattetagen. Die SVM zeigte eine deutlich bessere Klassifikation im Bereich der Fahnenblätter. Dieser Vorteil könnte an der Fähigkeit liegen, komplexe Klassengrenzen explizit zu modellieren, wobei der SAM nur wenige Archetypen zur Repräsentation der Klassenverteilung nutzen kann. In Bereichen mit hoher Dynamik, wie den Blattspitzen, wirken diese Eigenschaften dann negativ auf die Klassifikation aus. Die Ergebnisse zeigen das Potential von Spektalkameras für die Felddetektion von Pflanzenkrankheiten. Zukünftige Arbeiten werden sich mit der robusten und insbesondere vollautomatisierten Detektion und Identifikation von Pflanzenkrankheiten in hyper- oder multispektralen Datensätzen beschäftigen.

Literaturverzeichnis

- BRAVO C., MOSHOU D., WEST J., MCCARTNEY A., RAMON H., (2003):** Early disease detection in wheat fields using spectral reflectance. *Biosystems Engineering* 84, 137–145.
- BRAVO C., MOSHOU D., OBERTI R., WEST J., MCCARTNEY A., BODRIA L., RAMON H. (2004):** Foliar disease detection in the field using optical sensor fusion. *Agricultural Engineering International* 6.
- MAHLEIN AK., KUSKA MT., BEHMANN J., POLDER G., WALTER A. (2018):** Hyperspectral sensors and imaging technologies in phytopathology: State of the art. *Annual Review of Phytopathology* 56, 535–558.
- MAHLEIN AK. (2016):** Plant disease detection by imaging sensors – parallels and scientific demands for precision agriculture and plant phenotyping. *Plant Disease* 100, 241–51.
- WEST J., BRAVO C., OBERTI R., LEMAIRE D., MOSHOU D., MCCARTNEY A., RAMON H. (2003):** The potential of optical canopy measurement for targeted control of field crop diseases. *Annual Review of Phytopathology* 41, 593–614.

Erfassung der Vitalität des Deutschen Weidelgrases mit Hilfe von RGB- und NIR-Aufnahmen

Capturing the vitality of the German ryegrass with the help of RGB and NIR images

Sandra Münzel¹, Oswald Blumenstein²

¹Universität Potsdam, Institut für Umweltwissenschaften und Geographie,
Karl-Liebknecht-Straße 24–25, 14476 Potsdam-Golm

²InterEnviroCon GmbH, Arthur-Scheunert-Allee 2, 14558 Nuthetal
E-Mail: smuenzel@uni-potsdam.de

Zusammenfassung: Aktuelle Klimaprognosen weisen auf ein verändertes Auftreten von Niederschlägen sowie auf eine Erhöhung der Durchschnittstemperaturen hin. So sollen laut dieser Voraussagen zukünftig Dürreperioden, wie sie beispielsweise im Jahr 2003, 2015 oder 2018 auftraten, häufiger werden. Überdies ist vor allem im landwirtschaftlichen Sektor durch eine übermäßige Bewässerung ein hoher Verbrauch an Süßwasser zu verzeichnen. Wassermangel während der Wachstumsphase kann vor allem bei Kulturpflanzen zu verminderten Erträgen führen. Das weltweite Süßwasserdargebot wird somit in Zukunft ein limitierender Faktor sein. So müssen in der Pflanzenproduktion Strategien für ein präzises und nachhaltiges Management der Bewässerung an trockenen Standorten entwickelt werden.

Vorrangiges Ziel des Forschungsprojektes ist es, einen Beitrag zur Sicherung langfristig stabiler landwirtschaftlicher Erträge zu leisten, welche den sich veränderten Niederschlagsmengen und -intensitäten sowie Temperaturbedingungen Rechnung trägt.

Im Rahmen eines Teilprojektes stand die Entwicklung einer kostengünstigen sowie einfachen Methode zur Vitalitätsbestimmung der Nutzpflanzen im Fokus. Mithilfe dieses Verfahrens soll eine Änderung der Vitalität durch Trockenstress, im Gegensatz zur bisher gängigen Beurteilung der Pflanzen über ihr phänologisches Erscheinungsbild, wesentlich früher und differenzierter erkennbar sein. Durch das lokale Monitoring des Wachstums der Kulturpflanzen mit Hilfe von technischen Systemen sollen zukünftig Trockenstressphänomene frühzeitig feststellbar sein, um rechtzeitig und gezielt Gegenmaßnahmen ergreifen zu können.

Dieser Beitrag beschäftigt sich mit den Unterschieden in der visuellen Erfassung und der foto-optischen Bestimmung der Vitalität von Deutschem Weidelgras (*Lolium perenne*), welches in einem Gefäßversuch einem künstlichen Wassermangel ausgesetzt wurde.

Die foto-optische Erfassung des Vitalitätszustandes der Versuchspflanze *Lolium perenne* erfolgte auf Grundlage von Spektraldaten zweier handelsüblicher Digitalkameras.

Eine erste ist mit einer Optik für das sichtbare Licht ausgestattet, eine zweite nimmt die Signale in den Spektralbereichen grün, blau und nahes Infrarot auf. Die Bestimmung der Pflanzenvitalität wurde einerseits mittels des Normalisierten Differenzierten Vegetationsindex (NDVI) und andererseits anhand einer Vitalitätstabelle mit visueller Bewertung vorgenommen.

Die Ergebnisse der Untersuchungen zeigten bei Verwendung der spektralen Daten eine deutlich differenziertere Erfassung der pflanzlichen Vitalität und bis zu fünf Tage frühere Erkennung des Vitalitätsverlustes. In der Konsequenz kann die Vitalitätsbestimmung über den NDVI eine geeignete Methode zur frühzeitigen Erkennung von Trockenstress sein. Sie bietet noch reichlich Potential für weitergehende Untersuchungen.

Die durchgeführten Arbeiten liefern einen ersten Ansatz für die Möglichkeiten der Berechnung des NDVI zur Trockenstresserkennung unter „Low-Budget“-Bedingungen. Sie zeigen, dass es nicht immer notwendig ist, auf ein kostenintensives Equipment zurückzugreifen. Überdies stellen die Ergebnisse eine gute Grundlage zur weiteren Verbesserung des Bewässerungsmanagements dar.

Deskriptoren: Weidelgras, NDVI, Trockenstress, Vitalität, Low-Budget-Kamera

Abstract: *Current climate forecasts indicate a change in precipitation and an increase in average temperatures. According to these predictions, drought periods, such as occurred in 2003, 2015 or 2018, will become more frequent in the future. Excessive irrigation especially in the agricultural sector causes a high consumption of fresh water. But a lack of water during the growth phase can lead to reduced yields, especially for crops. The global supply of fresh water will thus be a limiting factor in the future. Strategies for precise and sustainable irrigation management in dry locations need to be developed in crop production.*

The primary objective of the research project is a contribution for securing stable agricultural yields, which take into account the changing precipitation amounts and intensities as well as temperature conditions.

Focus of the subproject was the development of a cost-effective and simple method for determining the vitality of crops. With this method, a change in vitality due to drought stress should be recognizable much earlier and more differentiated than common assessment of phenological appearance. Local monitoring of drought-stress phenomena in crop growth should be detectable with the help of technical systems. They should enable timely and targeted countermeasures.

*This part deals with differences in visual recording and the photo-optical determination of the vitality of perennial ryegrass (*Lolium perenne*). The grass was exposed to an artificial water deficit in a pot experiment. The photo-optical recording of the state of vitality of *Lolium perenne* was based on spectral data of two commercial digital cameras. A first is equipped with optics for visible light. A second picks up the signals in the spectral ranges green, blue and near infrared. The determination of the plant vitality was carried*

out on the one hand by means of the Normalized Differentiated Vegetation Indices (NDVI) and on the other hand by means of vitality with visual evaluation.

The results of the investigations showed a significantly more differentiated assessment of plant vitality. By using the spectral data it was possible to detect the loss of vitality up to five days earlier. As a consequence, determination of vitality by NDVI can be a suitable method for the early detection of drought stress. It also offers plenty of potential for further investigations.

The results provide a first approach to possibilities of calculating the NDVI for drought stress detection with "low-budget" conditions. They show that it is not always necessary to use expensive equipment. Moreover, the results provide a good foundation for further improving irrigation management.

Keywords: ryegrass, NDVI, drought stress, vitality, low-budget-camera

1 Einleitung

Wasser ist die Quelle allen Lebens auf der Erde. Dabei macht das lebensnotwendige Süßwasser lediglich 2,5 % der gesamten Wassermenge aus. Der weltweite Wasserverbrauch hat sich von 1930 bis 2000 aufgrund der starken Bevölkerungszunahme sowie des höheren durchschnittlichen Pro-Kopf-Verbrauchs etwa versechsfacht (BARTEL *et al.* 2016). Mit ungefähr 70 % der Menge besitzt der Agrarsektor mit Abstand den größten Anteil. Heute werden fast 40 % der pflanzlichen Nahrungsmittel mithilfe der Bewässerungslandwirtschaft erzeugt. Den Pflanzen soll dabei nach Bedarf Wasser zugeführt werden. Demgegenüber steht eine Schädigung der Vegetation infolge Wassermangels bei verspäteter oder nicht ausreichender Bewässerung. Um diese negativen Folgen zu vermeiden, ist ein präzises Wissen zur Vitalität der zu bewässernden Pflanzen notwendig (POSTEL 2001).

Das Ziel der Forschungen war die Entwicklung einer kostengünstigen sowie einfachen Methode zur Vitalitätsbestimmung, um bei Kulturpflanzen einsetzenden Trockenstress frühestmöglich zu erkennen und so das Bewässerungsmanagement weiter optimieren zu können. Zudem sollte mithilfe der zu entwickelnden Methode eine Vitalitätsänderung der Pflanzen, verursacht durch Trockenstress, so früh wie möglich erkannt werden.

Aus diesem Grund ist die Vitalität von Graspflanzen, die künstlich einem Wasserdefizit ausgesetzt wurden, untersucht worden. Zum einen erfolgte die Vitalitätsbestimmung der Vegetation wie üblich über das äußere Erscheinungsbild (visuell) und zum anderen über die Auswertung der spektralen Daten mithilfe des Normalisierten Differenzierten Vegetationsindex (foto-optisch). Es galt dabei, Unterschiede zwischen beiden zu identifizieren. Darüber hinaus konnten gleichzeitig die Effekte eines Bodenergänzungstoffes auf die Vitalität der Vegetation untersucht werden.

Als Versuchspflanze wurde das in Deutschland häufig vorkommende Deutsche Weidelgras gewählt. Deutsches Weidelgras (*Lolium perenne* L.), auch Ausdauernder Lolch oder Englisch Raygras, gehört zu den Süßgräsern. Es kann bis zu 90 cm hoch wer-

den, wurzelt bis zu einem Meter tief und entwickelt lockere bis dichte Horste. Die Oberseite der Blätter ist glatt oder rau, die Unterseite stark glänzend und glatt (LENUWEIT *et al.* 2002). *Lolium perenne* wächst auf stickstoff- sowie nährstoffreichen Lehm- und Tonböden. Hinsichtlich des Nährstoff-, Ton- und Feuchtigkeitsgehaltes des Bodens gilt es als Zeigerpflanze (BUNDESSORTENAMT 2017, LENUWEIT *et al.* 2002). Als Teil von Trittpflanzengesellschaften findet das Deutsche Weidelgras vor allem als Futter- und Rasengras Verwendung. In diesem Fall ist es schnittverträglich, sehr robust, verträglich gegenüber Tritt und häufigem Verbiss. Es besitzt eine gute Trockenheitsresistenz. Die physiologischen Auswirkungen von Trockenstress auf das Deutsche Weidelgras wurden bereits eingehend untersucht (u.a. FOITO *et al.* 2009, BOTHE 2018, KARSTEN & MACADAM 2001).

Zahlreiche Studien zeigen bereits das Potential von foto-optischen Methoden zur frühzeitigen Diagnose von Trockenstress mithilfe verschiedener Spektralindizes. Beim Auftreffen elektromagnetischer Strahlung auf einen Körper kommt es zur Reflexion, Absorption sowie Transmission. Besonders die Reflexion der Strahlung steht im Fokus der Fernerkundung, da diese mithilfe von Empfangseinrichtungen aufgenommen und ausgewertet werden kann. Jeder Körper besitzt eine spezifische Reflexionskurve und damit seine eigene spektrale Signatur (ALBERTZ 2009). Aufgrund der Abhängigkeit der Reflexionseigenschaften von Zellstrukturen, lassen sich Pflanzen mithilfe ihrer artentypischen spektralen Signatur unterscheiden. Während die elektromagnetische Strahlung vor allem im blauen und roten Bereich von den Blattpigmenten im Palisadengewebe absorbiert wird, kann sie im nahen Infrarot dort ungehindert durchdringen.

Als Maß für die Vitalität von Pflanzen dienen sogenannte Vegetationsindizes. Der am häufigsten genutzte Index ist der *Normalized Difference Vegetation Index* (NDVI). Dieser setzt die spektralen Daten aus dem roten Bereich (ROT) mit den Daten aus dem nahen Infrarot (NIR) in Beziehung und wird wie folgt berechnet:

$$\text{NDVI} = (\text{NIR} - \text{ROT}) / (\text{NIR} + \text{ROT}).$$

Durch die Quotientenbildung wird eine Normierung der Werte (zwischen -1 und +1) und weitgehend eine Kompensation der Unterschiede innerhalb der Beleuchtungsverhältnisse erreicht. Negative Werte werden durch Wasser, pedo- oder geogenes Material oder Wolken verursacht. Hier ist die Reflexion innerhalb des sichtbaren Lichts höher als im nahinfraroten Bereich. Positive Werte deuten wiederum auf Vegetation hin. Der NDVI ist neben der Vitalität der Pflanze stark von der damit in Verbindung stehenden photosynthetischen Aktivität sowie dem Grad der Vegetationsbedeckung abhängig (ALBERTZ 2009, FALK 2016).

Die Veränderung der spektralen Eigenschaften aufgrund von Trockenstress bei Pflanzen wurde bereits erkannt (u.a. KIM *et al.* 2011). Die höchste Korrelation ist in dem Red Edge NDVI bei 705 und 750 nm in Schmalbandindizes und dem NDVI bei 680 und 800 nm in Breitbandindizes gefunden worden. Die experimentellen Ergebnisse zeigten, dass optische Sensoren Entscheidungshilfen für die Erkennung von Stress bei Vegetation ermöglichen können. Dennoch bleibt bei Kulturpflanzen bisher ein direkter Ver-

gleich zwischen der visuellen und der foto-optischen Erkennung von Trockenstressanzeichen unerforscht. Es wurden somit auch keine Analysen zu trockenstressinduzierten spektralen Veränderungen beim Deutschen Weidelgras durchgeführt (BELLIN 2018).

2 Material und Methoden

Zur Untersuchung der Vitalität des Deutschen Weidelgrases wurden die Pflanzen im Rahmen eines Gefäßversuchs einem Wasserdefizit ausgesetzt. Aufgrund der hohen Korrelation zwischen den spektralen Eigenschaften der Vegetation und deren Vitalität ist zur foto-optischen Vitalitätsbestimmung der NDVI genutzt worden. Zum Vergleich wurde die Vitalität der Pflanzen visuell untersucht.

Versuchsboden und Bodenergänzungsstoff

Ausgangssubstrat für die Versuchsgefäße war ein Grundmoränen-Substrat aus Golm, einem Ortsteil Potsdams. Nach der bodenkundlichen Kartieranleitung (AD-HOC-AG BODEN 2005) wies das lehmig sandige Substrat (SI3) einen pH-Wert von 6,7, einen Karbonatgehalt zwischen 10 und 25 % und einen Humusgehalt <1% auf.

Der verwendete organische Bodenergänzungsstoff Bodenbalsam-H enthält die für die Pflanzen zum Wachstum benötigten Nährelemente Phosphor, mineralischen Stickstoff, Kalium, Magnesium sowie Calcium. Bodenbalsam-H besteht zu 42 % aus organischer Substanz und besitzt eine neutrale Bodenreaktion (pH-Wert 7,1). Die Zugabe dieses Bodenergänzungsstoffes führt zur Lockerung des Bodens, zur Lieferung und Speicherung von Nährstoffen, zur Säurepufferung und zur Steigerung der Wasserhaltekapazität (INTERENVIROCON GMBH o.J.).

Versuchsanordnung und Standortbedingungen

Das Experiment wurde als Doppelversuch in einem überdachten Raum und unter kontrollierbaren Bedingungen angelegt. Die acht Töpfe mit einem Durchmesser von etwa 10 cm wurden in zwei Reihen an einem lichtbegünstigtem Standort aufgestellt (**Abbildung 1**).

Um die Vitalität des Grases unter Trockenstressbedingungen bestimmen zu können, war neben einer regelmäßig bewässerten Versuchsreihe (Kontrollgruppe) eine zweite angeordnet worden, bei der die Bewässerung ab einer Wuchshöhe von 11 cm eingestellt worden war. Die Halmlänge wurde als Höhengrenze für Aufnahmen der spektralen Daten mithilfe des Kamerasystems festgelegt. Zudem erhielt jeweils die Hälfte jeder Versuchsgruppe eine Zugabe von 5 % Bodenbalsam-H. Jedes Gefäß erhielt eine Codierung entsprechend nachstehender Kriterien:

- Bodenart: *B* = Boden, *BB* = Boden mit 5% Bodenbalsam-H
- Bewässerung: *W* = bewässert, *T* = trocken

- Nummer des Doppelversuchs: = 1, = 2

In jedes Gefäß ist die gleiche Masse an Pflanzensamen gesät worden. Diese wurden mit 150 ml Wasser pro Experimentalgefäß angegossen. Ab dem 17. Tag des Versuches (6. Mai) erhielten die Pflanzen der Versuchsgruppe Trockenstress (B-T und BB-T) kein Wasser mehr. Die Wasserzufuhr der Kontrollgruppe erfolgte entsprechend der Notwendigkeit. Anzeichen hierfür waren ein trockener Boden sowie leicht hängende Halme. Die Untersuchungszeit betrug 35 Tage und endete mit dem Absterben der letzten Pflanzen.




Abbildung 1: Spektralaufnahmen des Weidelgrases am 23. Mai (BELLIN 2018)

Kamerasystem und Spektralon

Die Aufnahme der spektralen Daten erfolgte mit zwei Kompaktkameras:

- Canon Powershot S100 (RGB-Kamera) und
- Canon Powershot S110, für Aufnahmen im Nahinfrarot (von der Firma HEXAPILOTS® modifiziert). Der eingebaute Filter minimalisiert hier die Durchlässigkeit der reflektierten Strahlung im roten Bereich des sichtbaren Lichts und ermöglicht umgekehrt die Transmission von nahinfraroter Strahlung zwischen 680 und 840 nm.

Beide Kameras besitzen jeweils eine Auflösung von 8 Bit. Pro Kanal können die Werte zwischen 0 und 255 liegen. Auf diese Weise war es möglich, die benötigten Daten für die Berechnung des NDVI zu erhalten.

Um die Vergleichbarkeit der Aufnahmen gewährleisten zu können, mussten verschiedene Kriterien eingehalten werden. Zum einen wurden die Digitalkameras auf einer Aluminium-Gleitschiene befestigt (**Abbildung 2**). So konnten Unterschiede innerhalb der Aufnahmewinkel auf ein Minimum reduziert werden. Zum anderen wurden bei beiden Kameras die Einstellungen an allen Untersuchungstagen konstant gehalten und

die Programmautomatik genutzt. Zur Anpassung der ermittelten Grauwerte der Vegetation ist das Spektralon der Firma MicaSense eingesetzt worden (**Abbildung 1**; jeweils mittig).



Abbildung 2: Verwendetes Kamerasystem aus einer Canon Powershot S100 (links) und einer modifizierten Canon Powershot S110 (rechts), beide befestigt auf einer Aluminium-Gleitschiene

Bestimmung der Vitalität

Für die visuelle Erfassung der Pflanzen wurde das durchschnittliche Höhenwachstum der Pflanzen täglich dokumentiert. Zudem ist mittels sechs entwickelter Vitalitätsklassen und konkret definierten Kriterien für jede Klasse, eine tägliche Zuordnung der Gräser erfolgt, wobei Klasse 1 eine sehr gute und Klasse 6 eine besonders schlechte Vitalität der Pflanze bedeutete. Als Kriterien für die einzelnen Klassen dienten die Standfestigkeit ihrer Halme (entsprechend dem Turgor der Pflanzen), die Farbe der Gräser und ihre Wuchsstärke (BELLIN 2018).

Ab dem 16. Tag (5. Mai) bis zum Ende des Versuches (23. Mai) waren die spektralen Daten mithilfe des Kamerasystems täglich erfasst worden. Der Aufnahmezeitpunkt lag in der Regel zwischen 13 und 17 Uhr. Es wurde sowohl künstliches Licht als auch direktes Sonnenlicht gemieden, um Schattenbildungen zu reduzieren und auswertbare Bedingungen zu erreichen. Bei einer überhöhten Helligkeit auf dem Bild wäre eine korrekte Anpassung der Grauwerte mit dem Spektralon nicht mehr möglich.

Unter Nutzung des Bildbearbeitungsprogramms Adobe Photoshop® wurden auf allen Aufnahmen beider Kameras sämtliche Grashalme des Weidelgrases ausgewählt. So erhielt man eine klare Abtrennung zwischen der Umgebung und den Pflanzen. Die Verarbeitung der Grauwerte für die RGB- sowie NIR-Aufnahme und des Spektralon-Werts sowie die Berechnung des jeweiligen NDVI pro Versuchspflanzen erfolgten mit Microsoft® Excel.

3 Ergebnisse und Diskussion

Wie erwartet, zeigte sich bis zum Versuchsende bei den bewässerten Versuchspflanzen eine konstant hohe Vitalität (Klasse 1). Bei den unter Trockenstress gesetzten Pflanzen trat jedoch nach einiger Zeit aufgrund von destruktiven Schädigungen sowie Abwehrmechanismen ein Vitalitätsabfall auf. Nach dem Einsetzen des Wasserdefizits (ab 5. Mai)

behielten zunächst alle Versuchspflanzen noch etwa eine Woche ihre Vitalitätsklasse 1. Ab dem 8. Tag wurden die Trockenstresserscheinungen sichtbar (**Abbildung 3**).




Abbildung 3: Verlauf der Vitalitätsklassen der Versuchspflanzen (visuelle Vitalitätserfassung, n=2)

Das Weidelgras in den Gefäßen mit Bodenergänzungstoffen wurde, unabhängig von dem Bewässerungsstatus, bis 2 cm höher als ohne Zusatz. Das schnellere Wachstum der Pflanzen unter Zugabe von Bodenbalsam-H hat einen erhöhten Wasserbedarf zur Folge. Da der Rückgang des Turgors das erste Anzeichen für Wassermangel ist, war ein Verlust der Stabilität und Festigkeit des Gewebes und damit der Standhaftigkeit die Konsequenz.

Dieser starke Wasserverbrauch führte dazu, dass die unter Trockenstress gesetzten *BB*-Pflanzen zwei Tage früher von der Vitalitätsklasse 1 auf 2 wechselten als die Pflanzen, die sich auf reinem Versuchsboden entwickelten. Die infolge des nährstoffreicheren Bodens erhöhte Wuchskonkurrenz führte bei den kontinuierlich bewässerten *BB*-Pflanzen zum Ende der Untersuchungszeit zu einer niedrigeren Vitalität.

Zu Beginn der Aufnahmezeit (5. Mai) besaßen alle Versuchspflanzen einen vergleichsweise hohen NDVI zwischen 0,60 und 0,65. Im Anschluss kam es bei der Vegetation in allen Gefäßen zu einem Abfall der NDVI-Werte auf 0,55 bis zum 8. Mai (**Abbildung 4**). Bereits am Folgetag stieg die Vitalität der bewässerten Pflanzen auf ein ähnliches Niveau wie zum Anfang der Aufnahmezeit wieder an. Mögliche Ursache des anfänglichen Rückgangs könnte die noch vorherrschende geringe Halmdichte sein. Dies erschwerte die Auswahl der Halme mit Adobe Photoshop.

Während die bewässerten Versuchspflanzen relativ konstant hohe Vitalitätswerte aufwiesen, fand bei den Pflanzen, die unter Wassermangel gesetzt wurden, ein kontinuierlicher Rückgang der Vitalität statt.




Abbildung 4: Verlauf des mittleren NDVI (n=2) der Versuchspflanzen (foto-optische Vitalitätserfassung)

Bei dieser Versuchsgruppe war auffällig, dass in den 14 Tagen vom 6. Mai bis 19. Mai die durchschnittlichen NDVI-Werte der Pflanzen im Versuchsboden ohne Ergänzungsstoff (*B-T*) höher waren als bei den Pflanzen, die einen Zusatz erhalten hatten (*BB-T*). Ab dem 20. Mai erfolgte hier gleichfalls ein starker Rückgang der Pflanzenvitalität (**Abbildung 4**). Zu den Möglichkeiten einer Vorhersage von Trockenstress ist festzustellen, dass die Pflanzen in den Experimentalgefäßen ohne Ergänzungsstoffe (*B-T*) im Mittel am 14. Mai, also nach acht Tagen, deutliche Differenzen gegenüber der bewässerten Version (*B-W*) zeigten. Dieses Merkmal trat bei den *BB*-Pflanzen am 9. Mai, also nach 3 Tagen auf (**Abbildung 4**).

Auch Vorversuche von 2017 bestätigen diese Ergebnisse. Es konnte somit bei Weidelgras mit der foto-optischen Methode, im Vergleich zu einer rein optischen Bewertung, ein bis zu 5 Tage früherer Vitalitätsabfall festgestellt werden (HERMANN 2018).

4 Fazit

Die beiden verwendeten Methoden zur Bestimmung der Pflanzenvitalität stimmen in ihren Tendenzen des Vitalitätsverlaufs überein. Sowohl durch die foto-optische als auch die visuelle Methode ließ sich feststellen, dass die bewässerten Pflanzen der Kontrollgruppe kontinuierlich hohe Werte aufwiesen. Hierzu steht der Vitalitätsabfall der unter Trockenstress gesetzten Versuchspflanzen im Gegensatz. Weiterhin konnten bei beiden Methoden die gleichen Differenzen in der Vitalität in Abhängigkeit des genutzten Bodensubstrates ermittelt werden.

Die Methode der foto-optischen Erfassung erlaubt aufgrund ihrer hohen radiometrischen Auflösung von 8 Bit sowie der 201 Abstufungen im NDVI eine differenziertere und somit genauere Vitalitätsbestimmung als das Verfahren, welches auf Beobachtungen durch das menschliche Auge erfolgt. Natürliche Vitalitätsschwankungen waren bei den ständig bewässerten deutlicher nachweisbar.

Entsprechend der Ergebnisse lassen sich mithilfe der foto-optischen Vitalitätsbestimmung die Auswirkungen von Trockenstress auf die Versuchspflanzen früher erkennen als die visuelle Erfassung der Vitalität dies ermöglicht.

Unter Zuhilfenahme der spektralen Daten war bei dem Deutschen Weidelgras eine Identifikation des Vitalitätsabfalls früher möglich. Im Vergleich zur visuellen Bestimmung waren es im reinen Versuchsboden drei Tage, bei den Pflanzen, die zusätzlich mit Bodenergänzungstoff wuchsen, sogar fünf Tage. Demzufolge wurden die Auswirkungen von Trockenstress auf die Vitalität der Vegetation über den NDVI deutlich eher erkannt.

Neben der frühzeitigeren sowie differenzierteren Erkennung der Folgen von Wassermangel besitzt die entwickelte Methode der foto-optischen Vitalitätsbestimmung aber auch einige Schwächen. Sie ist trotz Nutzung eines Spektralons anfälliger gegenüber äußeren Einflüssen, so z.B. Lichtverhältnissen. Die Bestimmung der Vitalität mithilfe der spektralen Daten ist zudem in der Durchführung zeitaufwendiger. Besonders die Bearbeitung in Adobe Photoshop nimmt viel Zeit in Anspruch (vgl. BELLIN 2018).

Durch weitere Forschungen könnte die Methodik verbessert werden. Eine Möglichkeit bildet die Entwicklung eines Entscheidungsbaumschemas zur Automatisierung der Weiterverarbeitung der spektralen Daten in einer Bildauswertungssoftware, wie beispielsweise ENVI. Bei der Auswahl der spektralen Vegetationsdaten im Rahmen des Programms Adobe Photoshop hat sich herausgestellt, dass besonders die Unterscheidung zwischen den Bildbereichen des Bodens und der Pflanze eine Herausforderung darstellt. Die Grauwerte in den Kanälen Blau, Grün und Rot für Vegetation sowie für Boden liegen nah beieinander oder gleichen sich sogar völlig. Lediglich im Nahinfrarot ist ein deutlicher Unterschied zu erkennen.

Jedoch kann das bekannte Potential von foto-optischen Methoden zur frühzeitigen Diagnose von Trockenstress mithilfe des NDVI bestätigt werden. Mit dem direkten Vergleich zu der visuellen Vitalitätsbestimmung konnten neue methodische Schritte realisiert werden. Bisher wurde der NDVI vorrangig zur Identifikation der Vegetation aus großer Entfernung benutzt, jedoch könnte die Eigenschaft des NDVI auch für die Bestimmung des Vitalitätszustandes von Einzelpflanzen genutzt werden.

Es wurde eine Methode getestet, mit deren Hilfe die Bewässerung zeitlich präziser und räumlich genauer gestalten lässt. Durch weitere Forschungsansätze und Automatisierung einzelner Prozesse innerhalb dieser Methode kann die Bestimmung der Vitalität über den NDVI die Grundlage für ein optimiertes Bewässerungsmanagement bilden und den Verbrauch an Süßwasser innerhalb des Agrarsektors stark senken.

Literaturverzeichnis

AD-HOC-AG BODEN (2005): Bodenkundliche Kartieranleitung, 5. Auflage, Hannover.

ALBERTZ, J. (2009): Einführung in die Fernerkundung. Grundlagen der Interpretation von Luft- und Satellitenbildern, 4., aktualisierte Aufl., Darmstadt: WGB.

- BARTEL, H. et al. (2016):** Rund um das Trinkwasser, Umweltbundesamt (Hrsg.), 4. aktualisierte Aufl., Dessau-Roßlau: Umweltbundesamt.
- BELLIN, L. (2018):** Vergleich zwischen visueller und foto-optischer Erfassung von Vitalitätszuständen des Deutschen Weidelgrases, Bachelorarbeit, Universität Potsdam.
- BOTHE, A. et al. (2018):** Drought tolerance in perennial ryegrass (*Lolium perenne* L.) as assessed by two contrasting phenotyping systems, in: Journal of Agronomy and Crop Science, Jg. 204, Nr. 4, p. 375–389.
- BUNDESSORTENAMT (2017):** [online] [07.02.2019].
https://www.bundessortenamt.de/internet30/fileadmin/Files/PDF/bsl_rasengraeser_2017.pdf
- FALK, D. (2016):** Landnutzungsklassifikation im Becken von Zoige: Untersuchung von Landsat-Tm-Aufnahmen hinsichtlich einer Landschaftsdegradation, Hamburg: Diplomica Verlag GmbH, S. 11.
- FOITO et al. (2009):** Transcriptional and metabolic profiles of *Lolium perenne* L. genotypes in response to a PEG-induced water stress, in: Plant Biotechnology Journal, Jg. 7, Nr. 8, p. 719–732.
- HERMANN, T. (2018):** Auswirkungen von Trockenstress bei Deutschem Weidelgras, dargestellt auf Basis von NDVI-Werten, Bachelorarbeit, Universität Potsdam.
- INTERENVIROCON GMBH (o.J.):** Eigenschaften, [online] <http://bodenbalsam.de/EIGENSCHAFTEN/> [07.08.2018].
- KARSTEN, H. D. & MACADAM, J. W. (2001):** Effect of drought on growth, carbohydrates, and soil water use by perennial ryegrass, tall fescue, and white clover, in: Crop Science, Jg. 41, Nr. 1, p. 156–166.
- KIM, Y., GLENN, D. M., PARK, J., NGUGI, H. K. & LEHMAN, B. L. (2011):** Hyperspectral image analysis for water stress detection of apple trees, in: Computers and Electronics in Agriculture, Jg. 77, Nr. 2, p. 155–160.
- LENUWEIT, U., GHARADJEDAGHI, B., SÜßER, M., SCHÖPS, K., BLEW, J. & RIDDER, S. (2002):** Biologische Basisdaten zu *Lolium perenne*, *Lolium multiflorum*, *Festuca pratensis* und *Trifolium repens*, Umweltbundesamt (Hrsg.), Bd. Texte 08/2002, Berlin: Umweltbundesamt.
- POSTEL, S. (2001):** Landwirtschaft. Mehr ernten mit weniger Wasser, in: Spektrum der Wissenschaft, Heft 8/2001, S. 74.

Detection of *Rhizoctonia solani* in sugar beet from leaves hyperspectral images on a single plant scale

Detektion von Rhizoctonia solani in Zuckerrüben aus Hyperspektralktrabildern auf Pflanzenebene

Abel Barreto, Stefan Paulus, Mark Varrelmann, Anne-Katrin Mahlein

Institute of Sugar Beet Reserach (IfZ), Holtenser Landstraße 77, 37079 Göttingen

E-Mail: Barreto@ifz-goettingen.de

Zusammenfassung: Der bodenbürtige Pilzerreger *Rhizoctonia solani* AG 2-2IIIB ist eine der wichtigsten Limitierungen der Zuckerrübenproduktion weltweit. In der Zuckerrübe, ist der Wurzelfäule-Pilzerreger üblicherweise über Bonitierung von oberirdischen Symptomen erst spät in der Erntesaison zu erkennen. Für die Evaluierung einer automatischen Detektion der Pilzkrankheit wurden acht Wochen alte Zuckerrübenpflanzen mit dem Pathogen inokuliert. Während des Krankheitsverlaufs wurden VIS-NIR hyperspektrale Bilder (400–1000 nm) des Blattapparates aufgenommen. Reflektanzinformation wurden durch Etablierung einer Hochdurchsatzanalyse extrahiert. Für die Identifizierung anfälliger Pflanzen wurde eine überwachte Lernmethode, Support Vector Machines (SVM), auf Basis von Vegetationsindizes angewendet. Basierend auf den Indizes ARI 1, NDVI und TGI zeigen die Ergebnisse, dass ein SVM-Modell erfolgreich trainiert werden kann, um erkrankte Pflanzen bereits fünf Tage vor der visuellen Bewertung zu erkennen. Diese Studie zeigt, dass es möglich ist einen bodenbürtigen Erreger mittels hyperspektraler Bildgebung frühzeitig zu erkennen.

Deskriptoren: Pflanze-Pathogeninteraktion, Support Vector Machines, Früherfassung, Wurzelfäule

Abstract: *The soil-borne fungal pathogen Rhizoctonia solani AG 2-2IIIB is one of the most critical constraints in sugar beet production worldwide. In sugar beet, crown and root rot caused by this fungus are traditionally recognized later in the cropping season by rating the aboveground symptoms. To evaluate the detection of the disease, eight-weeks-old plants were inoculated with this pathogen. Subsequently, VIS-NIR hyperspectral images (400–1000 nm) from leaves were obtained during disease development. Reflectance information was extracted by establishing an image processing methodology. To classify diseased plants the machine learning technique, Support Vector Machine (SVM) was employed using promising vegetation indexes for the modeling. The results showed that based on ARI 1, NDVI and TGI indices, a SVM-model can be trained to detect diseased plants five days before changes in index values and visual*

rating. This study confirms the possibility to detect early a soil-borne pathogen by using hyperspectral imaging.

Keywords: Plant-pathogen interaction, support vector machine, early detection, root rot disease

1 Introduction

The sugar-beet, *Beta vulgaris L. ssp. vulgaris* is one of the most important crops worldwide, and one of only two plants which constitute the only substantial source of sucrose (COOKE & SCOTT 1993). The EU is the biggest sugar beet producer in the world and represents the fourth major arable crop of this region (1.3 million ha in 2015; SMIT *et al.* 2017). In the sugar factory, the technical quality of the beet plays an essential role in processing. Beets that do not meet the quality standards cause losses which include reduced harvestable tonnage and reduced white sugar recovery (MÄRLÄNDER *et al.* 2003).

Root rot diseases of sugar beet are a primary limiting factor to produce high-quality beets (JACOBSEN 2006). One of the most relevant root rot diseases is called Rhizoctonia Root and Crown Rot (RRCR) is caused by the soil-borne fungus *Rhizoctonia solani* AG 2-2IIIB. Symptoms of RRCR include from leaf yellowing and foliage death to cankers and cracks deep into the root (GALLIAN 2001). On the field, the identification of Rhizoctonia infected zones early in the season allows the control of the pathogen by using fungicides, e.g. azoxystrobin, which is applied on to the petioles and crown areas (AGRIOS 2009).

Hyperspectral Imaging (HSI) is a non-invasive method that allows time-series evaluation, and which in the last years has found an application in plant pathology (BOCK *et al.* 2010). Hyperspectral sensors take reflected light and describe it as a function of wavelength. In a crop, reflected light function or spectral signature could deliver information from the leaf about the biophysical and biochemical attributes of vegetation (CROFT & CHEN 2018). Fungal pathogens influence the spectral signature depending on the interaction type. This characteristic makes specific the behavior of hyperspectral signatures for each plant-pathogen interaction (THOMAS *et al.* 2018).

The classification of diseased plants is possible without losing spectral information by using supervised classification methods such as the Support Vector Machine (SVM). SVM has the ability to learn well with high number of features, provides robustness against the error of models, and presents a superior computational efficiency (GHOLAMI & FAKHARI 2017).

To investigate the potential of hyperspectral sensors in sugar beets for the detection of *Rhizoctonia solani*, the following objectives were proposed: (1) Define an imaging method to obtain the VIS-NIR (400–1000 nm) spectral information for plants diseased with Rhizoctonia root and crown rot; (2) Evaluate the possibility of early detection of

Rhizoctonia root rot by using hyperspectral imaging, resulting vegetation indexes and support vector machine.

2 Material and Methods

Biological material and data acquisition

The variety Sabrina (susceptible to RRRCR, KWS GmbH, Einbeck, Germany) of sugar beet was used in this study. Rhizoctonia inoculum was prepared from a highly aggressive isolate of *R.solani*, AG 2-2IIIB (Institute of Sugar Beet Research-IfZ, Göttingen, Germany). Eighteen plants were inoculated with Rhizoctonia infested barley grains, and together with fifteen control plants were transferred to a greenhouse under controlled conditions. Leaf reflectance from 400 to 1000 nm was recorded by a hand-held VIS-NIR sensor from Specim (IQ, Specim, Oulu, Finland), in total in eight measurement dates. The first measurement started one day before inoculation (dbi). Further scanning dates took place after the inoculation, three times per week, beginning in three days after inoculation (dai) to 17 dai (**Figure 1**).

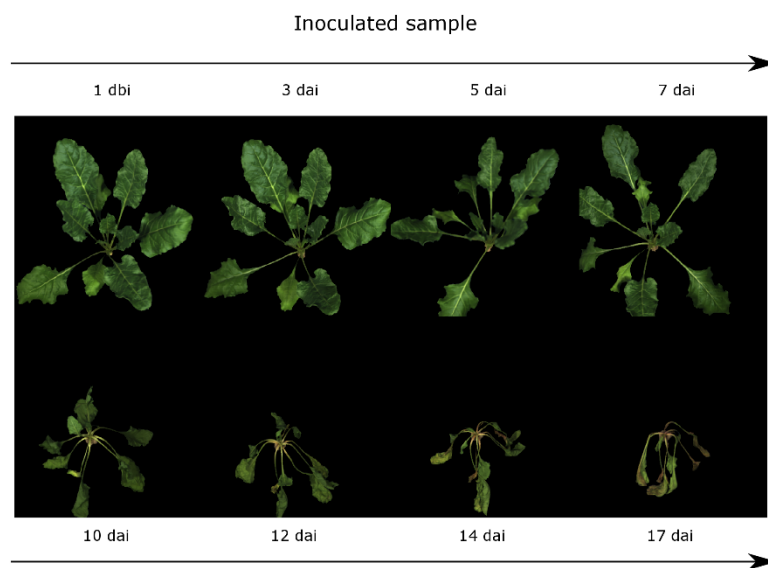


Figure 1. Development of inoculated sample at different measurement dates

Image processing

Raw images were normalized by using the Specim IQ Studio software (Specim IQ, Specim, Finland), which is integrated into the camera. To reduce random noises, the Savitzky-Golay filtering was applied with a filter order of 3 ($p = 3$), and a length of 31 ($n = 31$). Plant and background separation were based on a thresholding of different Spectral Vegetation Indexes (SVIs). The outcome data were submitted to the morphological operation “Erosion” (structuring element: 3×3), obtaining a new outcome mask (vegetation mask). The average spectral value was calculated for each band from the region of interest (ROI) of each image (**Figure 2**).

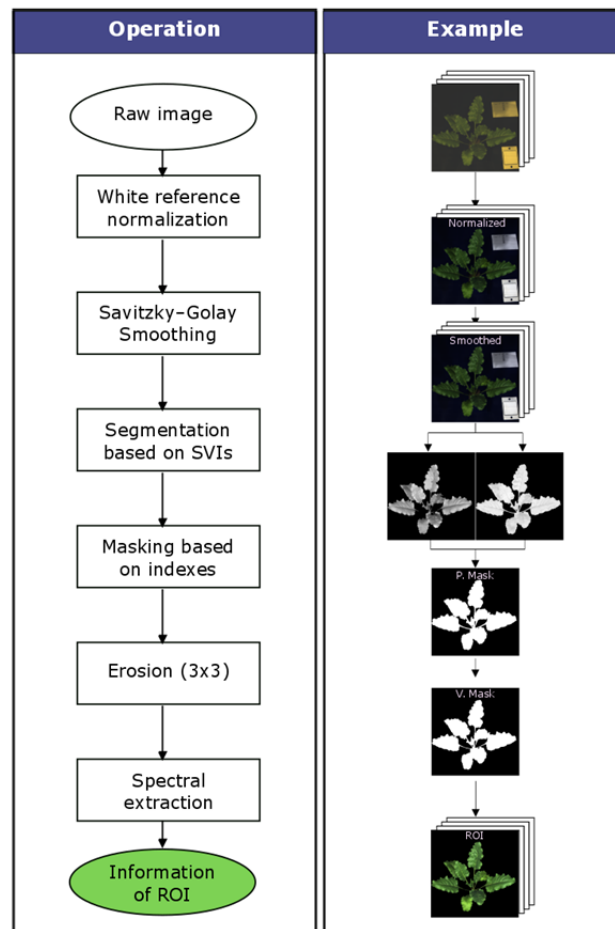


Figure 2. Imaging method to segment and extract relevant information from Rhizoctonia infected plants

Support vector machine

For data training, images from the two last measurement dates (14 and 17 dai) were split by pixels to obtain 400 observations. From spectral information each observation and based on leaves attributes, anthocyanin content, green biomass and chlorophyll content, it was calculated the values of

Anthocyanin Reflectance Index 1:

$$(ARI\ 1; ARI\ 1 = 1/R_{550} - 1/R_{700}; GITELSON\ et\ al.\ 2001),$$

Normalized Difference Vegetation Index:

$$(NDVI; NDVI = (R_{750} - R_{705}) / (R_{750} + R_{705}); ROUSE\ JR\ et\ al.\ 1974)\ and$$

Triangular Greenness Index:

$$(TGI; TGI = -0.5 \times ((R_{[665:675]} - R_{[475:485]}) \times (R_{670} - R_{550}) - (R_{[665:675]} - R_{[545:555]}) \times (R_{670} - R_{480})); HUNT\ et\ al.\ 2011).$$

The indexes values were randomly stratified, allocating 60% of the total (240 observations) for the training data. Two kernels were tested in the SVM-models at this stage: linear and radial. The method used for training was repeated cross-validation (3 repetitions, 10-fold cross-validation). The data was centered and scaled. The best cost- and sigma-value were searched by inputting values in a grid with a granularity of 10. To check the accuracy of the linear and radial model, a confusion matrix was performed first with the test data set (160 observation resting from the stratification stage). Finally, the accuracy was tested with the mean index value of ROI from each image.

3 Results and discussions

The most promising indexes, Anthocyanin Reflectance Index 1 (ARI 1), Normalized Difference Vegetation Index (NDVI), and the Triangular Greenness Index (TGI) showed significant differences in terms of index value from the fifth measurement date (10 dai, **Figure 3**). Similarly, visual rating presented discrimination of inoculated samples from 10 dai.

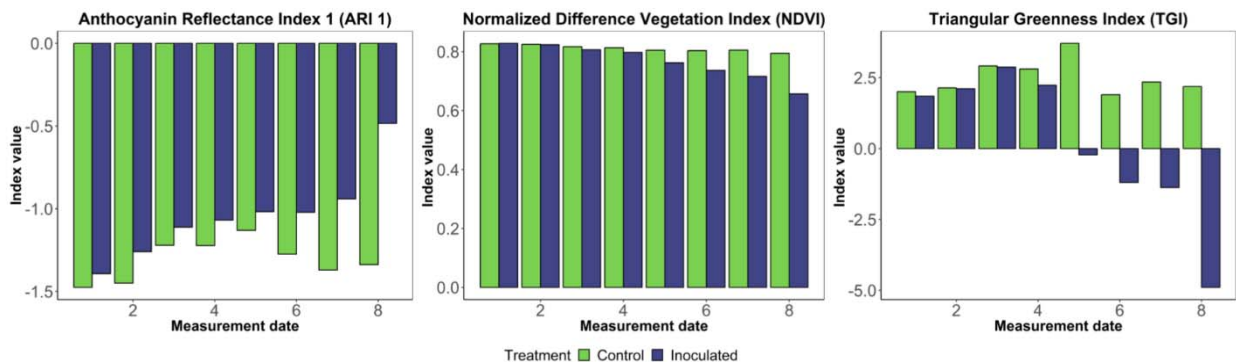


Figure 3. ARI 1, NDVI and TGI index performance during RCRR development

Moreover, using selected indexes, the calculated SVM-model with a linear kernel showed the best accuracy for the time-series evaluation. *Rhizoctonia* inoculated sugar beet plants started being detected at the third measurement date (5 dai, **Figure 4**), five days before the differentiation each index and classification by human eye.

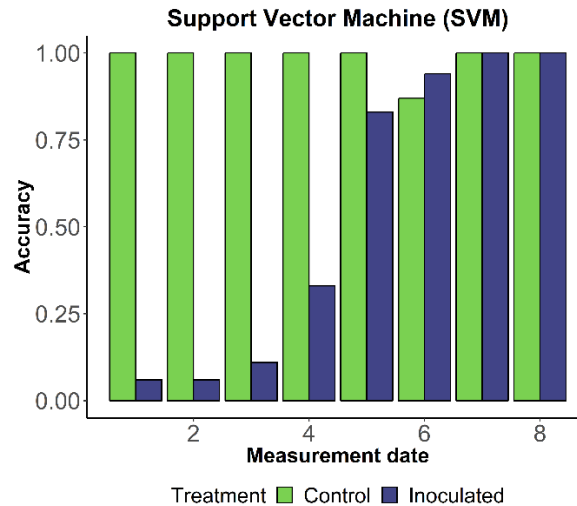


Figure 4. SVM performance during RCRR development

ARI 1 index is highly correlated with Anthocyanin content on leaves. In plants, this compound is accumulated as a result of abiotic and biotic stress like fungal infections (GITELSON *et al.* 2001). NDVI index was developed to estimate green biomass and vegetation moisture content (ROUSE JR *et al.* 1974), these parameters are apparently also affected during the infection process. TGI index is a precise parameter to predict leaf chlorophyll content in sugar beet (leaf area index (LAI) >2; (HUNT *et al.* 2011). Chlorosis is one of most notorious aboveground symptoms of RRCR used to locate the pathogen on the field. The benefits of all mentioned indexes in one SVM-model allows the early detection of *Rhizoctonia solani*.

4 Conclusions

This publication shows the use for VIS-NIR hyperspectral imaging for the early detection of *Rhizoctonia solani* for sugar beet plants in time series. Under controlled conditions and working on the single plant scale, the use of a SVM-model of pre-calculated vegetation indexes allowed the identification of inoculated samples five days before the differentiation of visual rating by human eyes. The proposed model showed the same advantage singly against ARI 1, NDVI and TGI indexes.

References

- AGRIOS G.N. (2009):** Plant pathology. 5. ed., 4. print. – (Elsevier Acad. Press) Amsterdam.
- BOCK C.H., POOLE G.H., PARKER P.E. & GOTTWALD T.R. (2010):** Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. – *Critical Reviews in Plant Sciences*, 29 (2): 59–107.
- COOKE D.A. & SCOTT R.K. (1993):** The Sugar Beet Crop. – (Springer Netherlands) Dordrecht.
- CROFT H. & CHEN J.M. (2018):** Leaf Pigment Content. – In: *Comprehensive Remote Sensing*. – pp. 117–142 (Elsevier) <https://doi.org/10.1016/B978-0-12-409548-9.10547-0>.

- GALLIAN J.J. (2001):** Management of Sugarbeet Root Rots. – (University of Idaho Cooperative Extension Service). <http://www.cals.uidaho.edu/edcomm/pdf/PNW/PNW0538.pdf> (Retrieved January 25, 2019)
- GHOLAMI R. & FAKHARI N. (2017):** Support Vector Machine: Principles, Parameters, and Applications. – In: Handbook of Neural Computation. – pp. 515–535 (Elsevier).
- GITELSON A.A., MERZLYAK M.N. & CHIVKUNOVA O.B. (2001):** Optical Properties and Nondestructive Estimation of Anthocyanin Content in Plant Leaves. – Photochemistry and Photobiology, 74 (1): 38 [https://doi.org/10.1562/0031-8655\(2001\)074](https://doi.org/10.1562/0031-8655(2001)074).
- HUNT E.R., DAUGHTRY C.S.T., EITEL J.U. & LONG D.S. (2011):** Remote sensing leaf chlorophyll content using a visible band index. – Agronomy Journal, 103 (4): 1090–1099.
- JACOBSEN B.J. (2006):** Root rot diseases of sugar beet. – Proceedings of Natural Sciences, Matica Srpska Novi Sad, 110: 9–19.
- MÄRLÄNDER B., HOFFMANN C., KOCH H.-J., LADEWIG E., MERKES R., PETERSEN J. & STOCKFISCH N. (2003):** Environmental Situation and Yield Performance of the Sugar Beet Crop in Germany: Heading for Sustainable Development. – Journal of Agronomy and Crop Science, 189 (4): 201–226 <https://doi.org/10.1046/j.1439-037X.2003.00035.x>.
- ROUSE JR J., HAAS R., SCHELL J. & DEERING D. (1974):** Monitoring vegetation systems in the Great Plains with ERTS. – .
- SMIT A.B., JONGENEEL R.A., PRINS H., JAGER J.H. & HENNEN W.H.G.J. (2017):** Impact of coupled EU support for sugar beet growing: More production, lower prices. – (Wageningen Economic Research) Wageningen <https://doi.org/10.18174/430039>.
- THOMAS S., KUSKA M.T., BOHNENKAMP D., BRUGGER A., ALISAAC E., WAHABZADA M., BEHMANN J. & MAHLEIN A.-K. (2018):** Benefits of hyperspectral imaging for plant disease detection and plant protection: A technical perspective. – Journal of Plant Diseases and Protection, 125 (1): 5–20 <https://doi.org/10.1007/s41348-017-0124-6>.

Validierung der teilflächenspezifischen Ertragsprognose auf Basis maschinellen Lernens mit realen Ertragsmessungen auf einem Ackerbaubetrieb

Site-specific crop yield prediction using machine learning and real-time yield measurements on an arable farm

Sebastian Jerratsch¹, Andreas Walter Heckmann², Stefan Paulus³, Steffen Herbold¹

¹Georg-August-Universität Göttingen, Institut für Informatik, Goldschmidtstraße 7, 37077 Göttingen

²Georg-August-Universität Göttingen, DNPW- Abteilung Agrartechnik, Gutenbergstraße 33, 37075 Göttingen

³Institut für Zuckerrübenforschung, Holtenser Landstraße 77, 37079 Göttingen
E-Mail: s.jerratsch01@stud.uni-goettingen.de

Zusammenfassung: Diese Publikation zeigt die Nutzung von Spektralinformationen der Satelliten zur Vorhersage bzw. Abschätzung von Ertragsmengen in Kornfrüchten. Dazu wurde ein spektraler Vegetationsindex (NDVI) genutzt, der auf der Nutzung des Rotkanals (665 nm) und des NIR Kanals (835 nm) basiert. Durch die Nutzung eines neuronalen Netzes konnten die Satellitenpixel zusammen mit den orts- und zeitreferenzierten Ertragsdaten der Mähdrescherkartierung in einem sehr genauen Modell zur Vorhersage fusioniert werden. Als Testdaten wurden dazu völlig unbekannte Daten eines zweiten Betriebes benutzt, um die Unabhängigkeit der Trainings- und Testdaten zu gewährleisten. Im Stand der Forschung wurde eine derartige Trennung bisher nicht berücksichtigt.

Dennoch zeigen die Ergebnisse, dass es möglich ist, mit einer sehr hohen Genauigkeit ($R^2 = 0,85$) die Erntemenge auf den Feldern vorherzusagen. Im Mittel wurden gute Ergebnisse ($R^2 \approx 0,68$) erreicht. Dies zeigt, dass der Transfer von trainierten Modellen auf andere Felder möglich ist. In dieser Publikation werden die Ergebnisse hinsichtlich ihrer Validität und Übertragbarkeit analysiert, sowie weitere Verbesserungsmöglichkeiten diskutiert.

Deskriptoren: Datenfusion, NDVI, neuronale Netzwerke (CNN), Satellitenbild-Verarbeitung, Sentinel, Precision farming, Ertragskartierung, Ertragsprognose

Abstract: *This publication demonstrates the use of spectral information from satellites to predict or estimate yields in grain crops. A spectral vegetation index (NDVI) calculated on the red channel (665 nm) and the NIR channel (835 nm) was used. Through the application of a neural network, the satellite pixels could be fused together with the loca-*

tion- and time-referenced harvest-data of the yield-mapping in a very accurate model for prediction. As validation, completely unknown data from a second farm sight was used to guarantee the independence of the training and test data. In the current state of research, such a method has not been considered. The results show that it is possible to predict the yield on the fields with a very high accuracy ($R^2 = 0.85$), on average good results were achieved ($R^2 \approx 0.68$). This shows that the transfer of trained models to other unknown fields is possible. In this publication, the results are analyzed with regard to their validity and transferability. In addition, further possibilities for improvement are discussed.

Keywords: *data fusion, NDVI, neural network (CNN), satellite imagery, sentinel, precision agriculture, yield mapping, yield prediction*

1 Einleitung

Eine zentrale Herausforderung im Pflanzenbau ist die frühzeitige Zustandserkennung des Felds. So kann schnell auf Stress reagiert werden, indem standortangepasste Managementmaßnahmen initiiert werden. Voraussetzung dafür ist die Nutzung von Sensorik zur teilflächenspezifischen Beschreibung des Pflanzenaufwuchses. Dabei gilt: Je höher die zeitliche und räumliche Auflösung ist, desto besser kann der Feldzustand erfasst und erforderliche Maßnahmen abgeleitet werden. Im Pflanzenbau ist die frühzeitige Schätzung des Kornertrags für die einzelnen heterogenen Teilflächen notwendig, um standortangepasste Managemententscheidungen zu treffen (LINSEISEN 2002). Durch den Einsatz von Fernerkundungstechniken können landwirtschaftliche Flächen nicht-invasiv und kostengünstig hinsichtlich der Heterogenität ihres Biomasseaufwuchses analysiert werden. Die Prognose des Kornertrages ist dabei eine zentrale Herausforderung (IDSO *et al.* 1980; LOBELL 2017).

Seit vielen Jahren kommen hier Methoden der Fernerkundung basierend auf Satellitendaten zum Einsatz (BENDETTI 1993). Sowohl die Auflösung als auch die Verfügbarkeit von Satellitendaten steigen beständig. Seit dem Start der Sentinel-2 Satelliten im Jahr 2015 sind hochaufgelöste Multispektralbilder mit heute bis zu 10 x 10 m Pixelgröße in 13 Bändern zwischen 443 und 2190 nm Wellenlänge öffentlich verfügbar. Sichtbares rotes, grünes und blaues Band und Nahinfrarot (NIR)-Bereiche des elektromagnetischen Spektrums wurden erfolgreich verwendet, unter anderem für das Monitoring des Biomassezuwachses, des Ernteertrags, sowie von Krankheits- und Nährstoffstress. Dabei wird vor allem der spektrale Vegetationsindex NDVI benutzt (ROUSE 1973), der eine hohe Korrelation mit Biomassemessungen aufweist (BENDIG *et al.* 2015), um durch diesen auf das Kornertragspotential zu schließen (PASSIOURA 1977). Aktuelle Studien arbeiten meist auf regionaler Ebene und selten teilflächenspezifisch (PANDA 2010). Das zugrundeliegende Modell basiert auf der Nutzung von maschinellen Lernmethoden wie SVM oder *Random-Forest* und erreicht Genauigkeiten im Bereich von $R^2 \sim 0,53-0,79$ (WANG, 2016). Mithilfe öffentlich verfügbarer Sentinel-2 Daten (Level 1C) stellen wir eine skalierbare, genaue und kostengünstige Methode der Ernteertragsprognose für drei

Praxisflächen vor. Es erfolgt ein Abgleich mit den durch die Ertragskartierung des Mähdreschers erhobenen geo- und zeitreferenzierten Felderträgen aus der Ernte 2018. Unser Ansatz verbessert bestehende Techniken bezüglich der Auflösung der Kornertragsprognose, sowie der Robustheit des Ansatzes durch eine hochaufgelöste Referenzmessung auf dem Feld. Wir verwenden hierfür ein Regressionsmodell, in dem wir für 10 x 10 m Parzellen die Kornerträge vorhersagen. Wir werten die Vorhersagegenauigkeit für die Parzellen aus und berechnen anschließend den Gesamtertrag pro Feld. In der bisherigen Forschung wurden keinen genauen Erträge vorhergesagt, sondern lediglich Ertragsklassen, zum Beispiel hoch, mittel und niedrig (PANTAZI 2016).

Ein wichtiges Alleinstellungsmerkmal unseres Ansatzes ist die Nutzung eines *Convolutional Neural Networks* (CNN) (LECUN 2015). CNNs ermöglichen die einfache Korrelation von benachbarten Informationen in Datenräumen, zum Beispiel benachbarten Bildpunkten. Wir nutzen diese Fähigkeit außerdem, um die zeitlichen Nachbarschaften zu berücksichtigen, das heißt um NDVI-Aufnahmen von verschiedenen Zeitpunkten zu korrelieren und zu fusionieren. Dieser Ansatz zur Datenfusion lässt sich ohne Weiteres um weitere Spektraldaten und andere Informationsquellen erweitern, zum Beispiel die Rohdaten aus den Bändern des Satelliten, Aufnahmen vor der Aussaat oder Wetterdaten.

2 Materialien und Methoden

Es wurden Ertragsmessungen des landwirtschaftlichen Versuchsbetriebs Reinshof der Universität Göttingen verwandt. Auf den Feldschlägen des Versuchsguts Reinshof der Universität Göttingen werden seit 2002 die Kornerträge durch den Mähdrescher Claas Lexion 480 mittels der verbauten volumetrischen Ertragskartierung *Claas Quantimeter* erfasst. Es liegen geo- und zeitreferenzierte Erntedaten, wie z. B. Kornertrag und -feuchte vor. Die technischen Vorrichtungen werden für jedes Jahr, jede Kultur und Sorte durch die Betriebsmitarbeiter kalibriert (STEINMAYER 2003). In der Ergebnisdarstellung werden stellvertretend jeweils ein Feld für eine gute, mittlere und weniger gute Prognosegenauigkeit aufgeführt. Es handelt sich um die Felder „Hirschmorgenbreite“ (Feld 1, Winterweizen Sorte Landsknecht, Vorfrucht Winterweizen Größe: 11,58 ha, Boden: AB Vega), „Wolfsacker 1 Nord“ (Feld 2, Winterweizen Sorte Landsknecht, Vorfrucht Winterweizen, Größe: 3,6 ha, Boden: LL-SS Pseudogley-Parabraunerde) und „Jeidental“ (Feld 3, Winterweizen Sortengemenge, Vorfrucht Winterweizen, Größe: 16,75 ha, Boden: R Rendzina).

Für die Berechnung der geo- und zeitreferenzierten NDVI-Werte in einer 10 x10 m Auflösung wurden Aufnahmen der Sentinel-2 Satelliten verwendet. Der NDVI wurde anhand der folgenden Formel und des Nahinfrarot- und Rot-Bands (835 nm und 665 nm) errechnet:

$$\text{NDVI} = (\text{NIR} - \text{Rot}) / (\text{NIR} + \text{Rot})$$

Es wurden wolkenfreie Bilder mit Hilfe der *Google Earth Engine* ausgesucht, um die Qualität der Eingabedaten sicherzustellen. Mit Hilfe der Ertragsdaten wurde bestimmt,

dass eine 1440 x 1440 m große Box ausreichend ist, um alle Felder zu umschließen. Da jeder Pixel der Satellitendaten einen 10 x 10 m großen Bereich repräsentiert, ergibt sich also ein Raster aus 144 x 144 Pixeln.

Mit diesen wurde im nächsten Schritt jeweils der Bereich des Feldes aus dem großen Satellitenbild zugeschnitten. Für jedes Feld liegen dann GeoTIFF-Bilder mit NDVI-Werten für vier verschiedene Zeitpunkte vor. Die vier Zeitpunkte vor der Ernte werden für jedes Feld anhand des Erntedatums aus der Menge der vorhandenen Aufnahmen ausgewählt. Die Aufnahmen stammen vom 14.04.2018, 14.05.2018, 31.05.2018, 14.06.2018, 30.06.2018, 14.07.2018 und 31.07.2018. Diese GeoTIFF-Bilder können eingelesen und als 144 x 144 Matrix interpretiert werden.

Um eine Regression des Ertrags pro 10 x 10 Abschnitt des Feldes durchzuführen, also pro Pixel in den Satellitendaten, müssen die Ertragswerte in die gleiche 144 x 144 Matrizenform gebracht werden. Eine Position (i,j) in einem Tupel von Matrizen referenziert dann immer die gleiche Geo-Position. Um das zu erreichen, wird zuerst ein Raster aus quadratischen 10 x 10 m Polygonen anhand der Pixel-Koordinaten der GeoTIFF-Bilder berechnet. Jedem Polygon wird seine (i,j)-Pixel-Position und das zugehörige Feld zugeordnet. Mit Hilfe dieses Polygon-Rasters können die Koordinaten der Ertragsmessung einem der Polygone zugeordnet werden, um verschiedene Datensätze die zu einer Parzelle gehören, zusammenzuführen. Da mehrere Ertragsmessungen in eine Parzelle fallen können, wird der Mittelwert dieser Erträge als Wert dieser Parzelle genommen. NDVI-Werte an Positionen, an denen kein Ertrag gemessen wurde, werden entfernt. Das Ergebnis dieser Verarbeitung sind 144 x 144 Matrizen gleicher Dimension, die NDVI-Werte zu vier verschiedenen Zeitpunkten vor der Ernte enthalten und eine 144 x 144 Matrix, welche die realen Ertragswerte enthält.

Damit die Methode flexibel auf jedes Feld, insbesondere auch solche, die nicht in unser 144 x 144 Raster passen würden, angewandt werden kann, unterteilen wir die 144 x 144 Matrizen in kleinere 6 x 6 Blöcke aufgeteilt.

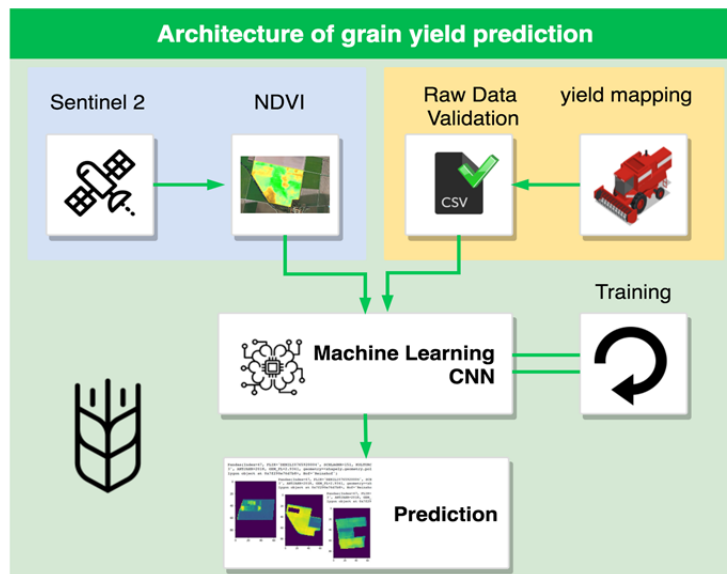


Abbildung 1: Datenfluss-Modell der Ertragsprognose des genutzten Convolutional Neural Network (CNN)

Hierdurch werden aus einer 144×144 Matrix stattdessen $576 \times 6 \times 6$ Matrizen. Diese Blöcke bilden die Grundlage für das Training des CNNs. Hierzu werden die $576 \times 6 \times 6$ Matrizen der vier NDVI -Aufnahmen als Tensor der Form $(576, 6, 6, 4)$ interpretiert. Die erste Dimension des Tensors ist die Anzahl der 6×6 Blöcke, die zweite und dritte Dimension die Größe der Blöcke und die vierte Dimension die Anzahl der NDVI Aufnahmen, die berücksichtigt werden. Die erwartete Ausgabe des CNNs wird durch einen Tensor der Form $(576, 6, 6)$ über die Ertragsdaten modelliert (**Abbildung 1**).

Das gewählte CNN besteht aus insgesamt vier *Convolutional-Layern* (CL) und einem *Fully-Connected Layer* (FL) zwischen zweitem und dritten CL. Eine Besonderheit ist, dass nur für den *Output-Layer* eine ReLU Aktivierungsfunktion gewählt wurde, die restlichen Layer nutzen die Identitätsfunktion. Die Trainingsdaten beinhalten Werte von insgesamt 20 Feldern mit einer Gesamtfläche von ca. 133 ha. Die Validierungsdaten stammen von insgesamt 14 Feldern, die ca. 6 km Luftlinie von den Feldern der Trainingsdaten entfernt liegen und eine Gesamtfläche von ca. 110 ha abdecken.

3 Ergebnisse und Diskussion

Unsere ersten Ergebnisse zeigen, dass der Ansatz vielversprechend ist. **Abbildung 2** und **Tabelle 1** zeigen exemplarisch die Ergebnisse von drei der 14 Felder aus unseren Validierungsdaten. Die Felder wurden so ausgewählt, dass Sie bezogen auf die R^2 Korrelationen ein sehr gutes Ergebnis (Feld 1), ein im Mittel zu erwartendes Ergebnis (Feld 2), und ein sehr schlechtes Ergebnis (Feld 3) darstellen. Die Ergebnisse zeigen, dass unser Ansatz sehr präzise sein kann, sowohl für das gesamte Feld, gemessen im Verhältnis zwischen der Vorhersage und dem realen Korntrug, als auch für die einzelnen Parzellen, gemessen durch die R^2 Korrelation zwischen den Vorhersagen und den rea-

len Werten. Feld 2 zeigt, dass unser Ansatz häufig für die einzelnen Parzellen noch gute Ergebnisse liefern kann, selbst wenn die Abweichungen über das gesamte Feld aufsummiert größer werden können. Feld 3 zeigt die Limitierungen unseres Ansatzes auf. Für dieses Feld sind die Vorhersagen sowohl insgesamt, als auch für die einzelnen Parzellen, sehr ungenau.

Tabelle 1: Ergebnisse der Vorhersagen für die drei Beispielfelder

	Feld 1	Feld 2	Feld 3
Vorhersage [t]	56,500	23,875	50,682
Vorhersage pro Hektar [t/ha]	4,226	3,758	2,978
Realer Kornertrag [t]	57,037	29,380	89,678
Realer Kornertrag pro Hektar [t/ha]	4,266	4,624	5,269
Vorhersage / Realer Kornertrag	0,991	0,814	0,565
R ²	0,844	0,672	0,082

Bedenkt man, dass wir lediglich den NDVI aus Satellitendaten für unsere Vorhersagen benutzen, sind die Ergebnisse sehr gut und können mit dem Stand der Forschung mithalten, bzw. gehen darüber hinaus. Die teils schlechten Ergebnisse lassen sich dadurch erklären, dass wir für das Training des Netzwerkes andere Felder verwendet haben, als für die Vorhersagen. Hierdurch werden Faktoren wie der Bodentyp und das Klima relevant.

Hier liegt jedoch die Stärke unseres Ansatzes, die Vorhersagen basierend auf CNNs zu machen. Weitere Datenquellen lassen sich problemlos hinzufügen und würden nur eine weitere Dimension im Tensor der Trainingsdaten ausmachen. Nützliche Zusatzinformationen wären zum Beispiel: Wetterdaten, wie die Temperatur und Feuchte; die Höhe und Neigung der Feldabschnitte; sowie manuell erhobene Daten, wie die Bonitur und der Chlorophyllgehalt. Auch zeitlich wären weitere Informationen relevant, zum Beispiel Satellitendaten vor der Aussaat. Der NDVI könnte ebenfalls um weitere Indizes und/oder die rohen Spektraldaten der Satellitenbilder ergänzt werden.

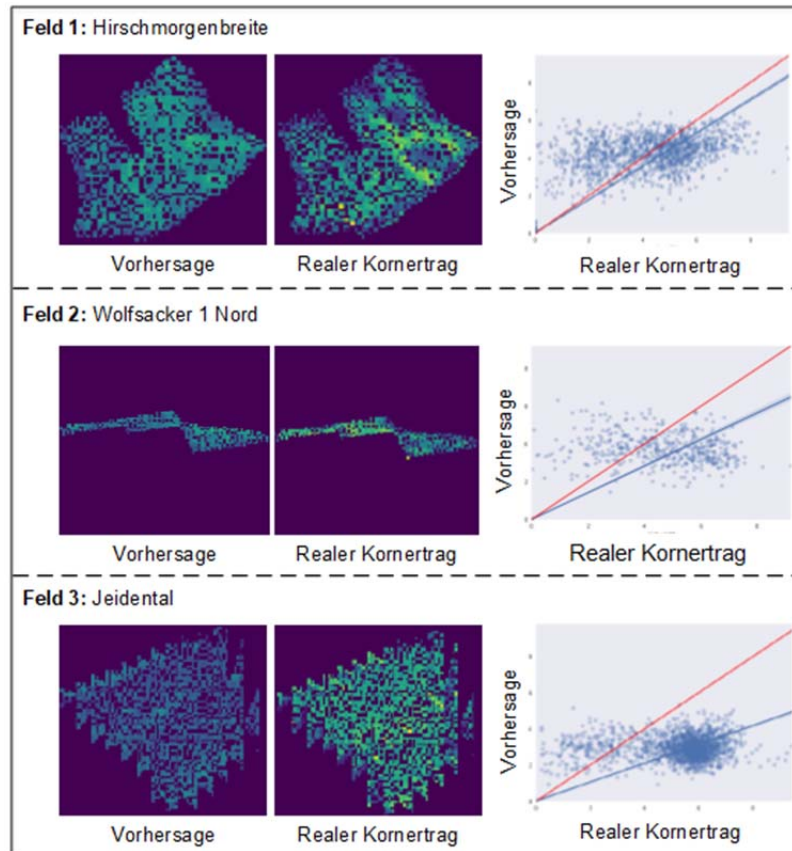


Abbildung 2: Visualisierung der Vorhersageergebnisse für drei Beispielfelder

4 Ausblick

Durch die Vielzahl der möglichen Datenquellen stehen weitere Merkmale zur Erweiterung unseres Ansatzes zur Verfügung (SKAKUN 2017). Zur Verbesserung der frühzeitigen Korntragsprognose wäre insbesondere die Nutzung zeitlich und räumlich hochauflösender Sensordaten aus landwirtschaftlichen Flächen von Vorteil. Welche der oben genannten Datenquellen wirklich die Vorhersagen verbessern und welche Merkmale zur Benutzung im Vorhersagemodell ausgewählt werden, ist daher auch Teil unserer weiteren Forschung.

Literaturverzeichnis

BENDIG J., KANG Y, AASEN H., BOLTEN A., BENNERTZ S., BROSCHEIT J., GNYP M.L., und BARETH G. (2015): Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79–87.
<https://doi.org/10.1016/j.jag.2015.02.012>.

DORIGO W.A., ZURITA-MILLA R., DE WIT A.J.W., BRAZILE J., SINGH R., und SCHAEPMAN M.E. (2007): A review on reflective remote sensing and data assimilation techniques for enhanced agroecosystem modeling. *International Journal of Applied Earth Observation and Geoinformation*, 9(2), pp. 165–93.

- IDSO, S.B., PINTER P.J., JACKSON R.D., und REGINATO R.J. (1980):** Estimation of Grain Yields by Remote Sensing of Crop Senescence Rates. *Remote Sensing of Environment*, 9(1), pp. 87–91.
- LECUN Y., BENGIO Y. und HINTON G. (2015):** Deep learning. *Nature* 521, pp. 436.
- LINSEISEN H. (2002):** Entwicklung eines Management-Informationssystems für Entscheidungen im Precision Farming. Thesis, Technische Universität München.
- LOBELL D.B. (2013):** The Use of Satellite Data for Crop Yield Gap Analysis. *Field Crops Research*, 143, pp. 56–64.
- ROUSE J. W., HAAS R. H., SCHELL J. A. und DEERING D. W. (1974):** Monitoring Vegetation Systems in the Great Plains with ERTS. *NASA Special Publication*, 351, pp. 309.
- PANDA S.S., AMES D.P. und PANIGRAHI S. (2010):** Application of Vegetation Indices for Agricultural Crop Yield Prediction Using Neural Network Techniques. *Remote Sensing*, 2(3), pp. 673–96.
- PANTAZI, X. E., MOSHOU D., ALEXANDRIDIS T., WHETTON R. L., und MOUAZEN A. M. (2016):** Wheat yield prediction using machine learning and advanced sensing techniques. *Computers and Electronics in Agriculture*, 121, pp. 57–65.
- PASSIOURA, J.B. (1977):** Grain yield, harvest index, and water use of wheat. *The Journal of the Australian Institute of Agricultural Science*, 43(3–4), pp. 117–120.
- SKAKUN S., VERMOTE E., ROGER J.C., FRANCH B. (2017):** Combined Use of Landsat-8 and Sentinel-2A Images for Winter Crop Mapping and Winter Wheat Yield Assessment at Regional Scale. *AIMS Geosciences*, 3(2), pp. 163–86.
- STEINMAYR T. (2003):** Fehleranalyse und Fehlerkorrektur bei der lokalen Ertragsermittlung im Mährescher zur Ableitung eines standardisierten Algorithmus für die Ertragskartierung. <https://mediatum.ub.tum.de/doc/603333/603333.pdf> (Download am 1. Januar 2003).
- WANG, L., ZHOU X., ZHU X., DONG Z., und GUO W. (2016):** Estimation of Biomass in Wheat Using Random Forest Regression Algorithm and Remote Sensing Data. *The Crop Journal*, 4(3), pp. 212–19.
- WEIGERT G. (2006):** Entwicklung von Entscheidungsregeln zur kleinräumigen Stickstoffausbringung. Dissertation, Technischen Universität München eingereicht und durch die Fakultät Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt, <https://mediatum.ub.tum.de/doc/603736/603736.pdf>.

Herausforderungen und Einschränkungen bei hyperspektralen Messungen im UV-Bereich

Challenges and limitations of hyperspectral measuring in the UV-range

Anna Brugger¹, Jan Behmann¹, Stefan Paulus² Ulrike Steiner¹, Anne-Katrin Mahlein²

¹Universität Bonn, Institut für Nutzpflanzenwissenschaften und Ressourcenschutz, Pflanzenkrankheiten und Pflanzenschutz, Nussallee 9, 53115 Bonn

²Institut für Zuckerrübenforschung, Holtenser Landstraße 77, 37079 Göttingen
E-Mail: abrugger@uni-bonn.de

Zusammenfassung: Die Phänotypisierung von Pflanzen mittels hyperspektraler Sensorik fokussierte sich bisher auf die Spektralbereiche sichtbaren Lichts bis kurzwelligen Infrarots (400–2500 nm). Der ultraviolette Spektralbereich (UV, 200–380 nm) ist bisher noch nicht genutzt worden, um Wirt-Pathogen Interaktionen durch Hyperspektralmessungen zu beschreiben, ungeachtet einer Vielzahl von Pflanzenmolekülen wie Flavonoide, Aminosäuren, Anthocyane oder Nucleoside, welche ein Absorptionsmaximum im UV-Bereich aufweisen. Es ist anzunehmen, dass frühe Wirt-Pathogen Interaktionen einen Einfluss auf pflanzliche Inhaltsstoffe haben und sich somit die Reflexionseigenschaften im UV-Bereich verändern.

In dieser Studie wurde ein hyperspektrales Messsystem im UV-Bereich etabliert, wobei relevante Messparameter wie Belichtungszeit, Anzahl an aufgenommenen Bildern, der zu messende Bereich und die Intensität der UV-Lampe berücksichtigt wurden. Da UV-Strahlung Pflanzengewebe potentiell schädigt, mussten Vorstudien mit unterschiedlichen Beleuchtungsstärken durchgeführt und mikroskopisch sowie phänologisch ausgewertet werden. Es hat sich gezeigt, dass bei einer Beleuchtung von Pflanzenproben von fünf Minuten Gewebeschäden auftreten.

Um die Auswirkungen veränderter Konzentration pflanzlicher Inhaltsstoffe während der Pathogenese zu erfassen, müssen folglich simulierte Zeitreihenmessungen mit jeweils nur einmal genutzten Pflanzenproben durchgeführt werden. Somit können Veränderungen in der spektralen Reflektanz im UV-Bereich erfasst und pathogenspezifische Auswirkungen detektiert werden.

Deskriptoren: Hyperspektrale Messungen, UV-Bereich, Zuckerrübe, abiotischer Stress

Abstract (Zusammenfassung in englischer Sprache): Previous plant phenotyping studies with hyperspectral sensors focused from the visible to the short-wave infrared (400–2500 nm) range. The ultraviolet spectral range (UV, 200–380 nm) has not yet

been used to describe host-pathogen interactions by hyperspectral measurements regardless of a variety of plant molecules such as flavonoids, amino acids, anthocyanins or nucleosides featuring absorption maxima in the UV range. It can be assumed that early host-pathogen interactions have an influence on plant substances like secondary plant metabolites and therefore change the reflection properties in the UV range.

In this study, a hyperspectral measuring system in the UV range was established, taking into account relevant measurement parameters such as exposure time, number of recorded images, the measured area and the intensity of the UV lamp. Since UV radiation can potentially damage plant tissue, preliminary studies with different illuminance levels had to be carried out and were microscopically and phenologically evaluated. It was shown that sugar beet leaves showed tissue damage after about five measurements with irradiation with UV light. Therefore, to record the effects of changing concentrations of plant substances during pathogenesis, simulated time-series measurements must be performed on plant samples that are used only once. Thus, changes in the spectral reflection in the UV range can be detected and related to pathogen-specific effects.

Keywords: hyperspectral imaging, UV-range, sugar beet, abiotic stress

1 Einleitung

Bisherige Phänotypisierungstudien mit hyperspektralen Sensoren konzentrierten sich auf den sichtbaren (400–700 nm), nahinfraroten (700–1000 nm) und kurzwelligen (1000–2500 nm) Infrarotbereich (MAHLEIN 2016). Der ultraviolette Bereich (UV, 200–380 nm) wurde bisher noch nicht zur Phänotypisierung von Pflanzen verwendet, obwohl einige Pflanzenmoleküle wie Flavonoide, Aminosäuren, Anthocyane und Nucleoside Absorptionsmaxima im UV-Bereich zeigen (FISCHER 1995; GIUSTI *et al.* 2014; TALROSE *et al.* 2009). Das aromatische Phenol weist beispielsweise eine maximale Absorption bei 270–274 nm auf und wird von einer Vielzahl von Pflanzen als Schutz gegen Stress produziert (BHATTACHARYA *et al.* 2010), während Flavonoide in Pflanzen für die Resistenz gegen Pilze wichtig sind (MIERZIAK *et al.* 2014) und zwei Absorptionsmaxima bei 240–290 nm und 310–370 nm haben (SANTOS-BUELGA *et al.* 2003). Um die Reflektanz von Blättern im UV-Bereich messen zu können, gelten besondere Anforderungen an das Messsetup der Messplattform. Ein geeigneter Sensor und eine Lichtquelle mit einer homogenen Ausleuchtung über das zu messende Spektrum von 250 bis 500 nm müssen in die Messplattform integriert werden. Frühere Arbeiten zeigten jedoch, dass UV-Strahlung DNA, Aminosäuren, Proteine, Lipide und Wachstumsregulator der Pflanzen schädigt, was zu Veränderungen des Wachstums und der allgemeinen Entwicklung führt (HOLLÓSY *et al.* 2002). Als eine Reaktion auf UV-Strahlung können Mitochondrien und Chloroplasten reaktive Sauerstoffspezies (ROS) wie H_2O_2 produzieren, was zu einer Aktivierung des programmierten Zelltods führt (MACKERNESS *et al.* 2001; VAN BREUSEGEM *et al.* 2006). Um sicherzustellen, dass durch die Verwendung einer UV-Lichtquelle bei hyperspektralen Messungen kein Gewebeschaden induziert wird, müssen bestrahlte Pflanzen auf die Produktion von ROS untersucht werden.

2 Material und Methoden

Messaufbau und hyperspektrale Messungen

Zur Erfassung der Reflektanz von Pflanzen wurde ein bildgebender hyperspektraler UV-VIS-Sensor eingesetzt. Der UV-Linienscanner (Headwall Photonics, Bolton, USA) besteht aus einem Hyperspec UV-VIS-Interline CCD-Sensor im Bereich von 240 bis 500 nm mit einer spektralen Auflösung von 1,4 nm und einen Pixelabstand von 5,5 mm. Das UV-VIS-Objektiv bietet eine Brennweite von 28,3 mm mit einer maximalen Blendenöffnung von $f / 3,5$. Die Beleuchtung erfolgt durch die Halogenlampe 21 DC (TechniQuip, Pleasanton, USA) und eine UV-Lampe (UniLux, Guardian, Saddle Brook, USA) mit einer Intensität von 1000 Lux. Für die Messungen wurden Belichtungszeiten von 800 ms verwendet mit einer Bildwiederholungsrate von sieben Bildern pro Sekunde.

Qualitative Bewertung der Interaktion zwischen UV-Licht und Pflanzengewebe

Zur Bestimmung einer maximalen Intensität der UV-Strahlung, bei der keine Gewebeschäden an Pflanzenmaterial auftreten, wurde eine Reihe von Intensitätsmessungen an Zuckerrüben der Sorte 'Annemaria' (KWS) durchgeführt. Bei Wachstumsstadium 16 gemäß der BBCH-Skala wurden die Pflanzen 30 Minuten lang mit 20 verschiedenen UV-Intensitäten von 300 bis 5000 Lux beleuchtet. Für jede Intensität wurden drei Proben jeder Pflanze mit einer Größe von 1 x 1 cm für mikroskopische Untersuchungen verwendet um Gewebeschäden mittels H_2O_2 -Detektion durch 3,3-Diaminobenzidin (DAB) nach THORDAL-CHRISTENSEN *et al.* (1997) und WOLF *et al.* (1981) zu untersuchen. Der Nachweis von H_2O_2 erfolgte durch braungefärbte Zellkomponenten in der mikroskopischen Analyse (Leica Leitz DMBRB, Leica, Wetzlar, Deutschland).

*Hyperspektrale Messungen von Zuckerrüben inokuliert mit *Cercospora beticola* im UV-Bereich*

Betrachtet wurden Zuckerrüben, inokuliert mit *Cercospora* Blattflächenkrankheit (*Cercospora beticola* Sacc.). Hyperspektrale Messungen wurden ausgehend von acht Tagen nach Inokulation alle zwei Tage an den Pflanzen durchgeführt.

3 Ergebnisse

Nach den hyperspektralen Messungen zeigten die Zuckerrübenblätter durch die UV-Beleuchtung bei Intensitäten von 3000 bis 5000 Lux makroskopisch sichtbare Gewebeschäden. Um nicht schädliche Intensitäten von UV-Licht zu bestimmen wurden Zuckerrübenpflanzen mit Intensitäten von 300 bis 5000 Lux bestrahlt und mit DAB gefärbt. Die mikroskopische Untersuchung verdeutlichte eine H_2O_2 Produktion in Blättern, bestrahlt mit Intensitäten von 2000 bis 5000 Lux. Eine visuelle Quantifizierung ergab, dass die H_2O_2 Produktion an den Zellwänden begann und sich von dort in der Zelle ausbreitete.

In Zuckerrübenblättern die mit 1250 Lux oder weniger bestrahlt wurden, konnte keine H_2O_2 Produktion nachgewiesen werden (**Abbildung 1**).




Abbildung 1: Mikroskopische Beobachtung der H_2O_2 Produktion durch Gewebeschäden in Zuckerrübenblättern nach hyperspektralen Messungen mit einer UV-Lichtquelle mit Beleuchtungsstärken von 300 bis 5000 Lux

Für eine Zeitreihenmessung von Zuckerrübenblättern (gesund, sowie inokuliert mit *Cercospora beticola*) wurden ausgehend von acht Tagen nach Inokulation alle zwei Tage Messungen durchgeführt. Nach der fünften Messung (16 Tage nach Inokulation) traten auf den Blättern Gewebeschäden auf. Gewebe mit deutlichen Symptomen einer *Cercospora beticola* Infektion zeigte einen Anstieg der Reflektanz im Bereich von 250 bis 450 nm im Vergleich zu gesundem Blattgewebe.

4 Diskussion

Um Intensitäten der UV-Beleuchtung zu ermitteln, welche bei Zuckerrübenpflanzen keine Gewebsschäden hervorrufen, wurde die Wechselwirkung zwischen UV-Licht und Pflanzengewebe durch die Produktion von H_2O_2 mikroskopisch beobachtet. H_2O_2 wurde in allen Zuckerrübenblättern nachgewiesen die mit 2000 bis 5000 Lux bestrahlt worden sind. Da DAB sofort polymerisiert, sobald es mit H_2O_2 in Kontakt kommt, konnte H_2O_2 lokal in mikroskopischen Untersuchungen nachgewiesen werden. Als Reaktion auf UV-Bestrahlung weisen Pflanzenzellen erhöhte ROS-Werte auf, die durch Störungen der Stoffwechselaktivität und erhöhte Aktivität von Membran-lokalisierter NADPH-Oxidase verursacht werden (NAWKAR *et al.* 2013). Die Ergebnisse unserer Experimente zeigen, dass Zuckerrübenblätter mit weniger als 2000 Lux bestrahlt werden müssen, um Gewebeschäden durch UV-Strahlung auszuschließen. In Übereinstimmung mit diesen Einstellungen können nun Änderungen der Reflektanz mit pathogenspezifischen Auswirkungen verknüpft werden. Jedoch zeigte eine Zeitreihenmessung von Zuckerrübenblättern (gesund sowie inokuliert mit *Cercospora beticola*) makroskopische Gewebeschäden nach fünf hyperspektralen Messungen mit UV-Bestrahlung von 1000 Lux im Ab-

stand von je zwei Tagen. Das lässt darauf schließen, dass trotz einer sehr geringen UV-Intensität, welche bei einer einmaligen Bestrahlung von 20 Minuten keine mikroskopischen Gewebeschäden hervorruft, bei mehreren Messungen Gewebeschäden auftreten. Bei der Auswertung dieser Daten muss berücksichtigt werden, dass Änderungen der spektralen Signaturen nicht mit Veränderungen pflanzlicher Inhaltsstoffe während der Pathogenese korreliert werden können, sondern auch Resultat phototoxischer Effekte sind. Daraus resultiert, dass keine Zeitreihenmessungen durchgeführt werden können, sondern simulierte Zeitreihenmessungen mit jeweils nur einmal genutzten Pflanzenproben durchgeführt werden müssen. Somit können phototoxische Effekte ausgeschlossen werden und erfasste spektrale Veränderungen der Reflektanz im UV-Bereich mit pathogenspezifische Auswirkungen verknüpft werden.

Literaturverzeichnis

- BHATTACHARYA A.; SOOD P.; CITOVSKY V. (2010):** The roles of plant phenolics in defence and communication during *Agrobacterium* and *Rhizobium* infection. *Molecular plant pathology*, 11, 705–719.
- FISCHER J. (1995):** Specific detection of nucleotides, creatine phosphate, and their derivatives from tissue samples in a simple, isocratic, recycling, low-volume system. *The magazine of Separation Science*, 8, 254–254.
- GIUSTI M.M.; POLIT M.F.; AYVAZ H.; TAY D.; MANRIQUE I (2014):** Characterization and quantitation of anthocyanins and other phenolics in native Andean potatoes. *Journal of Agricultural and Food Chemistry*, 62, 4408–4416.
- HOLLÓSY, F. (2001):** Effects of ultraviolet radiation on plant cells. *Micron*, 33, 179–197.
- MACKERNESS S.; JOHN C.F.; JORDAN B.; THOMAS B. (2001):** Early signaling components in ultraviolet-B responses: distinct roles for different reactive oxygen species and nitric oxide. *FEBS letters*, 489, 237–242.
- MAHLEIN A.K. (2016):** Plant disease detection by imaging sensors—parallels and specific demands for precision agriculture and plant phenotyping. *Plant Disease*, 100, 241–251.
- MIERZIAK J.; KOSTYN K.; KULMA A. (2014):** Flavonoids as important molecules of plant interactions with the environment. *Molecules*, 19, 16240–16265.
- NAWKAR G.; MAIBAM P.; PARK J.; SAHI V.; LEE S.; KANG C. (2013):** UV-induced cell death in plants. *International Journal of Molecular Sciences*, 14, 1608–1628.
- SANTOS-BUELGA C.; GARCÍA-VIGUERA C.; TOMÁS-BARBERÁN F. (2003):** Online identification of flavonoids by HPLC coupled to diode array detection. *Methods in Polyphenol Analysis*, 92, 127.
- TALROSE V.; YERMAKOV A.; USOV A.; GONCHAROVA A.; LESKIN A.; MESSINEVA N.; TRUSOVA N.; EFIMKINA M. (2009):** UV/visible spectra. NIST Chemistry WebBook, NIST Standard Reference Database, p. 20899.
- THORDAL-CHRISTENSEN H., ZHANG Z., WEI Y. & COLLINGE D.B. (1997):** Subcellular localization of H₂O₂ in plants. H₂O₂ accumulation in papillae and hypersensitive response during the

barley-powdery mildew interaction. – *The Plant Journal*, 11 (6): 1187–1194
<https://doi.org/10.1046/j.1365-313X.1997.11061187.x>.

VAN BREUSEGEM F.; DAT J.F. (2006): Reactive oxygen species in plant cell death. *Plant physiology*, 141, 384–390.

WOLF G.; FRIC F. (1981): A rapid staining method for *Erysiphe graminis* f. sp. *hordei* in and on whole barley leaves with a protein-specific dye. *Phytopathology*, 71, 596–598.

Erkennung von Bodensignalen in 3D Punktwolken einer Apfelplantage

Removing Ground Points from 3D Point Cloud in Apple Orchard

Kowshik K. Saha, Nikolaos Tsoulias, Manuela Zude-Sasse

Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB),

Max-Eyth-Allee 100, 14469 Potsdam

E-Mail: KSaha@atb-potsdam.de

Zusammenfassung: Dreidimensionale (3D) Punktwolken können kulturrelevante Daten zum Wachstumsstadium von Obstbäumen bereitstellen. Eine erste Problemstellung ist hierbei die Erkennung und Segmentierung von Bodenpunkten, um die Bäume zu charakterisieren. Im vorliegenden Experiment wurden 3D Punktwolken in einer 0,6 ha großen Apfelanlage mit 1,5 % Hangneigung mittels Laserscanner gemessen. Der Laserscanner wurde mit einem Traktor in Seitenansicht zu den Bäumen betrieben. In vier Messgängen erfolgte die Messung von 28 Bäume, wobei die Unterscheidung von Boden- und Vegetationspunkten mittels *Cloth Simulation Filter* (CSF) stattfand. Die Ergebnisse zeigen ein hohes Bestimmtheitsmaß, ($R^2 = 0,94$), von CSF Daten und Referenzbodenpunkten, die mit Hilfe eines GNSS ermittelt wurden. Das somit ermöglichte, automatisierbare Verwerfen der Bodensignale kann die Analyse der Baumdaten unterstützen.

Deskriptoren: LIDAR, 3D Punktwolke, Präzisionsgartenbau, CS Filter

Abstract: *Three dimensional (3D) point cloud reconstruction of apple tree morphology can provide valuable data on growth stage of fruit trees. However, soil points need to be defined and segmented from tree points in order to estimate the tree parameters. In this research, a methodology for the detection of 3D soil cloud considering an elevation with 1.5% slope in a 0.6 ha apple orchard was tested. A two dimensional light detection and range (LiDAR) laser scanner mounted on a tractor was used to scan apple trees. One hundred and twelve trees were scanned and the detection of the terrain and aerial points was performed with Cloth Simulation Filter (CSF) algorithm. The result of CSF revealed encouraging potential to detect ground points with appropriate parameters setting. Comparing the results for slope measured by global navigation satellite system and from cloth simulation filtered LiDAR point cloud showed a high agreement ($R^2 = 0.94$). The erase of soil points, particularly in conditions of slight inclination due to elevation*

difference can improve the processing of 3D point clouds and as a consequence predict the tree parameters more accurately.

Keywords: LIDAR, 3D point cloud processing, precision horticulture, CSF algorithm

1 Introduction

Delineation of geometric and structural parameters of fruit trees in non-destructive way is one of the key tasks in the domain of precision horticulture (PH) research. As PH deals with site specific management and decision support system for farm production, a number of agricultural operations, including plant protection, irrigation, fertilization, pruning, harvesting etc., may be optimized by employing geometric information of fruit trees. Attaining precise geometric parameters from the orchard trees is a complex approach due to irregular and non-uniform structures of the trees, density of the tree components, slope of the ground surface, limited point of view.

A number of remote sensing techniques have been used to perform the tree structural characterization. Photogrammetry, stereoscopic techniques, hyperspectral imaging, ultrasonic sensors, and the method of light detection and ranging (LiDAR) were currently tested for canopy measurement and geometrical distribution analyses. LiDAR is one of the remote sensing tools with active light source potentially providing robust and accurate information on the tree structure and vegetation parameters. The LiDAR laser scanner can be installed on different types of platform such as satellite, airborne LiDAR systems, terrestrial LiDAR systems or mobile LiDAR systems. The measuring principle of LiDAR is the measurement of the time of travel of pulsed laser beam from the source to the object and reflected backwards to the detector. After acquisition of the distance data three-dimensional (3D) point clouds of the focused object can be generated. In recent years, mobile LiDAR system (vehicle or robotic platform mounted) appeared as useful tool to acquire high temporal georeferenced 3D tree structure. A number of literatures reveal the potential of 2D LiDAR scanners as a tool for detail observation of the fruit tree structure (SANZ-CORTIELLA *et al.* 2011; OMASA *et al.* 2007).

Tractor-mounted 2D LIDAR scanning system has been utilized for generating 3D reconstruction of the tree rows of pear, apple and vineyards (ROSELL *et al.* 2009a). The acquisition technique of mobile 2D LIDAR scanner is based on the time of flight mode which acquires slices of cross-sectional information when operating between the rows of orchard trees. The, in our study, side looking sensor is capable of emitting and receive laser pulses as a dense point cloud of the tree rows including the soil when scanning from two opposite sides of a tree row. The two independent point clouds produce the complete 3D reconstruction of the trees when fused. Inclusion of a global navigation satellite system (GNSS) can be used to produce a georeferenced 3D point cloud (ROSELL *et al.* 2009b).

To make use of acquired 3D point cloud data needs several processing steps. Complete and accurate 3D reconstruction of the trees requires removal of the outliers, noise

and also ground points detection and removal. Segmenting the ground points from the tree points is the first step of post-processing of 3D point cloud. GARRIDO *et al.* (2015) applied RANSAC algorithm to detect the ground plane followed by gridding filter and noise removal filter. They applied the algorithm to separate bare soil surface from maize plants point cloud in an experimental plot located in a greenhouse. RANSAC algorithm was able to detect the shapes from the point cloud, removing the ground points by means of fitting to a plane.

In the present study, a 0.6 ha commercial apple orchard was chosen for 3D reconstruction using tractor mounted 2D LIDAR system. The selected orchard showed a slight slope of and uneven ground surface unlike the condition, where GARRIDO *et al.* (2015) applied RANSAC to detect ground plane. The objective of this research is to test an effective methodology for removal of ground soil-points from the 3D point cloud considering such real-world orchard.

2 Material und Methods

Field data collection

The field test was carried out in a 0.6 ha commercial apple orchard having a gentle slope in elevation of roughly 1.5 % in north-south direction located in the Potsdam-Marquardt, Germany. Four measurements were carried out, each on 28 trees, in total 112 trees. The LIDAR sensor was mounted on a tractor and driven parallel to the rows of the orchard at constant speed (1 km/h) at 2.5 m distance from the row axis (**Figure 1**). The height of the laser scanner (1.6 m) was approximately half the maximum height of the trees (3.5 m). An angular resolution of 0.167° and 100 Hz scanning frequency was used. A real time kinematic global navigation satellite system (RTK-GNSS) (AgGPS 542, Trimble, Sunnyvale, USA) was placed vertically next to the LiDAR to georeference each scan of the LiDAR. Furthermore, an inertial measurement unit (IMU) (MTi-G-710, XSens, Enschede, The Netherlands) was used to provide roll, pitch, and yaw information needed to correct sensor readings for deviation due to the movement of the tractor. The IMU worked at the same frequency with LiDAR, whilst the RTK-GNSS worked at 5 Hz. Thus, software was developed in Visual Studio (Microsoft, USA) for all data to be timestamped, synchronized and saved on computer in a txt file. The LiDAR scanner was used to scan from both sides of a tree row perpendicular to the direction of travel with 270° field of view. Therefore, the side looking laser scanner could acquire data from complete trees vertically and the ground points as well.




Figure 1. Coordinate system of the LiDAR sensor movement during data acquisition. X direction is the tractor's path of travel, YZ plane is the scanning plane.

LIDAR data processing

The acquired point clouds captured noises, outliers and points from the ground surface. A low pass filter served as noise removal filter. This algorithm locally fits a plane around each point of the cloud and then removes the point if it's too far away from the fitted plane thus reducing the size of the point cloud.

Cloth simulation filtering (CSF) algorithm was applied to detect and separate the ground points from the aerial points of point clouds. CSF algorithm utilizes a cloth simulation technique to separate point clouds into ground and non-ground points (ZHANG *et al.* 2016). The method is based on the simulation of a simple physical process which turned the point cloud surface upside down, and then a cloth with rigidity falls under the action of gravity, the final shape of the cloth is the terrain model (**Figure 2**). Finally a threshold was applied to separate the ground and non-ground points based on the distance between cloth nodes and points. CSF algorithm involves four parameters, such as, i) grid resolution (GR), which represents the horizontal distance between two neighboring particles; ii) time step (DT), which controls the displacement of particles from gravity during each iteration; iii) rigidity (RI), which controls the rigidity of the cloth and iv) iterations numbers (IN), which controls the maximum iteration numbers.




Figure 2. Overview of the cloth simulation algorithm (ZHANG *et al.* 2016).

3 Result and Discussion

Parameter setting for CSF

The tractor mounted LiDAR laser scanner generated high density point cloud from the tree rows including the ground surface (**Figure 3a**). After application of manual delimitation with the row dimension the outer points were discarded from the raw point clouds. Each point cloud consists of ground points from approximately 127.5 m² (85 × 1.5 m) area. Due to dense point cloud the cloth resolution parameter value of 1.0 was selected, maximum iteration number was set at 1000 and the classification threshold parameter value was 0.3 to optimize the segmentation result. Cloth resolution parameter determines the grid size of the simulated cloth, which is used to cover the terrain. The minimum value (1.0) was chosen to get a fine DTM, which was used afterwards to determine the slope precisely. Classification threshold is another important parameter for CSF algorithm classifying the pointclouds into ground and non-ground (aerial) parts based on the distances between points and the simulated terrain. As in this case the tree height is an important parameter for precision horticulture research, the separation point should be kept as near a possible to the ground surface. With 0.3 classification threshold optimum classification result was obtained and evaluated visually (**Figure 3b**). With the present measuring set-up between 61 and 65 % of the laser hits went to the ground (**Table 1**). In the four observations the results appeared similar considering the percentage of relevant laser hits.

Table 1. Point cloud classification result for four exemplary tree-row point clouds.

Observation no.	Total number of points	Aerial points	Ground points
1	4,291,097	1,501,442 (34.99 %)	2,695,997 (62.83 %)
2	4,221,031	1,368,407 (35.23 %)	2,753,332 (63.43 %)
3	4,272,159	1,504,944 (32.42 %)	2,710,040 (65.23 %)
4	4,277,804	1,566,894 (36.63 %)	2,649,829 (61.94 %)

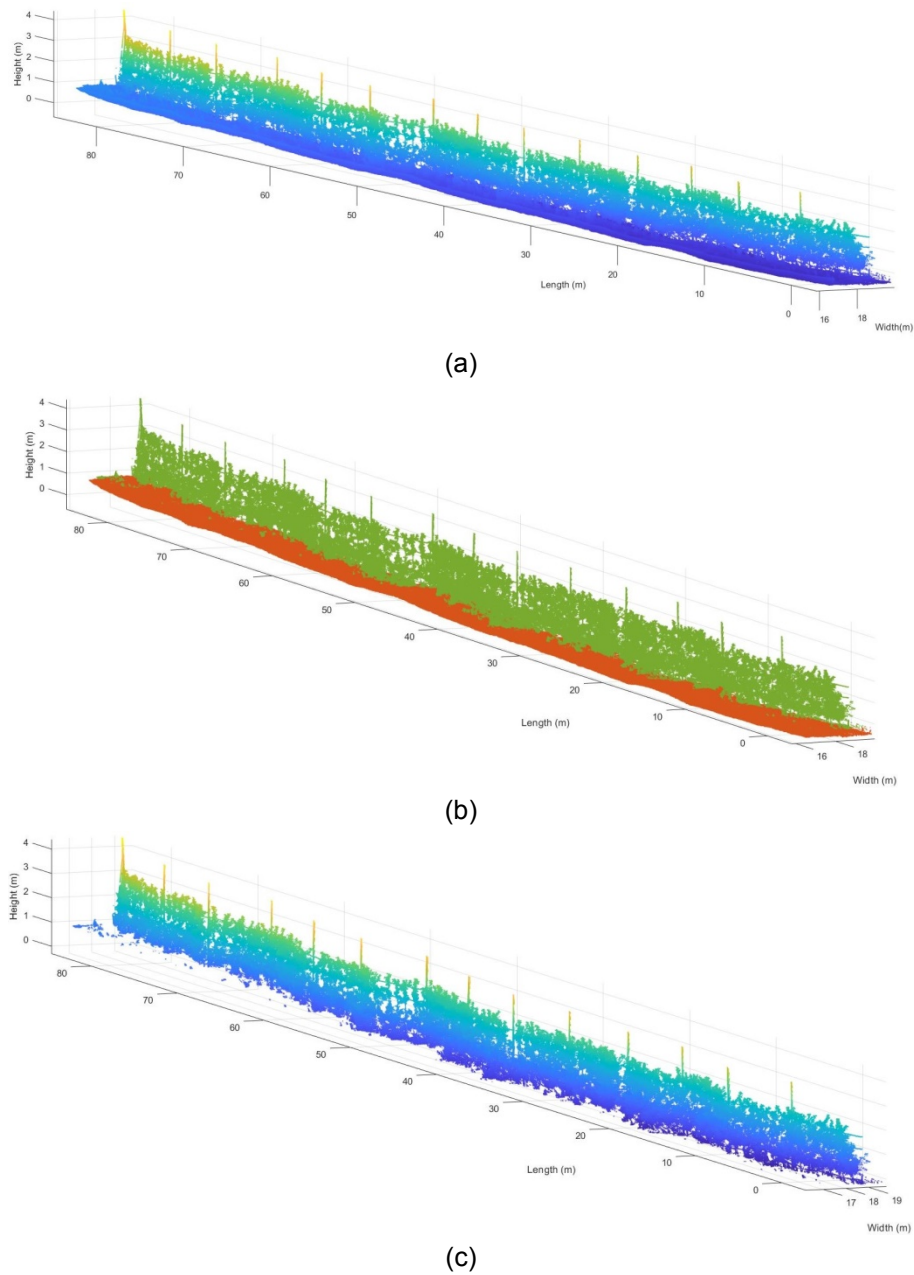


Figure 3. (a) Original point cloud, (b) after classified as ground and aerial points using CSF algorithm, and (c) final tree point cloud after ground points removed.

Comparison to GNSS data

After removing the aerial points the remaining ground point cloud (**Figure 4**) was used to calculate the slope of terrain. The calculated slope was compared with the slope measured using GNSS during acquisition of the LiDAR data.




Figure 4. Segmented ground point cloud from a typical LiDAR data set.

The visual observation of the point clouds show difference in slope due to the soil surface covered with grass (**Figure 4**). The linear regression analysis of slope measured by GNSS and slope calculated from cloth simulation filtered LiDAR point cloud for the four scans reveal high coefficient of determination ($R^2 = 0.94$) which indicates a good consistency between the datasets (**Figure 5**). The results showed that the percent slope obtained from the LiDAR-based elevation model are very close to the measured slope from the GNSS elevation data.




Figure 5. Linear regression equation ($y = 0.7984x + 0.2831$) obtained between slopes from GNSS and filtered LiDAR ground point cloud.

4 Conclusion

In this study, the effectiveness of the CSF algorithm was tested to classify the ground points and the aerial (tree) points from the point cloud acquired by a mobile LiDAR sys-

tem in a apple orchard with slight slope. The classificaton result revealed that about two-third of the total number of points in a point cloud belonged to sloped ground points. Comparison of slope results proved that the algorithm is capable to detect varying terrain surface.

References

- CAI S., ZHANG W., QI J., WAN P., SHAO J., and SHEN A. (2018):** Applicability Analysis of Cloth Simulation Filtering Algorithm for Mobile LIDAR Point Cloud, *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLII-3, 107-111. <https://doi.org/10.5194/isprs-archives-XLII-3-107-2018>.
- GARRIDO M., PARAFOROS D. S., REISER D., ARELLANO M. V., GRIEPENTROG H. W., & VALERO C. (2015):** 3D Maize Plant Reconstruction Based on Georeferenced Overlapping Lidar Point Clouds. *Remote Sensing*, 7(12), 17077–17096. <https://doi.org/10.3390/rs71215870>.
- OMASA K., HOSOI F., & KONISHI A. (2007):** 3D lidar imaging for detecting and understanding plant responses and canopy structure. *Journal of Experimental Botany*, 58(4), 881–898. <https://doi.org/10.1093/jxb/erl142>.
- ROSELL-POLO J.R., SANZ R., LLORENS J., ARNÓ J., RIBES-DASI M., MASIP J., CAMP F., GRÀCIA F., SOLANELLES F., PALLEJÀ T.s. (2009a):** A tractor-mounted scanning lidar for the non-destructive measurement of vegetative volume and surface area of tree-row plantations: A comparison with conventional destructive measurements. *Biosyst. Eng.* 102, 128–134.
- ROSELL J.R., LLORENS J., SANZ R., ARNO J., RIBES-DASI M., MASIP J., ESCOLÀ A., CAMP F., SOLANELLES F., GRÀCIA F. (2009b):** Obtaining the three-dimensional structure of tree orchards from remote 2D terrestrial lidar scanning. *Agric. For. Meteorol.* 149, 1505–1515.
- Sanz-Cortiella R., Llorens-Calveras J., Escolà A., Arnó-Satorra J., Ribes-Dasi M., Masip-Vilalta J., Camp F., Gràcia-Aguilá F., Solanelles-Batlle F., Planas-DeMartí S., Pallejà-Cabré T., Palacin-Roca J., Gregorio-Lopez E., Del-Moral-Martínez I., Rosell-Polo J.R. (2011):** Innovative LIDAR 3D dynamic measurement system to estimate fruit-tree leaf area. *Sensors*, 11(6), 5769–5791. <https://doi.org/10.3390/s110605769>.
- ZHANG W., QI J., WAN P., WANG H., XIE D., and WANG X. (2016):** An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. *Remote Sens.* 2016, 8, 501. <https://doi.org/10.3390/rs8060501>.

Validating the accuracy of 3D point cloud reconstruction on standard box and fruit trees in the field

Validierung von 3D Punktwolken mittels Kalibrierkörper im obstbaulichen Versuch

Nikolaos Tsoulas¹, Dimitrios S. Paraforos², Spyros Fountas³, Manuela Zude-Sasse¹

¹Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB),
Max-Eyth-Allee 100, 14469 Potsdam

²Universität Hohenheim, Institute of Agricultural Engineering, Technology in Crop Production,
Garbenstraße 9, 70599 Stuttgart

³Agricultural University of Athens, Department of Natural Resource Management and
Agricultural Engineering, Iera odos 75, 11855 Athens
E-Mail: ntsoulas@atb-potsdam.de

Zusammenfassung: Die Überführung von 3D Punktwolken aus dem lokalen System der Aufzeichnung in ein übergeordnetes System zum Zusammenführen von Punktwolken komplexer Baumarchitekturen ist immernoch eine Herausforderung, jedoch wesentlich für die Nutzung terrestrischer LiDAR Laserscanner in gartenbaulichen Anwendungen. In der vorliegenden Arbeit wurde ein Metallquader mit bekannter Größe von vier Seiten abgetastet, um die Registrierung im Feld zu validieren. Darüberhinaus wurden sechs Apfelbäume in der im Erwerbsobstbau üblichen Baumform einer schlanken Spindel von beiden Seiten gescannt und hinsichtlich Höhe und Breite bonitiert. Für das Registrierungsverfahren der direkten Georeferenzierung wurde der Laserscanner sowie ein Echtzeit kinematisches globales Satellitennavigationssystem (RTK-GNSS) und inertiales Messsystem (IMU) an der Rückseite eines Traktors betrieben. Die Translation und Rotation vom RTK-GNSS zum Laserscanner wurde verfolgt, um jede Baumseite individuell zu bestimmen. Für die Feinregistrierung und das Zusammenführen der beiden Baumseiten wurde der *Iterative Closest Point* (ICP) Algorithmus eingesetzt. Die Schätzung der Quadergröße mittels Laserscanner ergab eine Messunsicherheit, hier als mittlerer quadratischer Fehler, von 0,5 %. Die Boniturdaten der Bäume und die Analyse mit dem Laserscanner waren positiv korreliert mit einem Bestimmtheitsmaß von $R^2=0,85$. Die Anwendung des ICP Algorithmus reduzierte die Messunsicherheit bei der Fusion der Punktwolken der Baumseiten. Die somit georeferenzierten 3D Punktwolken ermöglichen weiterhin die Fusion von Punktwolken, die in variierenden Baumwachstumsphasen aufgenommen wurden, um räumlich-zeitlich aufgelöste Baumdaten und Informationen über den Bestand im kommerziellen Obstbau zu erhalten.

Deskriptoren: 3D Punktwolke, Obstbaum, Laserscanner, LiDAR

Abstract: *Point cloud rigid registration and stitching for plants with complex architecture is a challenging task, however, it is an important process to utilize the 3D data in agricultural applications. In this research a metal box, with known dimensions, was scanned from four sides to validate the measuring uncertainty of a light detection and range (LiDAR) laser scanner. Furthermore, 6 apple trees were scanned from both sides, and measured manually considering height and width. The LiDAR sensor together with a real time kinematic global navigation satellite system (RTK-GNSS) and an inertial measurement unit (IMU) were mounted on a metal construction, on the rear side of the tractor. Thus, serial translation and rotation from the RTK-GNSS to the LiDAR sensor were followed in order to reconstruct each side individually, whereas iterative closest point (ICP) algorithm was used to fuse the sides. The estimation of the metal box dimensions had a 99% accuracy and 0.5% root mean square error from the 3D point cloud. The manual measurements of tree height and width correlated positively with the LiDAR data ($r=0.85$). The application of the ICP algorithm proved to be a significant tool during point cloud fusion that minimizes the error metric based on the distance between point clouds. From the results it was proved that the LiDAR position and distance from the RTK-GNSS is crucial with the number of final points that are used for the 3D plant reconstruction. Having the georeferenced 3D reconstruction of the fruit trees from different growth stages, other time-stamped georeferenced data can be fused to the existing plant reconstruction. The produced 3D plant structure can be used for plant phenotyping purposes in order to detect complex plant traits.*

Keywords: *3D point cloud, fruit tree, laser scanner, LiDAR*

Ermittlung geeigneter Wellenlängen für das automatische Klassifizieren von Pflanzen und Früchten

Determination of suitable wavelengths for the automatic classification of plants and fruits

Joachim Intreß und Martin Geyer

*Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB),
Max-Eyth-Allee 100, 14469 Potsdam
E-Mail: jintress@atb-potsdam.de*

Zusammenfassung: Die Automatisierung des Ernteprozesses erfordert die visuelle Erkennung von Früchten und Pflanzen. Hyperspektralaufnahmen liefern hierfür eine geeignete Basis. Die Auswertung dieser Aufnahmen ist jedoch mit einem hohen Ressourcenaufwand verbunden. In der Regel ist aber nur ein kleiner Teil dieser Daten, einige wenige Wellenlängen, für die Klassifizierung wirklich aussagekräftig. Können diese Wellenlängen sicher ermittelt werden, wird der Einsatz einer Multispektralkamera möglich. Wir haben ein Programm in der Programmiersprache C# entwickelt, welches beim Auffinden dieser Wellenlängen unterstützen kann. Als Anwendungsbeispiel wurde die Erkennung von Einlegegurken für die maschinelle Ernte gewählt. Im RGB-Bereich unterscheiden sich Gurken und Blätter nur wenig. Beziehen wir hingegen das Spektrum zwischen 400 bis 1000 nm Wellenlänge (Bereich der Hyperspektralkamera) in die Erfassung ein, können beide Pflanzenteile gut unterschieden werden.

Problematisch für eine eindeutige Unterscheidung ist, dass das Spektralprofil von Pflanzen relativ großen Streuungen unterliegt. Daher ist es notwendig, mehrere Aufnahmen zusammen auszuwerten. Diese Aufnahmen sollten möglichst alle zu erwartenden Zustände der späteren Anwendung abbilden. Die je Aufnahme gefundenen Wellenlängenbereiche gelten immer nur für ein Objektpaar. Die Analyse muss daher immer für alle möglichen Kombinationen ausgeführt werden. In unserem Beispiel sind diese Objekte der Hintergrund (Erde, Topf, Rankgestell), die Gurken, die Stiele und die Blätter der Pflanze.

Das von uns entwickelte Programm soll den Anwender bei dieser zeitaufwendigen Analyse entlasten. Hierzu gibt das Programm die gefundenen Wellenlängenbereiche in Form einer Tabelle und einer Grafik aus. Anhand dieser Ausgaben ist es dem Nutzer relativ einfach möglich, geeignete Wellenlängen für die Bildung der Indizes festzulegen. Zusätzlich werden Abweichungen in einzelnen Aufnahmen hervorgehoben. In einem zweiten Schritt können die so ermittelten Indizes an weiteren Aufnahmen getestet werden. Das Programm gibt wiederum für alle Einzelaufnahmen und alle Objekte die Statistik (Mittelwert und Perzentile) in Tabellenform und als Grafik aus.

Deskriptoren: Hyperspektral, Multispektral, Bildbearbeitung, Gurke, Einlegegurken, Klassifizierung

Abstract: *The automation of the harvesting process requires the visual recognition of fruits and plants. For this purpose hyperspectral images provide a suitable basis. The evaluation of these recordings, however, is associated with a high consumption of resources. In general, only a small part of these data, a few wavelengths, is really meaningful for the classification. If these wavelengths can be reliably determined, the use of a multi-spectral camera becomes possible. We have developed a program in C # which can help to find these wavelengths. As an application example, the gherkin detection for machine harvest was selected. Here, the cucumber fruit and leaves in the RGB range differ only slightly. On the other hand, if we include in the detection the spectrum between 400 to 1000 nm wavelength (range of the hyperspectral camera), both parts of the plant can be well distinguished. The problem is that the spectral profile of a plant is subject to relatively large scatter. Therefore, it is necessary to evaluate multiple recordings together. These recordings should, as far as possible, reflect all expected situations of later use. The wavelength ranges found per shot are only valid for one object pair. Therefore, the analysis must always be executed for all possible combinations. In our example, these objects are the background (soil, pot, climbing frame, etc.), the cucumbers, the stems and the leaves of the plant.*

The program developed by us is intended to relieve the user in this time-consuming analysis. In the hyperspectral images, the objects to be classified (gherkin, leaf and stem) are first masked and these masks are then stored in a directory together with the hyperspectral images. The program first normalizes all recordings and forms the possible object pairs (cucumber leaf, cucumber stalk, stem leaf). Now it is automatically checked in each individual recording and for each wavelength, to what extent the selected object pair can be distinguished on this wavelength. For the example of cucumber and leaf, several wavelength ranges were found in which the two objects can be distinguished from each other. However, these ranges vary more or less from one shot to the next. The program outputs the wavelength ranges found in this way in the form of a table and a graphic. Based on these outputs, it is relatively easy for the user to determine appropriate wavelengths for the formation of the indices. In addition, deviations in individual images are highlighted. So the user has the opportunity to search specifically for the causes of these deviations.

In a second step, the indices determined can be tested on further recordings. The program again outputs the statistics (mean and percentiles) in tabular form and as a graph for all individual images and all objects. This information makes it possible to establish appropriate classification limits. In addition, different single shots can easily be compared with each other and problems resulting from different environmental conditions can be detected at an early stage.

Keywords: hyperspectral, multispectral, image processing, pickling cucumber, gherkin, classification

1 Einleitung

Die automatisierte Ernte von Feldfrüchten wird in Zukunft eine immer größere Bedeutung erlangen (HEMMING 2001, FERNANDEZ *et al.* 2014, SHAMSHIRI *et al.* 2018). Eine wichtige Voraussetzung hierfür ist die automatische, visuelle Erkennung dieser Früchte. Viele grüne Früchte, wie z.B. Gurken unterscheiden sich im RGB-Bereich nur wenig bis gar nicht von Blättern und Stielen der Pflanzen (Bao *et al.* 2016). Eine bessere Unterscheidung ist hier nur durch die Einbeziehung zusätzlicher Wellenlängen mit Hilfe einer Multispektralkamera möglich (FERNANDEZ *et al.* 2018). Die geeigneten Wellenlängen müssen jedoch zunächst ermittelt werden. Hier kommt eine Hyperspektralkamera zum Einsatz.

Ein Problem hierbei ist, dass die Spektralprofile der Pflanzen relativ großen Streuungen unterliegen. Gleichzeitig spiegelt das Spektralprofil den aktuellen, vitalen Zustand dieser Pflanze wieder. Dies alles macht es nötig, möglichst viele, unter verschiedenen Bedingungen aufgenommene Hyperspektralbilder zu vergleichen. Dieser Vorgang ist von Hand relativ zeitaufwendig.

Wir haben ein Programm entwickelt, das es gestattet, viele, beliebig auswählbare Hyperspektralaufnahmen automatisch miteinander zu vergleichen.

2 Material und Methoden

Am Forschungsstandort Marquardt des ATB wurden 4 Sorten Einlegegurken des Gemüsezüchtungsunternehmens (Rijk Zwaan Welver GmbH, Welver) angebaut. Parallel dazu wurden einige Gurkenpflanzen der Sorte 1 in Töpfen angezogen. Stichproben dieser Pflanzen wurden mit einer Hyperspektralkamera aufgenommen.

Eingesetzt wurde eine Hyperspektralkamera (Zeutec Opto-Elektronik GmbH, Rendsburg) bestehend aus den folgenden Bestandteilen:

- Spektrograph ImSector V10E (400 bis 1000 nm, spektrale Auflösung: 2,5 nm) (Fa. Specim Spectral Imaging Ltd. Oulu, Finnland)
- s/w-Kamera Pixelfly qe (Fa. PCO AG, Kehlheim, Germany)
- Schrittmotorgesteuerter Rotationsspiegel (Fa. MicroStep)

Als Lichtquelle kam ein 150 W Gleichstromstabilisiertes Halogen-Zeilenlicht (über Glasfaser) zum Einsatz. Die Ansteuersoftware wurde in unserem Haus in LabView 8.2 (National Instruments AG, Texas) selbst programmiert.



Abbildung 1: die gemessenen Pflanzen (von links nach rechts) a) am Versuchsstandort Marquardt; b) die für die Messung getopferten Pflanzen c) Pflanze während der Messung im Hyperspektrallabor

Da die verwendete Messtechnik nur unter Laborbedingungen einsatzfähig ist, erfolgten die Messungen ausschließlich unter Laborbedingungen. Die Feldpflanzen wurden unmittelbar nach ihrer Entnahme innerhalb von 2 Stunden gemessen.

In unserem Fall wollten wir 4 Objekte in den Bildern klassifizieren:

- Gurken
- Blätter
- Stiele
- Hintergrund (Rankgestell, Erde, Topf, ...)

Da Gurken, Blätter und Stiele das typische Spektralprofil grüner Pflanzen aufweisen, bietet sich der Normalized Difference Vegetation Index (NDVI) zur Freistellung der Pflanzen im Bild an. Dieser Sachverhalt wurde überprüft und bestätigt. Die folgende Untersuchung beschränkt sich nun auf die Objekte der Pflanze.

Das Ziel war, dass die Klassifizierung über Indizes, analog dem NDVI erfolgen soll. Hierfür müssen zunächst die Wellenlängen ermittelt werden, an denen sich die einzelnen Objekte, unter Einbeziehung der Streuung unterscheiden.

Zunächst müssen die Objekte in allen Aufnahmen manuell maskiert werden. Dies geschieht mit Hilfe eines Bildbearbeitungsprogramms (Name, Hersteller, Ort) und kann im einfachsten Fall darin bestehen, genügend große Regionen innerhalb der Objekte auszuwählen. Die eigentliche Auswertung (Berechnung) erfolgt in dem von uns erstellten Programm. Hierzu werden Hyperspektralbilder und Masken (gekennzeichnet durch eine Erweiterung des Dateinamens) in den entsprechenden Verzeichnissen abgelegt. Die Verzeichnisse werden automatisch bei der Programminstallation angelegt (**Abbildung 2**).

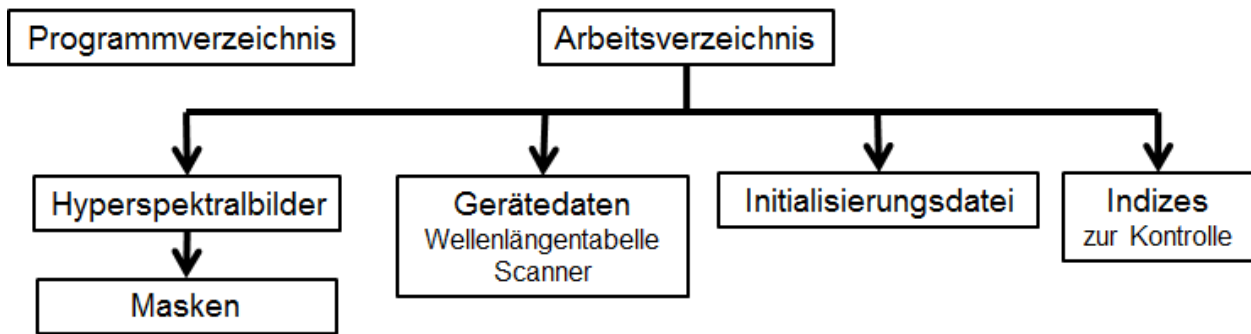


Abbildung 2: Verzeichnisstruktur des Programms

Das Programm selbst führt die Auswertung in 2 Arbeitsschritten aus. Im ersten Schritt werden die Hyperspektralbilder zunächst normiert und daran anschließend die möglichen Objektpaare gebildet. Das sind in unserem Fall:

- Gurke–Blatt
- Gurke–Stiel
- Stiel–Blatt

Das Programm berechnet nun getrennt für jedes Hyperspektralbild und jedes Objekt die statistische Verteilung der Messwerte für jedes Wellenlängenband. Daran anschließend bestimmt das Programm für jedes Objektpaar den Abstand (bzw. die Überschneidung) zwischen beiden Objekten unter Einbeziehung des Streubereichs in jedem Band. Hierfür werden für jedes Objekt die Perzentile (P5, P10, P25, P75, P90 und P95) und der Median berechnet. Diese Werte werden nun in einem Diagramm und in einer Tabelle ausgegeben.




Abbildung 3: Das Objektpaar Gurke–Blatt unterscheidet sich für die 4 Sorten und in Abhängigkeit der Perzentile in den folgenden Wellenlängenbereichen

Gesucht werden nun die Wellenlängenbereiche, in denen sich in allen Bildern die Objektpaare nicht (bzw. möglichst wenig) überschneiden (siehe **Abbildung 3**). Die so gefundenen Wellenlängen sind in Verbindung mit dem Spektralprofil der Ausgangspunkt für die Bildung der Indizes.

Es hat sich als günstiger erwiesen, diese Indizes manuell zu ermitteln. Denn die Lage dieser Wellenlängen im Spektralprofil hat hier großen Einfluss.

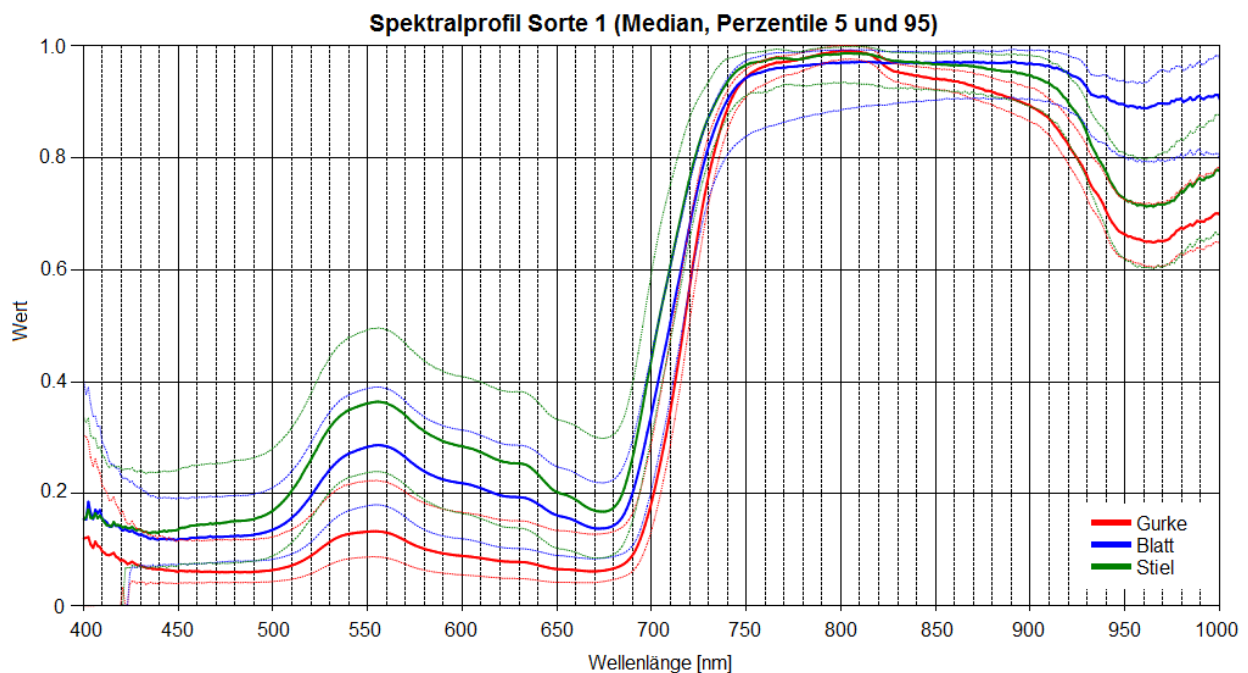


Abbildung 4: Die mittleren Spektralprofile von Gurken, Blättern und Stielen unter Einbeziehung der Streuung (P5 und P95; dünne Linien)

Der für die Unterscheidung Gurke-Blatt gefundene Wellenlängenbereich (940 bis 970 nm) bildet die Wasserbande ab. In diesem Fall erscheint uns die Auswertung der Flanke, hin zu 850 nm am günstigsten. Wir kommen in diesem Fall, analog zum NDVI auf den Index $(890 - 965) / (890 + 965)$ (VAN HENTEN *et al.* 2002, NOBLE & LI 2012).

Um das Klassifizierungsergebnis zu verbessern, kann es vorteilhaft sein, mehrere Indizes miteinander zu kombinieren. Auch diese Vorgehensweise unterstützt unser Programm.

Weisen die innerhalb der Hyperspektralbilder gefundenen Wellenlängenbereiche (beim Vergleich einer größeren Anzahl von Bildern) Gruppierungen auf, sollte man die Ursachen anhand der Metadaten ermitteln. Dieser Programmteil ist noch in Entwicklung. In unserem Versuch war dies nicht der Fall.

Im zweiten Teil des Programms wird nun das Klassifizierungsergebnis geprüft. Hierfür werden die gefundenen Indizes manuell eingegeben und die Statistikwerte für jedes Objekt und jeden Index über alle Bilder automatisch berechnet. Die Ergebnisse werden graphisch dargestellt und in Tabellenform als Textdatei ausgegeben. Auf dieser Grundlage kann jetzt manuell für jeden Index ein Grenzwert ermittelt und der Index auf seine Anwendbarkeit hin überprüft werden.

3 Ergebnisse

Anwendung des Programms

Das Programm erlaubt es in relativ kurzer Zeit, geeignete Wellenlängen für die Objekt-klassifizierung zu ermitteln und diese anhand weiterer Aufnahmen statistisch abzusi-chern.




Abbildung 5: Vergleich der 3 Objektpaare für die 4 Sorten und in Abhängigkeit der Perzentile

Für die Objektpaare Gurke-Blatt und Blatt-Stiel zeigt der Vergleich die größten Unterschiede im Wellenlängenbereich zwischen 940 und 970 nm. Wie bereits oben beschrieben, ergibt sich hier der Index 1 zu $(890 - 965) / (890 + 965)$ [nm]. Das Objektpaar Gurke-Stiel zeigte den größten Unterschied im Bereich um 550 nm. Hier bieten sich vom Spektralprofil ausgehend zwei Indizes an. Einmal der normierte Grünanteil $555 / 805$ [nm] (Index 2) und zum zweiten die Flanke in Richtung „Blau“ $(555 - 520) / (555 + 520)$ [nm] (Index 3). Alle 3 Indizes werden im folgendem mit unserem Programm überprüft.

Für eine Untersuchung der signifikanten Unterschiede zwischen den Sorten 1 und 2 sowie 3 und 4 reichte die Anzahl unserer durchgeführten Messungen nicht aus. In **Abbildung 6** ist die graphische Programmausgabe für jeden überprüften Index dargestellt. Hier ist deutlich zu erkennen das Index 1 signifikant zwischen Gurke und Blatt sowie zwischen Blatt und Stiel unterscheidet. Eine Trennung zwischen Gurke und Stiel ist mit Index 1 nicht möglich. Die beste Trennung zwischen Gurke und Stiel liefert Index 2. Zwar ist auch hier keine 100% Klassifizierung gegeben, es treten aber deutliche Unterschiede auf. In Anbetracht der morphologischen Unterschiede zwischen Gurken und Stielen stellt sich hier die Frage, ob es gerechtfertigt ist einen größeren Aufwand zu betreiben.

Das entwickelte Programm liefert für die jeweiligen Indizes keine Grenzwertempfehlung. Es sollte auf Basis der Graphischen- und der Tabellenausgabe aber problemlos möglich sein, den entsprechenden Grenzwert manuell festzulegen.

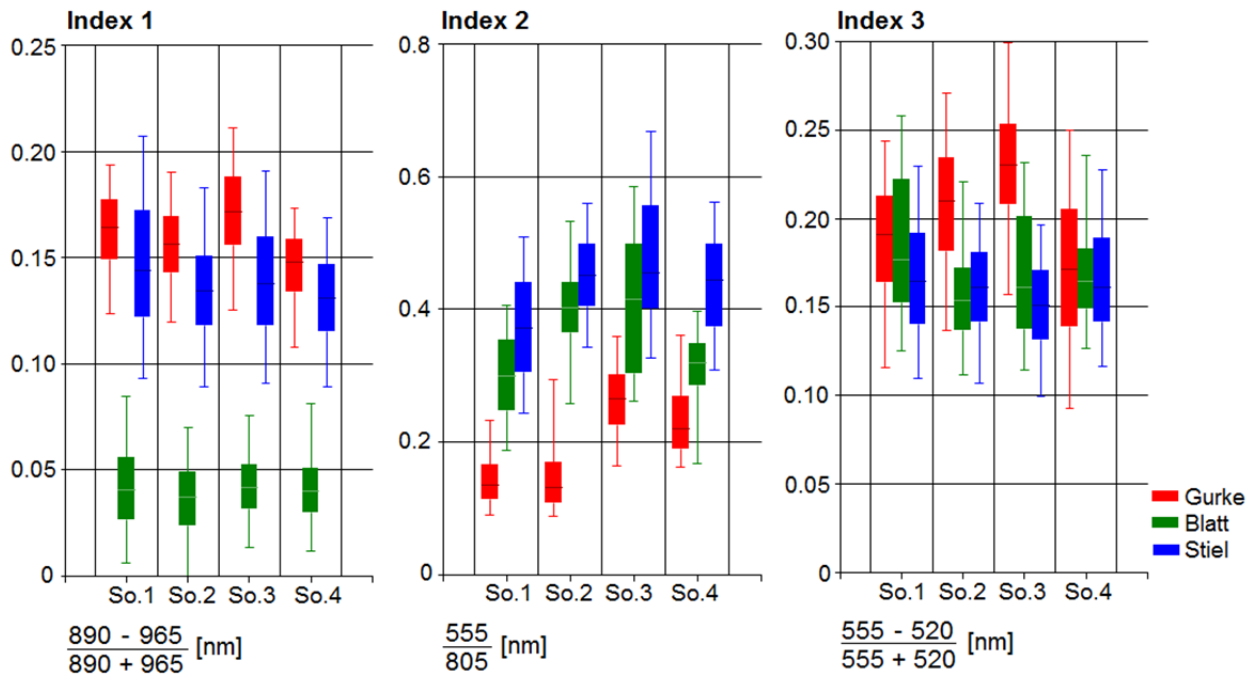


Abbildung 6: Streubreiche der Objekte in den jeweiligen Indexbildern

Eine weitere Kontrollmöglichkeit des Programms besteht darin, die einzelnen Indizes (zusammen mit den manuell festgelegten Grenzwerten) direkt auf einzelne Hyperspektralbilder anzuwenden und ein Ausgabebild zu berechnen und abzuspeichern. Dieses Bild kann dann in einem beliebigen Bildbearbeitungsprogramm (z.B. ENVI, Harris Geospatial Solutions, Broomfield) geöffnet und das Klassifizierungsergebnis manuell kontrolliert werden. So können Schwachstellen und Probleme recht gut erkannt werden.




Abbildung 7: a) RGB-Aufnahme b) mit NDVI maskiert c) Index 1 angewendet auf das maskierte Bild

Wurden in den Bildern alle zu klassifizierenden Objekte vollständig maskiert, kann eine automatische Kontrolle des Klassifizierungsergebnisses über das Programm erfolgen. Hier werden dann die klassifizierten Pixel mit den maskierten Pixeln bildweise verglichen und das Ergebnis in Form einer Tabelle ausgegeben. Das Programm erlaubt die Klassifizierung von bis zu 4 Objekten in beliebigen Hyperspektralaufnahmen. Die Art der Objekte ist nicht entscheidend. Es kann sich hier beispielsweise um Pflanzen aber auch um Insekten handeln. Im Moment müssen alle Hyperspektralbilder mit der glei-

chen Kamera aufgenommen worden sein (Wellenlängenzuordnung zu den jeweiligen Bändern). Bei Bedarf ist hier jedoch eine Erweiterung der Software möglich.

Mit Kenntnis der Indizes bzw. der für die Unterscheidung relevanten Wellenlängen, kann eine Multispektralkamera zum Einsatz kommen. Diese ist kostengünstiger und im praktischen Einsatz wesentlich leichter zu handhaben.

4 Ausblick

Das beschriebene Programm wird ständig weiter entwickelt. Wir möchten es ihnen aber gerne für Tests zur Verfügung stellen. Es kann von der ATB-Homepage über www.atb-potsdam.de/institut/fachabteilungen/technik-im-gartenbau/kompetenzen/sensortechnik/hyperspektralmessung.html heruntergeladen werden. Über Rückmeldungen, Kritiken und Anregungen für die Weiterentwicklung würden wir uns freuen.

Literaturverzeichnis

- FERNANDEZ R., MONTES H., SURDILOVIC J., SURDILOVIC D., DE-SANTOS G., ARMADA M. (2018):** Automatic Detection of Field-Grown Cucumbers for Robotic Harvesting, IEEE ACCESS, 6, pp. 35512–35527. DOI: 10.1109/ACCESS.2018.2851376.
- FERNÁNDEZ R., SALINAS C., MONTES H. und SARRIA J., (2014):** Multisensory system for fruit harvesting robots. Experimental testing in natural scenarios and with different kinds of crops, Sensors, 14(12), pp. 23885–23904.
- SHAMSHIRI R.R., WELTZIEN C., HAMEED I.A., YULE I.J., GRIFT T.E., BALASUNDRAM S.K. (2018):** Research and development in agricultural robotics: A perspective of digitalfarming, Int J Agric & Biol Eng, 11(4), pp. 1–14.
- VAN HENTEN E.J., HEMMING J., VAN TUIJL B.A.J., KORNET J.G., MEULEMAN J., BONTSEMA J., VAN OS E.A. (2002):** An autonomous robot for harvesting cucumbers in greenhouses, Autonomous Robots, 13(3), pp. 241–258.
- BAO G., CAI S., QI L., XUN Y., ZHANG L. und YANG Q. (2016):** Multi-template matching algorithm for cucumber recognition in natural environment, Comput. Electron. Agricult., 127, pp. 754–762.
- SCOTT D.N., DALI L. (2012):** Segmentation of Greenhouse Cucumber Plants in Multi-Spectral Imagery, Proc. International Conference of Agricultural Engineering, CIGR-Ageng.
- HEMMING J. (2001):** Bildanalyse für die robotisierte Ernte von Gewächshausgurken, Bornimer Agrartechn. Berichte, 26, pp. 42–52.

Automatisierte flugrobotergestützte Unkrauterken- nung als Voraussetzung für eine teilflächenspezifische Herbizidbehandlung im Ackerbau

Automated aerial weed detection as a prerequisite for site-specific herbicide treatment in crop cultivation

Michael Pflanz^{1,2}, Michael Schirrmann², Christina Wellhausen¹, Henning Nordmeyer¹

¹Julius Kühn-Institut, Institut für Pflanzenschutz in Ackerbau und Grünland,
Messeweg 11–12, 38104 Braunschweig

²Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB),
Max-Eyth-Allee 100, 14469 Potsdam
E-Mail: michael.pflanz@julius-kuehn.de

Zusammenfassung: Moderne digitalisierte Pflanzenschutztechnik bringt inzwischen eine der technologischen Voraussetzungen mit, um im Ackerbau Herbizidmaßnahmen teilflächenspezifisch durchführen zu können. Eine weitere Voraussetzung sind exakte Unkrautverteilungskarten, die im Idealfall nicht nur zwischen Nutzpflanze und Unkraut unterscheiden, sondern auch eine artspezifische räumliche Verteilung zeigen. Dies ist gegenwärtig nur durch manuelle Feldbonituren zu leisten, was sehr arbeits- und kostenaufwendig ist. Hier liegt eine große Chance und zugleich Herausforderung für eine automatisierte Erkennung verschiedener Leitunkräuter auf Basis von flugroboter-generierten Luftbildern.

Das hier vorgestellte Projekt verwendet Luftbildaufnahmen, die mit einem unbemannten Flugsystem (UAS) in geringer Flughöhe aufgezeichnet wurden, um eine ausreichende Abbildungsleistung für die objektbasierte Unterscheidung einzelner Unkräuter zu liefern. Auf Basis dieser Luftbilder wurde ein Bildklassifikator getestet, der mehrere Unkrautarten unterscheiden kann. Mit Hilfe eines Bag-of-visual-Word-Ansatzes (BoVW) wurden Support-Vektor-Maschinen trainiert, nachdem aus mehr als 20.000 Einzelbildern von Unkräutern lokale Objektmerkmale extrahiert wurden.

Die trainierten BoVW-Modelle wurden schließlich auf Testluftbildern validiert, die über einem Versuchsfeld des Julius Kühn-Institutes an insgesamt 108 Punkten in Flughöhen zwischen 1 und 6 m mit einem UAS aufgenommen wurden. Aus den UAS-Bildern wurden Unkraut- und Kulturpflanzen (Winterweizen) und Boden als separate Kategorien annotiert und für den Test und die Validierung der Modelle verwendet. Die Ergebnisse zeigen, dass der BoVW-Ansatz eine Unterscheidung einzelner Unkrautpflanzen mit hoher Genauigkeit für *Matricaria recutita* L. (89 %), *Papaver rhoeas* L. (89 %), *Viola arvensis* M. (88 %) und Winterweizen (94 %) ermöglicht.

Auf diese Weise automatisch klassifizierte UAS-Bilder könnten eine standortspezifische Unkrautbekämpfung ermöglichen und würden eine teilschlagspezifische Herbizidwahl basierend auf der Verteilung der vorhergesagten Unkrautarten unterstützen.

Deskriptoren: Bilderkennung, Bildklassifikation, maschinelles Lernen, Präzisionslandwirtschaft, teilflächenspezifischer Pflanzenschutz, UAS, Unkrautarten, Unkrautverteilung

Abstract: *Recent developments in crop protection technology have provided the possibility to carry out herbicide measures on specific sub-areas in arable farming. Another prerequisite are exact weed distribution maps, which ideally not only distinguish between useful plants and weeds, but also show a species-specific spatial distribution. At present, this can only be achieved by manual field sampling, which is very labour- and cost-intensive. This is a great opportunity and at the same time a challenge for an automated recognition of different main weed species on the basis of aerial photographs generated by unmanned aircraft systems (UAS).*

The study presented here uses aerial photographs taken with an UAS driven at low altitude to provide sufficient ground resolution for object-based differentiation of individual weeds. Based on these images, an image classifier was tested that was able to differentiate individual weed species. Using a Bag-of-Visual-Words approach (BoVW), support vector machines were trained after creating a visual dictionary of local object characteristics from more than 20.000 individual weed images.

*A total of 108 aerial photographs at flight altitudes between 1 and 6 m were taken over a test field of the institute for validating the trained BoVW models. Within these UAS images, weed plants, wheat and soil were annotated as separate categories. The results show that the BoVW model allows the differentiation of individual plants with high accuracy for *Matricaria recutita* L. (89%), *Papaver rhoeas* L. (89%), *Viola arvensis* M. (88%) and Winter wheat (94%). For site-specific weed control, the automatically classified UAS images would allow the selection of the correct herbicide based on the distribution of predicted weed species.*

Keywords: *Machine learning, image classification, image recognition, precision farming, UAS, site-specific weed control, weed distribution, weed species*

1 Einleitung

Bei der Unkrautbekämpfung werden zur Optimierung und Reduzierung des Herbizideinsatzes, seit vielen Jahren Möglichkeiten einer teilschlagspezifischen Herbizidapplikation diskutiert (THOMPSON *et al.* 1991; SÖKEFELD *et al.* 2007; DAMMER & WARTENBERG 2007; SHANER & BECKIE 2014; SAN MARTÍN *et al.* 2016). Mit der zunehmenden Verfügbarkeit kostengünstiger und hochauflösender optischer Sensoren, luftgestützter Kameraplattformen und effizienter Bildverarbeitungsalgorithmen ist die Unkrauterkenntnis in den Fokus der Forschung gerückt. Ziel des technologiegestützten chemischen Pflanzenschutzes sollte es sein, den Einsatz von Herbiziden u.a. mittels Applikationskarten nur

auf jene Teilflächen eines Ackers zu beschränken, auf denen tatsächlich Unkräuter vorhanden sind, ohne dabei die Wirksamkeit der gesamten Pflanzenschutzanwendung zu beeinträchtigen. Die Optimierung der Aufwandmenge und die Auswahl von Herbiziden basiert dabei auf der eindeutigen Identifikation sowie auf einer exakten Lokalisierung verschiedener Unkrautarten (Dichte, räumliche Verteilung) auf einer Fläche. Da Unkräuter räumlich aggregiert sind (NORDMEYER 2006), konnte gezeigt werden, dass eine Teilflächenapplikation den Herbizideinsatz effektiv reduzieren kann, ohne den Ertrag negativ zu beeinflussen (CHRISTENSEN *et al.* 2003).

Als Voraussetzung für eine angepasste Applikation von Herbiziden werden im Wesentlichen drei Elemente benötigt: (i) Ein Detektionssystem zur Bestimmung der Art und Verteilung von Unkrautpflanzen, (ii) ein Entscheidungsalgorithmus zur HerbizidAuswahl und zur Berechnung der ortspezifischen Ausbringungsmenge sowie (iii) eine Feldspritze, die in der Lage ist, entsprechend der aktuell erfassten (online-Ansatz) oder kartierten (offline-Ansatz) Unkrautverteilung situationsbezogen zu applizieren (CHRISTENSEN *et al.* 2009; JENSEN 2015). Das hier vorgestellte Projekt beschreibt einen offline-Ansatz für die automatisierte Erkennung und Lokalisierung von Unkräutern auf landwirtschaftlichen Flächen.

Die optische Unkrauterkenntung wird seit Jahrzehnten erprobt und diskutiert. Neben zahlreichen Untersuchungen zur Unterscheidung von Pflanzen auf Basis ihrer spektralen Signatur hat sich vor allem gezeigt, dass es sinnvoll ist, phänotypische Informationen über Blattform, Textur und Größe in eine Klassifizierung einzubeziehen. So wurden in ersten Untersuchungen Formmerkmale wie Kontur und Konvexität aus der globalen Morphologie von Blättern extrahiert und für die Klassifizierung verwendet (FRANZ *et al.* 1991; WOEBBECKE *et al.* 1995). Später wurden Algorithmen eingesetzt, die lokale Merkmale in einem Bild detektieren und beschreiben (ZULKIFLI *et al.* 2011). Einige der Merkmalsdetektoren wie z.B. SIFT (*Scale-invariant feature transform*) sind gegenüber Koordinatentransformativen wie Skalierung und Rotation robust, und liefern auch bei variierenden Lichtverhältnissen, Bildrauschen und Deformationen des Objektes reproduzierbare Merkmalsinformationen. Da einzelne Pflanzenteile im Bild jedoch häufig überlappend projiziert dargestellt sind, führte das direkte Trainieren von generischen Klassifikatoren (z.B. Support-Vektor-Maschinen – SVM) auf den extrahierten Merkmalen bisher nur teilweise zu guten Ergebnissen und zu der Erkenntnis, dass komplexere Methoden zur Formbeschreibung herangezogen werden müssen (RUMPF *et al.* 2012).

Eine dieser Möglichkeiten besteht darin, lokale Bildmerkmale als „Wörter“ in einem Wörterbuch zusammenzufassen. Dieses so genannte Bag-of-visual-Words (BoVW) Framework verwendet Clusterverfahren, um eine große Anzahl ähnlicher optischer Merkmale zu gruppieren und eine Datenbank eindeutiger Basismerkmale (Wörterbuch) zu erstellen. Über direkte Bezüge zum Wörterbuch können dann visuelle Signaturen erstellt werden, die sich leicht in maschinelle Lernverfahren integrieren lassen. Hieraus wird schließlich ein Klassifikator für die Pflanzenarten abgeleitet.

Mit BoVW-Klassifikatoren und einem Detektor für *maximally stable extremal regions* (MSER) konnten Kazmi *et al.* (2015) sehr gut zwischen Acker-Kratzdisteln und Zuckerrüben unterscheiden. Eine Studie von Suh *et al.* (2018) nutzte BoVW, um Zuckerrüben von Kartoffelpflanzen zu unterscheiden. Dabei zeigte sich, dass ein SVM-Training bei Verwendung mit BoVW und einem kleinen Annotationsdatensatz (<1000 Bilder) eine bessere Klassifikationsleistung aufwies als Verfahren wie *Random Forest*. Für eine differenziertere Pflanzendetektion zeigen *Convolutional Neural Networks* (CNN) unter Verwendung umfangreicher Trainingsdatensätze vielversprechende Ergebnisse (Dyrmann *et al.* 2016; Krizhevsky *et al.* 2017). Die Bilder wurden sowohl unter kontrollierten Lichtverhältnissen als auch unter Feldbedingungen aufgenommen und zeigten mittlere bis hohe Klassifizierungsraten für 22 Unkrautarten.

Die objektbasierte Bildanalyse (OBIA) ist Bestandteil der meisten neueren Studien zur Erfassung der räumlichen Verteilung verschiedener Unkrautarten aus hochauflösenden UAS-Bildern. Peña *et al.* (2013) klassifizierten Unkräuter beispielsweise in einem Maisbestand aus 30 m Höhe Flughöhe unter Verwendung geometrischer Merkmale wie die relative Position einzelner Pflanzen innerhalb der Pflanzenreihenstruktur. Hung *et al.* (2014) identifizierten drei Unkrautarten aus UAS-Bildern, indem sie ein einfaches neuronales Netz mit einem eindimensionalen Autoencoder (*sparse autoencoder*) anlernten.

Für die Auswertung von UAS-Bildern und für die Unkrauterkenner wurden BoVW-Ansätze bisher noch nicht getestet. Wir gehen davon aus, dass die Verwendung von lokalen invarianten Bildmerkmalen wie SIFT von Vorteil sein könnte, da sie sowohl gegenüber einer Bildtranslation als auch gegen Rotation invariant und damit robust gegenüber Änderungen der Flughöhe, der Flugorientierung oder leichten Abweichungen aus der Nadir-Kameraperspektive sind.

2 Material und Methoden

UAS-Befliegung und photometrische Aufnahmen

Für die Segmentierung verschiedener Unkrautarten wurde ein BoVW Klassifizierer mit Luftbilddaufnahmen unter realen Feldbedingungen von Echter Kamille (*Matricaria recutita* L., MATCH), Klatsch-Mohn (*Papaver rhoeas* L., PAPRH), Acker-Stiefmütterchen (*Viola arvensis* M., VIOAR) sowie von Winterweizen (*Triticum aestivum* L. cv. ‚Julius‘, TRZAW) und von Boden trainiert. Hierfür wurde Winterweizen mit einem Reihenabstand von 12,5 cm und einer Dichte von 380 Samen·m⁻² auf Versuchsflächen des Julius Kühn-Instituts (Standort Sickte, 52°12'54.6"N 10°37'25.7"E) gedreht.

Die Befliegung wurde innerhalb eines Tages im März 2014 durchgeführt. Zu diesem Zeitpunkt waren alle Unkraut- und Kulturpflanzen aufgelaufen und der im November 2013 ausgesäte Winterweizen hatte das Entwicklungsstadium BBCH 23 erreicht (**Tabelle 1**). Vor den Messungen wurden keine Unkrautbekämpfungsmaßnahmen durchgeführt. Beflogen wurden die Versuchsflächen mit einem Multirotorsystem (Hexakopter, Hexa XL, HiSystems GmbH Moormerland, Deutschland) und modifizierter Flugsteue-

nung auf der Basis von Papparazzi (BRISSET *et al.* 2006; CiS GmbH, Rostock-Bentwisch, Deutschland). Die photometrischen Aufnahmen erfolgten an insgesamt 108 Wegpunkten in einer Flughöhe zwischen 1 und 6 m (**Abbildung 1**). Eingesetzt wurde eine modifizierte RGB Kompaktkamera (NEX 5N, Sony, Japan), die maximal 4912 x 3264 Bildpunkte auf einer Sensorfläche von 23,7 x 15,8 mm (APS-C Sensor) auflöst. Das verwendete Objektiv hatte eine Festbrennweite von 60 mm (Sigma 2.8 DN, Sigma Corp., Japan), wodurch eine mittlere Bodenauflösung zwischen 0,1 und 0,5 mm erreicht wurde.




Abbildung 1: Testfeld am JKI-Standort Sickinge mit einer Gesamtfläche von ca. 6,2 ha. Rot eingezeichnet sind die UAS-Flugrouten (FL), sowie die Positionen der Bildaufnahmen durch das UAS. Zuordnung von Bildern erfolgte in drei Teildatensätze: zwei Trainingsdatensätze und ein Testdatensatz. Der Hintergrund zeigt die Unkrautverteilungskarte für die Unkrautart MATCH, die zum Zeitpunkt der UAS-Befliegung manuell bonitiert wurde. Die angezeigten Koordinaten befinden sich in der UTM-Zone 32N, ETRS89 (EPSG-Code: 5972).

Um für die Validierung der Messdaten unabhängige Ausgangsbedingungen zu schaffen, wurde das Untersuchungsgebiet in zwei Trainings- und einen Testbereich unterteilt (**Abbildung 1**). Für die Modelloptimierung wurde der Trainingsdatensatz nochmals in einen Kalibrier- und einen Validierungsdatensatz zerlegt. Die Proben wurden dabei zufällig aus dem Trainingsdatensatz zu 75 % in die Kalibrierungsgruppe und zu 25 % in die Validierungsgruppe verteilt. Zur Kalibrierung wurden nur die Einzelbilder aus dem Trainingsbereich verwendet.

Bildannotation, Bildvorverarbeitung und Bildausschnitte

Die über dem Versuchsfeld aufgenommenen Luftbilder wurden zunächst manuell am PC bonitiert. Hierzu wurde eine selbst entwickelte graphische Oberfläche (HerbCount GUI Ver. 0.35) entwickelt. Durch Auswahl und Setzen von Markierungen wurden in den Luftbildern Einzelpflanzen artspezifisch identifiziert und verortet. Ein Ausschnitt der

Größe 200 x 200 Pixel wurde auf Basis der Position der Einzelpflanzen erzeugt. Alle Einzelbilder ergeben den Basisdatensatz für das Training des BoVW-Klassifizierers. Insgesamt wurden auf diese Weise 8483 Einzelbilder für MATCH 2309 für PAPRH 2808 für VIOAR 3202 für TRZAW und 6031 für die Kategorie Boden mit Hilfe der UAS-Befliegung innerhalb eines Tages aufgezeichnet. Jedes Einzelbild zeigte entweder eine bestimmte Pflanze oder einen Bodenausschnitt.

Um eine Abhängigkeit der Vorhersagegenauigkeit zum verwendeten Farbraum abzuschätzen, wurde der ursprüngliche RGB-Trainingsdatensatz zusätzlich nach HSV konvertiert. Für die Transformation wurde die in Matlab integrierte Funktion `rgb2hsv` genutzt, die den Algorithmus von (SMITH 1978) anwendet.

Tabelle 1: Übersicht der Kategorien von Unkrautarten und Kulturpflanzen, deren EPPO-Codes und das Pflanzenentwicklungsstadium zum Zeitpunkt der automatischen Bonitur mittels UAS und der manuellen Feldbonitur

Pflanzenart	EPPO-Code	BBCH
<i>Matricaria recutita</i> L. (Echte Kamille)	MATCH	16-18
<i>Papaver rhoeas</i> L. (Klatsch-Mohn)	PAPRH	17-19
<i>Viola arvensis</i> M. (Acker-Stiefmütterchen)	VIOAR	15
<i>Triticum aestivum</i> L. (Winterweizen)	TRZAW	23

Kalibrierung eines Bildklassifizierers zur Unkrauterkenntung

Die BoVW-Klassifikatoren wurden mit einem modifizierten Framework erstellt, das aus der Computer Vision Feature Library (VLFEAT, Version 0.9.21) für Matlab (VEDALDI & FULKERSON 2010) stammt. Als Standardalgorithmus für die *keypoint*-Erkennung und -beschreibung verwendet diese Toolbox einen Blob-Detektor basierend auf SIFT (LOWE 2004). Das visuelle Wörterbuch wurde mit Hilfe von K-means Clustering erstellt, wobei die Codewörter das mittlere euklidische Zentrum der *keypoint*-Deskriptoren darstellen. Danach wurden für jedes Bild Relationen zwischen extrahierten SIFT Keypoints und den Codewörtern erstellt und in einem Histogramm als Fingerprint des Bildes zusammengefasst. Mit den Histogrammvektoren wurden letztendlich die Bildklassifikatoren auf der Basis von Support Vektor Machines (SVM) kalibriert. Für die Validierung wurden annotierte Bildausschnitte aus dem Testdatensatz genutzt.

3 Ergebnisse

Bildklassifizierung

Die Klassifikationsergebnisse von sechs getesteten BoVW-Modellen mit unterschiedlichen Vokabulargrößen und Farbraumtransformationen der Trainingsbilder sind in **Tabelle 2** zusammengefasst. Im Allgemeinen gab es eine Abhängigkeit der Klassifizierungsgenauigkeit bei der Erhöhung des Wortschatzumfangs von 200 auf 500, während die Erhöhung der Genauigkeit von 500 auf 1000 Wortschatzumfang vernachlässigbar

war. Durch die Transformation der Trainingsbilder in den HSV-Farbraum wurden die Gesamtklassifizierungsgenauigkeiten verbessert.

Tabelle 2: Werte für Genauigkeit (Precision) und Trefferquote (Recall) für die Modellvalidierung mit einem unabhängigen Bildsatz (Einzelbilder des Testdatensatzes).

ID	Wörter	Farb-raum	Genauigkeit (Precision) in %				
			MATCH	PAPRH	VIOAR	TRZAW	Boden
415	200	rgb	66.35	45.85	34.60	94.99	79.38
416	200	hsv	63.14	61.74	49.59	97.21	97.44
577	500	rgb	69.99	50.07	34.42	96.15	82.60
578	500	hsv	65.87	64.98	51.31	97.98	98.31
739	1000	rgb	71.28	48.24	35.32	96.63	83.57
740	1000	hsv	65.44	67.51	50.68	98.65	98.52
			Trefferquote (Recall) in %				
			MATCH	PAPRH	VIOAR	TRZAW	Boden
415	200	rgb	87.43	42.78	41.18	79.45	71.87
416	200	hsv	88.15	57.92	58.03	80.66	85.34
577	500	rgb	88.65	49.24	48.78	78.27	71.51
578	500	hsv	90.28	61.68	60.62	80.71	83.63
739	1000	rgb	88.72	51.12	49.68	77.51	70.91
740	1000	hsv	91.18	60.76	62.75	79.75	83.01

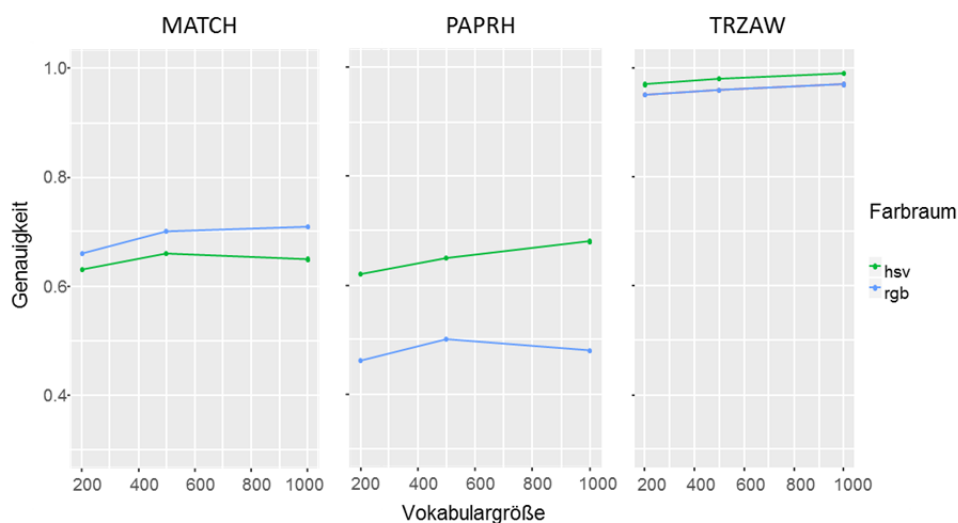


Abbildung 2: Zusammenhang zwischen Vorhersagegenauigkeit und der Wörterbuchgröße für das Trainieren des BoVW-Modells

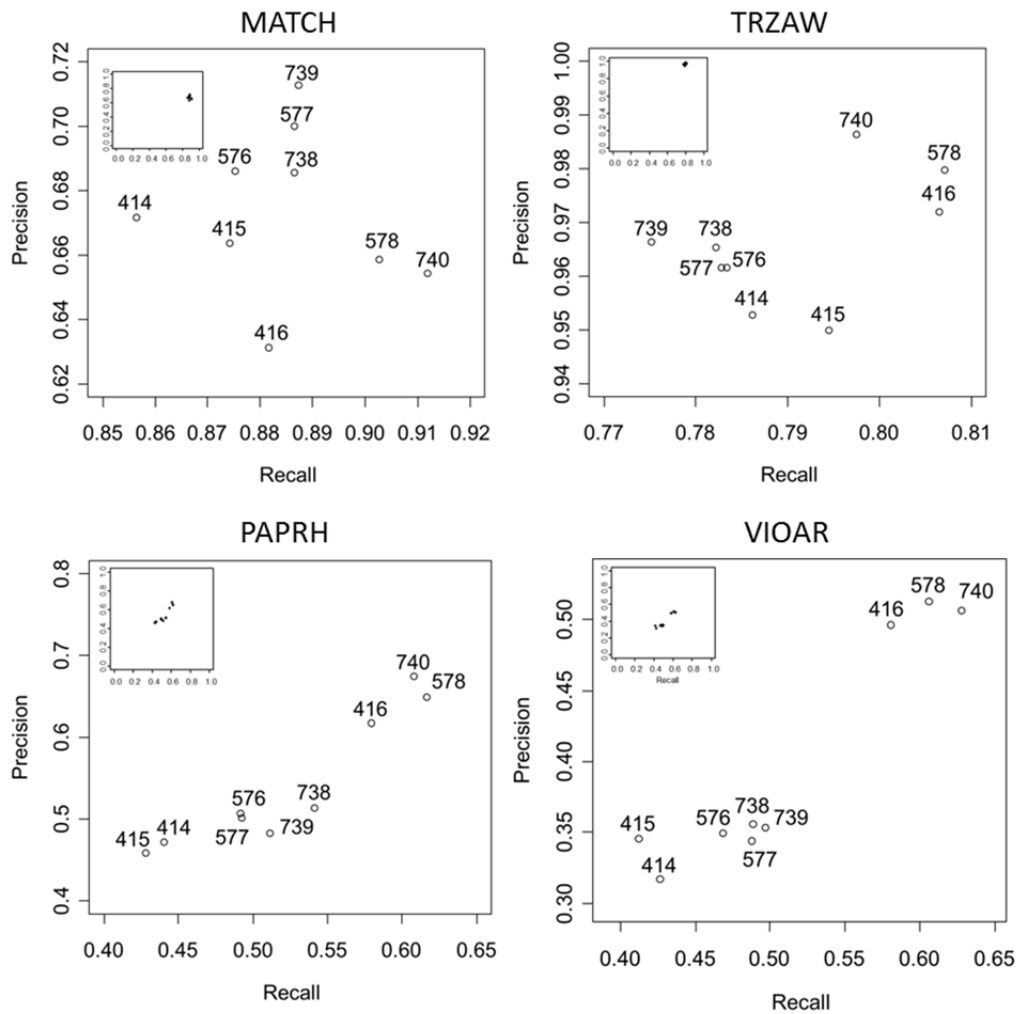


Abbildung 3: Graphische Beurteilung verschiedener BoVW-Klassifikatoren (Precision-recall-plots) für die Kategorien MATCH, TRZAW, PAPRH und VIOAR (oben rechts höhere Qualität der Vorhersage)

Insgesamt war die Genauigkeit bei der Erkennung von Boden- und Weizenbildern (> 95 %) gegenüber der Erkennung von Unkrautbildern (< 70 %) erhöht. Bis zu einem gewissen Grad bestand jedoch die Möglichkeit, dass Unkrautbilder fälschlicherweise als Boden oder Weizen eingestuft wurden. Unter den Unkrautarten wurde MATCH im Testdatensatz am genauesten identifiziert, während VIOAR die höchste Trefferquote aufwies. Die HSV-Transformation wirkte sich positiv auf die Präzision und die Trefferquote bei der Vorhersage von VIOAR sowie auf die Identifizierung des Bodenuntergrundes aus, während sie die Vorhersage von MATCH und PAPRH fast nicht beeinflusste.

Dass die getesteten Modelle die richtige Pflanzen- bzw. Bodenart in unmittelbarer Nähe eines Boniturpunktes recht gut vorhersagen, wird durch die in **Abbildung 4** dargestellten Vorhersagekarten für zwei der UAS gestützten Felddaufnahmen verdeutlicht. Auffallend ist, dass die Kategorie Boden die Pflanzen ähnlich einer Hintergrundmatrix hervorhebt, während die Weizenpflanzen aufgrund der Saatreihen regelmäßige, lange Streifen innerhalb der Karte bilden. Die verschiedenen Unkrautarten sind erwartungsgemäß räumlich heterogen zwischen den Weizenreihen verteilt. Rote Markierung

gen innerhalb der Karten geben die Position der manuellen Feldboniturpunkte und ihrer Kategorie an und in fast allen Fällen stimmen sie mit der errechneten Kategorie überein und beweisen somit die hohe Validität der Karte.

4 Diskussion

Der Ansatz der Unkrauterkenkung mittel BoVW-Klassifizierung war in der Lage, Unkräuter von Nutzpflanzen in UAS Bildern von verunkrauteten Ackerschlägen mit hoher Genauigkeit (>90 %) zu unterscheiden. Im Vergleich dazu konnten PEÑA *et al.* (2013) Unkräuter in Maiskulturen aus UAS-Bildern unter Verwendung eines OBIA-Ansatzes mit 86 % Gesamtgenauigkeit in drei Kategorien unterscheiden. HUANG *et al.* (2018) konnten Reis von nicht spezifiziertem Unkraut mit einer Genauigkeit von 97 % unterscheiden, indem sie ein *patch*-basiertes CNN verwendeten.

Ebenfalls hohe Klassifizierungsgenauigkeiten von 92 %, 90 %, 69 % bzw. 33 % für TRZAW, MATCH, PAPRH und VIOAR zeigt die Arbeit von DYRMANN *et al.* (2016). Im Vergleich dazu erzielt der vorliegende Ansatz Werte von 98 %, 66 %, 65 %, 65 % und 51 % für die gleichen Pflanzenarten. Die Ergebnisse können jedoch nicht direkt miteinander verglichen werden, da DYRMANN *et al.* (2016) bis zu 21 Pflanzenarten getestet und Bilder aus konstanter Höhe aufgenommen haben, während in dieser Studie nur 4 Pflanzenarten getestet wurden, aber Bilder von einer instabilen UAS-Plattform mit einem Höhenbereich zwischen 1,0 und 6,0 m aufgenommen wurden.

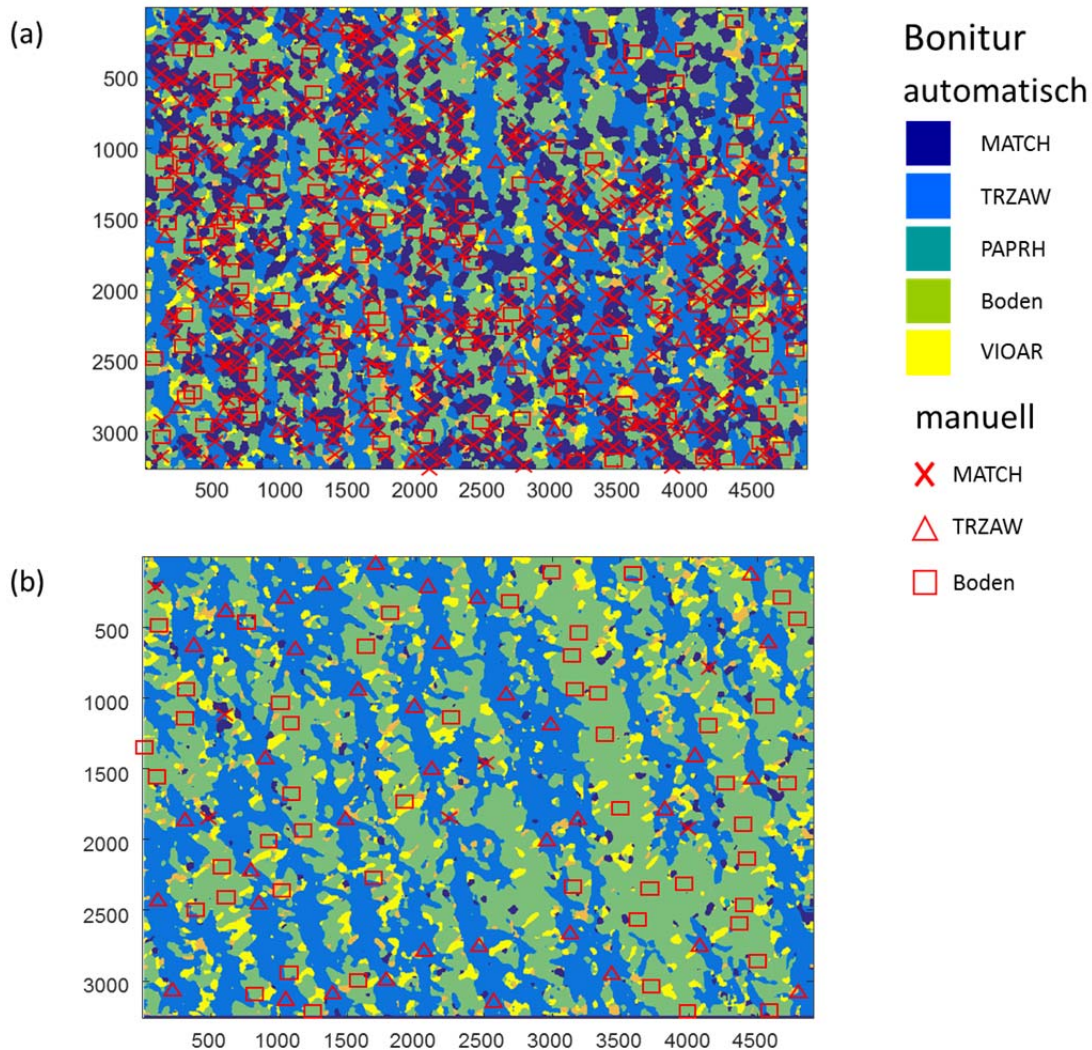


Abbildung 4: Unkrautklassifizierungsergebnisse des Modells 578 für die UAS-Bilder an den Feldposition 58 mit (a) hohem und (b) geringem Aufkommen an MATCH (Position 51, vgl. Abbildung 1). Die Abtastung über das Bild erfolgte mittels sliding window bei einer Schrittweite von 5 px und einer Blockgröße von 50 px. Die Kategorienkarte zeichnet die räumliche Verteilung von Unkraut, Winterweizen und Boden. Positionen der manuellen Feldbonitur für MATCH (x), TRZAW (Δ) und Boden (□) veranschaulichen die Genauigkeiten.

5 Fazit

Insgesamt zeichnete sich ab, dass die Bodenauflösung und die Flughöhe einen starken Einfluss haben auf die Abbildungsleistung und somit für den hier präsentierten Ansatz der Unkrautkartierung hochauflösende Bilder erforderlich sind, die auch Details der Kultur- und Unkrautpflanzen abbilden können. Je besser die Auflösung, desto höher die Kartenqualität. Für eine teilflächenspezifische Unkrautbekämpfung würde der hier vorgestellte Ansatz die Auswahl der Herbizide auf der Grundlage der Verteilung der Unkrautarten in den klassifizierten Felddaten und so eine situationsgerechte Applikation ermöglichen. Weitere Forschungsarbeiten werden darauf abzielen, die Modelle zu verbessern, indem die Annotationsdatenbank mit mehr Bilddaten aus verschiedenen Kulturen erweitert wird.

Danksagung

Wir danken den Mitarbeitern des Instituts für Pflanzenschutz in Ackerbau und Grünland des Julius Kühn-Instituts in Braunschweig für ihre tatkräftige Unterstützung bei den teilweise recht aufwendigen Versuchsdurchführungen. Besonderer Dank gilt hierbei Herrn Feistkorn und Herrn Littmann für die Befliegungen sowie Frau Behme und Herrn Lühr für die akribische manuelle Unkrautbonitur am PC.

Literaturverzeichnis

- BRISSET P., DROUIN A., GORRAZ M., HUARD P.-S. & TYLER J. (2006):** The paparazzi solution. – In: MAV 2006, 2nd US-European Competition and Workshop on Micro Air Vehicles.
- CHRISTENSEN S., HEISEL T., WALTER A.M. & GRAGLIA E. (2003):** A decision algorithm for patch spraying. – *Weed Research*, 43 (4): 276–284.
- CHRISTENSEN S., SOGAARD H.T., KUDSK P., NORREMARK M., LUND I., NADIMI E.S. & JORGENSEN R. (2009):** Site-specific weed control technologies. – *Weed Research*, 49 (3): 233–241 <https://doi.org/10.1111/j.1365-3180.2009.00696.x>.
- DAMMER K.H. & WARTENBERG G. (2007):** Sensor-based weed detection and application of variable herbicide rates in real time. – *Crop Protection*, 26 (3): 270–277 <https://doi.org/10.1016/j.cropro.2005.08.018>.
- DYRMANN M., KARSTOFT H. & MIDTIBY H.S. (2016):** Plant species classification using deep convolutional neural network. – *Biosystems Engineering*, 151: 72–80 <https://doi.org/10.1016/j.biosystemseng.2016.08.024>.
- FRANZ E., GEBHARDT M. & UNKLESBAY K.B. (1991):** Shape description of completely visible and partially occluded leaves for identifying plants in digital image. – *Transactions of the ASABE*, 34 (2): 673–681.
- HUANG H., DENG J., LAN Y., YANG A., DENG X. & ZHANG L. (2018):** A fully convolutional network for weed mapping of unmanned aerial vehicle (UAV) imagery. – *PLOS ONE*, 13 (4): e0196302 <https://doi.org/10.1371/journal.pone.0196302>.
- HUNG C., XU Z. & SUKKARIEH S. (2014):** Feature Learning Based Approach for Weed Classification Using High Resolution Aerial Images from a Digital Camera Mounted on a UAV. – *Remote Sensing*, 6 (12): 12037–12054 <https://doi.org/10.3390/rs61212037>.
- JENSEN P.K. (2015):** Target precision and biological efficacy of two nozzles used for precision weed control. – *Precision Agriculture*, 16 (6): 705–717 <https://doi.org/10.1007/s11119-015-9399-4>.
- KAZMI W., GARCIA-RUIZ F.J., NIELSEN J., RASMUSSEN J. & JØRGEN ANDERSEN H. (2015):** Detecting creeping thistle in sugar beet fields using vegetation indices. – *Computers and Electronics in Agriculture*, 112: 10–19 <https://doi.org/10.1016/j.compag.2015.01.008>.
- KRIZHEVSKY A., SUTSKEVER I. & HINTON G.E. (2017):** ImageNet classification with deep convolutional neural networks. – *Communications of the ACM*, 60 (6): 84–90 <https://doi.org/10.1145/3065386>.

- LOWE D.G. (2004):** Distinctive Image Features from Scale-Invariant Keypoints. – International Journal of Computer Vision, 60 (2): 91–110
<https://doi.org/10.1023/B:VISI.0000029664.99615.94>.
- NORDMEYER H. (2006):** Patchy weed distribution and site-specific weed control in winter cereals. – Precision Agriculture, 7 (3): 219–231 <https://doi.org/10.1007/s11119-006-9015-8>.
- PEÑA J.M., TORRES-SÁNCHEZ J., DE CASTRO A.I., KELLY M. & LÓPEZ-GRANADOS F. (2013):** Weed Mapping in Early-Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. – PLoS ONE, 8 (10): e77151
<https://doi.org/10.1371/journal.pone.0077151>.
- RUMPF T., RÖMER C., WEIS M., SÖKEFELD M., GERHARDS R. & PLÜMER L. (2012):** Sequential support vector machine classification for small-grain weed species discrimination with special regard to *Cirsium arvense* and *Galium aparine*. – Computers and Electronics in Agriculture, 80: 89–96 <https://doi.org/10.1016/j.compag.2011.10.018>.
- SAN MARTÍN C., ANDÚJAR D., BARROSO J., FERNÁNDEZ-QUINTANILLA C. & DORADO J. (2016):** Weed Decision Threshold as a Key Factor for Herbicide Reductions in Site-Specific Weed Management. – Weed Technology, 30 (4): 888–897 <https://doi.org/10.1614/WT-D-16-00039.1>.
- SHANER D.L. & BECKIE H.J. (2014):** The future for weed control and technology. – Pest Management Science, 70 (9): 1329–1339 <https://doi.org/10.1002/ps.3706>.
- SMITH A.R. (1978):** Color gamut transform pairs. – ACM Siggraph Computer Graphics, 12 (3): 12–19.
- SÖKEFELD M., GERHARDS R., OEBEL H., THERBURG R. & STAFFORD J. (2007):** Image acquisition for weed detection and identification by digital image analysis. – In: – pp. 523–528 *Precision agriculture'07. Papers presented at the 6th European Conference on Precision Agriculture, Skiathos, Greece, 3-6 June, 2007*. Greece (Wageningen Academic Publishers).
- SUH H.K., HOFSTEE J.W., IJSSELMUIDEN J. & VAN HENTEN E.J. (2018):** Sugar beet and volunteer potato classification using Bag-of-Visual-Words model, Scale-Invariant Feature Transform, or Speeded Up Robust Feature descriptors and crop row information. – Biosystems Engineering, 166: 210–226 <https://doi.org/10.1016/j.biosystemseng.2017.11.015>.
- THOMPSON J.F., STAFFORD J.V. & MILLER P.C.H. (1991):** Potential for automatic weed detection and selective herbicide application. – Crop Protection, 10 (4): 254–259.
- VEDALDI A. & FULKERSON B. (2010):** VLFeat: An open and portable library of computer vision algorithms. – In: Proceedings of the 18th ACM international conference on Multimedia. – pp. 1469–1472 (ACM).
- WOEBBECKE D.M., MEYER, G.E., VON BARGEN, K. & MORTENSEN, D.A. (1995):** Shape Features for Identifying Young Weeds Using Image Analysis. – Transactions of the ASAE, 38 (1): 271–281 <https://doi.org/10.13031/2013.27839>.
- ZULKIFLI Z., SAAD P. & MOHTAR I.A. (2011):** Plant leaf identification using moment invariants & General Regression Neural Network. – In: – pp. 430–435 (IEEE)
<https://doi.org/10.1109/HIS.2011.6122144>.

Low-cost Drohnen Einsatz zur Erkennung von Wurzelunkräutern On-farm

Perennial weed detection on-farm by low-cost UAV use

Maike Krauss¹, Christoph Hofstetter^{1,2}, Hansueli Dierauer¹, Frank Liebisch²

¹Departement Bodenwissenschaften, Forschungsinstitut für biologischen Landbau (FiBL), Ackerstrasse 113, 5070 Frick, Schweiz

²Institut für Agrarwissenschaften, ETH Zürich. Universitätsstraße 2, 8092 Zürich, Schweiz
E-Mail: maike.krauss@fibl.org

Zusammenfassung: Wurzelunkräuter breiten sich in Nestern aus und sind daher am Boden für eine Erfolgskontrolle von Regulierungsmaßnahmen schlecht zu erfassen. In einem Bodenbearbeitungsversuch wurde an Hand von Winden (*Convolvulus* spp.) Zeitpunkte im Dinkelbestand gesucht, die für eine erfolgreiche Segmentierung mit RGB Drohnenaufnahmen aus 25 m Flughöhe und einfacher Bilddiagnostik geeignet sind. Der Deckungsgrad der Gesamtbiomasse konnte mit dem Anteil grüner Pixel in frühen Stadien gut mit den visuell kartierten Aufnahmen korreliert werden. Die Winden konnten nur zur Abreife des Dinkels (BBCH 89) aus der Luft erfasst werden. Die Segmentierung wurde jedoch von Luzernedurchwuchs erschwert. Winden und Luzerne wurden durch Pflügen besser unterdrückt als durch nichtwendende Bodenbearbeitungsverfahren. Die Erweiterung mit zusätzlichen Spektralinformationen und Verbesserung der Auswertung versprechen einen kostengünstigen Einsatz von Drohnen zu Beratungszwecken.

Deskriptoren: Wurzelunkraut, *Convolvulus*, Winde, Dinkel, Drohne, RGB Kamera, Segmentierung, mechanische Unkrautregulierung, Biolandbau

Abstract: *Perennial weeds grow in patches and success of weed control is difficult to assess on the ground. Different growth stages of spelt were tested for best segmentation of bindweed (*Convolvulus* spp.) in a tillage trial. RGB images from drone flights in 25 m altitude were correlated to visual field assessments. Taking green pixels, plant canopy cover could be distinguished from soil in early stages. Weed segmentation was difficult. Bindweed was only detectable during spelt senescence in BBCH 89 which was complicated by volunteer alfalfa. Bindweed and alfalfa infestation was lower in ploughed plots than with non-inversion tillage. Adding more spectral information and improving algorithms may allow for low cost perennial weed detection in cereals for advisory services.*

Keywords: *perennial weeds, bindweed, spelt, drone, RGB camera, segmentation*

1 Einleitung

Die ausdauernden Rhizome von Wurzelunkräutern bilden jährlich neue Triebe und können sich von ihren stationären „Nestern“ im Laufe der Zeit ausbreiten und überhandnehmen. Sie stellen daher nicht nur im Biolandbau ein langfristiges Problem dar, wo deren Bekämpfung mit mechanischen Geräten nur teilweise erfolgreich ist und in der Regel zusätzlich kostenintensive Handarbeit erfordert. Sie behindern darüber hinaus die Umsetzung bodenschonender Praktiken wie die konservierende Bodenbearbeitung, bei der ein Ausbreiten von Wurzelunkräutern festgestellt wurde (ARMENGOT *et al.* 2015). Es werden daher Maßnahmen gesucht, die bodenschonender arbeiten als der Pflug und Wurzelunkräuter besser regulieren. Im Fall von Winden könnte eine tiefergehende Lockerung das Unkraut potenziell zurückdrängen, da sie dichtgelagerte Böden bevorzugen. Genaue visuelle Aufnahmen der Unkrautdeckung von Wurzelunkräutern im Feld sind durch die heterogene Verteilung in Nestern schwierig durchzuführen. Auch braucht es eine Art georeferenzierte Aufnahme, um die mittel-bis langfristige Ausbreitung oder Eindämmung registrieren zu können. Die Diagnostik ist daher nicht nur eine Herausforderung in der Forschung, sondern vor allem im praktischen Kontext, z.B. für On-farm Versuche oder in der Beratung. Fernerkundungsgestützte Aufnahmen mit Drohnen und die anschließende Auswertung der Bilddaten versprechen hier eine arbeits- und kostengünstigere Alternative.

Projektziel war es daher, mit hoher Präzision in einem Exaktversuch Bilddaten von Drohnenflügen mit visuell erhobenen Referenzdaten im Feld zu kalibrieren. Dabei wurden vier verschiedene Bodenbearbeitungsverfahren auf ihre Effektivität hinsichtlich der Unkrautregulierung (v.a. der Winden) untersucht und geschaut, ob drohnengestützte Bilddaten dies abbilden können.

2 Material und Methoden

Versuchsaufbau und Bewirtschaftung

Der einjährige Versuch in einer Dinkelkultur (Sorte 'Titan') wurde auf einem Feld des FiBL-Hofes in Frick im Herbst 2017 angelegt und im Sommer 2018 geerntet. Das stark mit Beikräutern und Winden belastete Feld wurde mehr als fünf Jahre mit nichtwendenden Maschinen flach, also reduziert bearbeitet (**Tabelle 1**). Ein Pflug wurde nur zum Wiesenumbruch eingesetzt. Es wurden 6 x 40 m große Parzellen mit vier Bodenbearbeitungsverfahren und drei Feldwiederholungen angelegt (Abbildung 1). Die Verfahren umfassen:

- INVs Flach wendend mit Pflug, 18 cm (shallow inversion)
- INVd Tief wendend mit Pflug, 28 cm (deep inversion)
- NONs Flach nichtwendend mit Grubber „Weco-Dyn“, 10 cm (shallow non-inversion)
- NONd Tief nichtwendend mit Grubber „Weco-Dyn“ 10 cm und Frontgrubber „Löwenzahn“ 30 cm (deep non-inversion)




Abbildung 1: Versuchsanordnung. INVs – Pflug 18 cm, INVd – Pflug 28 cm, NONs – Grubber 10 cm, NONd – Grubber 10 cm/30 cm

Tabelle 1: Bewirtschaftungsmaßnahmen

Datum	Bewirtschaftungsmaßnahme
September 2017	Dreimalige nichtwendende Stoppelbearbeitung des gesamten Feldes mit Lemken Grubber und Grubber „WecoDyn“ auf maximal 10 cm als Unkrautkur. Dies ist die einzige Bearbeitung in NONs (10 cm).
13.10.2017	Pflügen in INVs (18 cm) und INVd (28 cm)
18.10.2017	Nichtwendende Bearbeitung mit Grubber „WecoDyn“ (10 cm) und Tiefenlockerung mit Grubber „Löwenzahn“ (30 cm) in NONd in einem Durchgang
19.10.2017	Dinkelsaat mit Kreiselegge-Säkombination, Sorte „Titan“, 1.9 kg/A
22.11.2017	Gülleapplikation ca. 25 m ³ /ha
14.04.2018	Striegeln
12.07.2018	Dinkelernte

Untersuchungen

Innerhalb der Hauptparzellen wurden zur visuellen und drohnengestützten Datenerhebung Subparzellen mit einer Größe von 1 x 1 m angelegt: drei Subparzellen mit normaler Kulturentwicklung und eine Subparzelle, die von Hand gejätet wurde. Zur exakten Positionierung der Drohnenbilder wurden im Feld Kontrollpunkte installiert, deren Koordinaten mit einem GPS Gerät aufgenommen wurden. Graustandards wurden bei jedem Flug zur Qualitätskontrolle eingesetzt.

An acht Boniturterminen während der Hauptwachstumszeit des Dinkels wurde mit einer Drohne (DJI Phantom 4 Pro, RGB Kamera mit 4864 x 3648 Pixel Auflösung) in 25 m Höhe geflogen und anschließend die Dinkel- und Unkrautdeckung in den Subplots erhoben. Vor der Ernte (BBCH 89) wurde der Deckungsgrad der gut sichtbaren Winden in einem kleinräumigen Raster auf den gesamten Hauptparzellen zusätzlich visuell mittels Skalen ermittelt. Die Bilddaten der einzelnen Drohnenflüge wurden mit der Software AgiSoft PhotoScan Professional zu einem Orthofoto (siehe Anhang) zusammengesetzt und die Pixel mit der Software R verrechnet. Neben dem Triangular Greenness Index (TGI)

$$[TGI = -0.5[(\lambda r - \lambda b)(R_r - R_g) - (\lambda r - \lambda g)(R_r - R_b)];$$

R = Reflektanz, λ = Wellenlänge, r = rot, g = grün, b = blau

wurden die grünen Pixel als Schwellwert ($G > R$ & $G > B$) für die Segmentierung der Unkräuter genommen (**Abbildung 2**).




Abbildung 2: Beispiel der Segmentierung von Pflanzen und Boden in einem Subplot a) Originalbild, b) Schwellwert gesetzt durch den TGI und c) durch grüne Pixel





Abbildung 2: Mittelwerte (Standardfehler als Fehlerbalken) des Unkrautdeckungsgrades von Dikotyledonen (oben), Monokotyledonen (mittig) und der Gesamtdeckung, visuell geschätzt zu den BBCH Stadien 29, 33, 37, 49 und 69. Unterschiedliche Buchstaben zeigen signifikante Unterschiede (negativ binominales Modell, F-Test, $p < 0.05$). INVd – Pflug 28 cm, INV – Pflug 18 cm, NONd – Grubber 10 cm/30 cm, NONs – Grubber 10 cm

3 Ergebnisse

Zu Beginn der Saison war die Unkrautdeckung in den gepflügten Verfahren (INV) zunächst höher, sowohl bei den Gräsern (Monokotyle) als auch bei den breitblättrigen Beikräutern (Dikotyle) (**Abbildung 3**). Ab dem Ährenschieben jedoch war der Unkrautbesatz mit 10–15 % etwa gleich hoch zwischen den Verfahren. Die Ursache war die Zunahme der Winden (*Convolvulus* spp.), deren Besatz im nicht-wendenden Verfahren zum Ende der Saison hin stärker anstieg (Abbildung oben). Die Unterschiede konnten nur durch die visuellen Bonituren am Boden ermittelt werden. Aus den RGB Bildern der Drohnenbefliegungen konnte lediglich die Gesamtdeckung der Pflanzendecke abgeschätzt werden solange die Bodenoberfläche sichtbar war. Die Korrelation zwischen der am Boden ermittelten Gesamtdeckung der Pflanzen und dem Anteil an grünen Pixeln ($G > R$ & $G > B$) in den Subparzellen (**Abbildung 4a**) war besser als die Korrelation mit dem TGI (**Abbildung 4b**). Beide Parameter korrelierten gut bei BBCH 29. An Hand grüner Pixel konnte zudem der Gesamtdeckungsgrad bei BBCH 33 korreliert werden. Die Deckung der Beikräuter konnte durch den Abzug der Anzahl grüner Pixel aus den gejäteten Subparzellen von den verunkrauteten Subparzellen nicht zufriedenstellend berechnet werden (Daten nicht gezeigt).

a)



b)




Abbildung 4: Korrelation zwischen dem Bedeckungsgrad der Pflanzen (%; visuelle Bonitur am Boden) mit dem a) Anteil grüner Pixel und b) Anteil Pixel über dem TGI Schwellenwert in den Subparzellen (Drohnenbonitur).

Da Winden erst spät in der Saison auftreten und in Nestern vorkommen, wurde ihr Vorkommen nicht nur in den *Subplots*, sondern bei der Abreife des Dinkels zusätzlich über die ganze Parzelle hinweg untersucht (**Abbildung 5**).

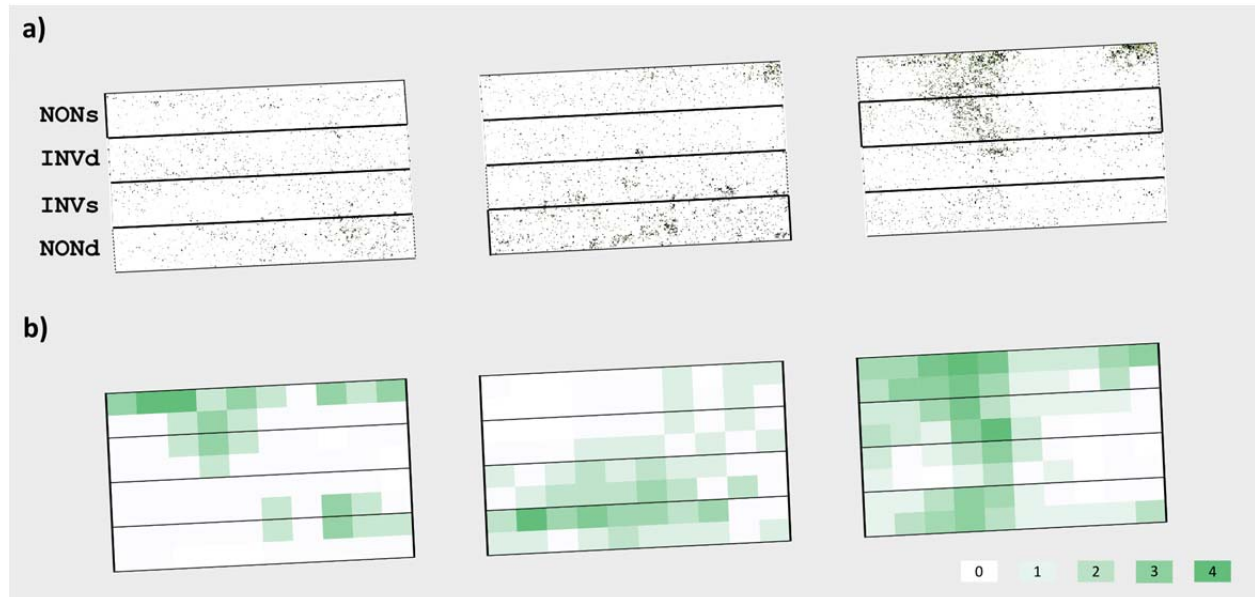


Abbildung 5: Räumliche Verteilung der Beikräuter über die Versuchsparzellen bei der Abreife des Dinkels (BBCH 89): a) Beikräuter als grüne Pixel ermittelt durch Drohnenaufnahmen, b) visuelle Abschätzung des Windenvorkommens im Feld nach einer Skala (0 – kein Vorkommen, 4 – starkes Auftreten)

Hier konnte der Unterschied zwischen dem Pflug (INV) und den nicht-wendenden Verfahren (NON) sowohl im Feld als auch aus der Luft bestätigt werden, obwohl dies auf Grund der hohen Streuung nicht signifikant war (**Tabelle 2**).

Tabelle 2: Mittelwert (Standardabweichung) des Windenbesatzes an Hand einer visuellen Abschätzung in Skalen (0 – kein Vorkommen bis 4 – starkes Auftreten) und des Anteils grüner Pixel am Gesamtbild extrahiert aus Drohnenaufnahmen zum Zeitpunkt der Abreife des Dinkels (BBCH 89). INV_s – Pflug 18 cm, INV_d – Pflug 28 cm, NON_s – Grubber 10 cm, NON_d – Grubber 10 cm/30 cm

Verfahren	Visuelle Abschätzung (Skala 0-4)	Anteil grüner Pixel (%)
INV _s	0.94 (0.49)	4.17 (0.74)
INV _d	0.80 (0.25)	4.76 (0.97)
NON _s	1.32 (0.28)	7.38 (3.60)
NON _d	1.32 (0.83)	8.91 (4.95)
Kruskal-Wallis Test [n=3, Chi Square (p-value)]		
Bodenbearbeitungstyp	2.08 (p = 0.150)	3.10 (p = 0.078)
Bearbeitungstiefe	0.23 (p = 0.631)	0.92 (p = 0.337)

4 Diskussion

Mit der einfachen Diagnostik der Drohnenbilder war die Segmentierung von Boden zur Gesamtdeckung der Pflanzen schon in frühen Entwicklungsstadien des Dinkels möglich. Dies kann noch weiter verfeinert werden durch andere spektrale Indizes und die Berücksichtigung der Saatreihen (JIN *et al.* 2017; TORRES-SÁNCHEZ *et al.* 2014). Die Identifikation von Unkräutern war in den frühen Wachstumsstadien bis zur Abreife des Dinkels mit der bisherigen Diagnostik jedoch nicht machbar. Der Einsatz gejäteter Subparzellen erwies sich als wenig hilfreich. Die Subplots waren mit 1 x 1 m möglicherweise zu klein. Auch ergaben sich Schwierigkeiten beim Jäten, da Gräser am Anfang schlecht vom Dinkel zu unterscheiden waren. Die Abschätzung von Beikräutern aus der Luft gelang daher nur bei der Abreife des Dinkels, da die Farbunterschiede (Dinkel = gelb; Beikräuter = grün) zu dem Zeitpunkt eindeutig waren. Hier ergab sich hinsichtlich der Windenbonitur aus der Luft jedoch die Schwierigkeit durch Luzernedurchwuchs, der bei der Segmentierung nicht von den Winden zu trennen war. Der Trend zwischen den Versuchsverfahren wurde trotzdem richtig abgebildet. Dies lag an der gleichzeitigen Unterdrückung von Winde und Luzerne durch die Pflugverfahren. Dies bestätigt die Beobachtung, dass die wendende Bodenbearbeitung Wurzelunkräuter besser regulieren kann (ARMENGOT *et al.* 2015; GRUBER & CLAUPEIN 2009). Um Wurzelunkräuter spezifisch erkennen zu können, müssen geeignete spektrale Indizes gefunden und Algorithmen zur Erkennung formuliert werden. Hierzu gibt es schon erste Ansätze (GAO *et al.* 2018; GARCIA-RUIZ *et al.* 2015; MINK *et al.* 2018; ZISI *et al.* 2018), wobei der Fokus meist bei Disteln (*Cirsium* spp.) und kaum bei Winden lag. Auch wurde die Segmentierung in Reihenkulturen wie Mais oder Zuckerrüben vorgenommen. Hier zeigen Getreidekulturen zum Zeitpunkt der Abreife Potential für eine erfolgreiche Segmentierung. Der späte und punktuelle Zeitpunkt ermöglicht aber nur ein Monitoring zur Erfolgskontrolle spezifischer Maßnahmen, weniger die Möglichkeit zur direkten Unkrautregulierung.

Danksagung

Wir danken dem Coop Fonds für Nachhaltigkeit und der Stiftung Sur la Croix für die finanzielle Unterstützung des Projektes.

Literaturverzeichnis

ARMENGOT L., BERNER A., BLANCO-MORENO J., MÄDER P., SANS F.X. (2015): Long-term feasibility of reduced tillage in organic farming. *Agron. Sustain. Dev.* 35, 339–346.

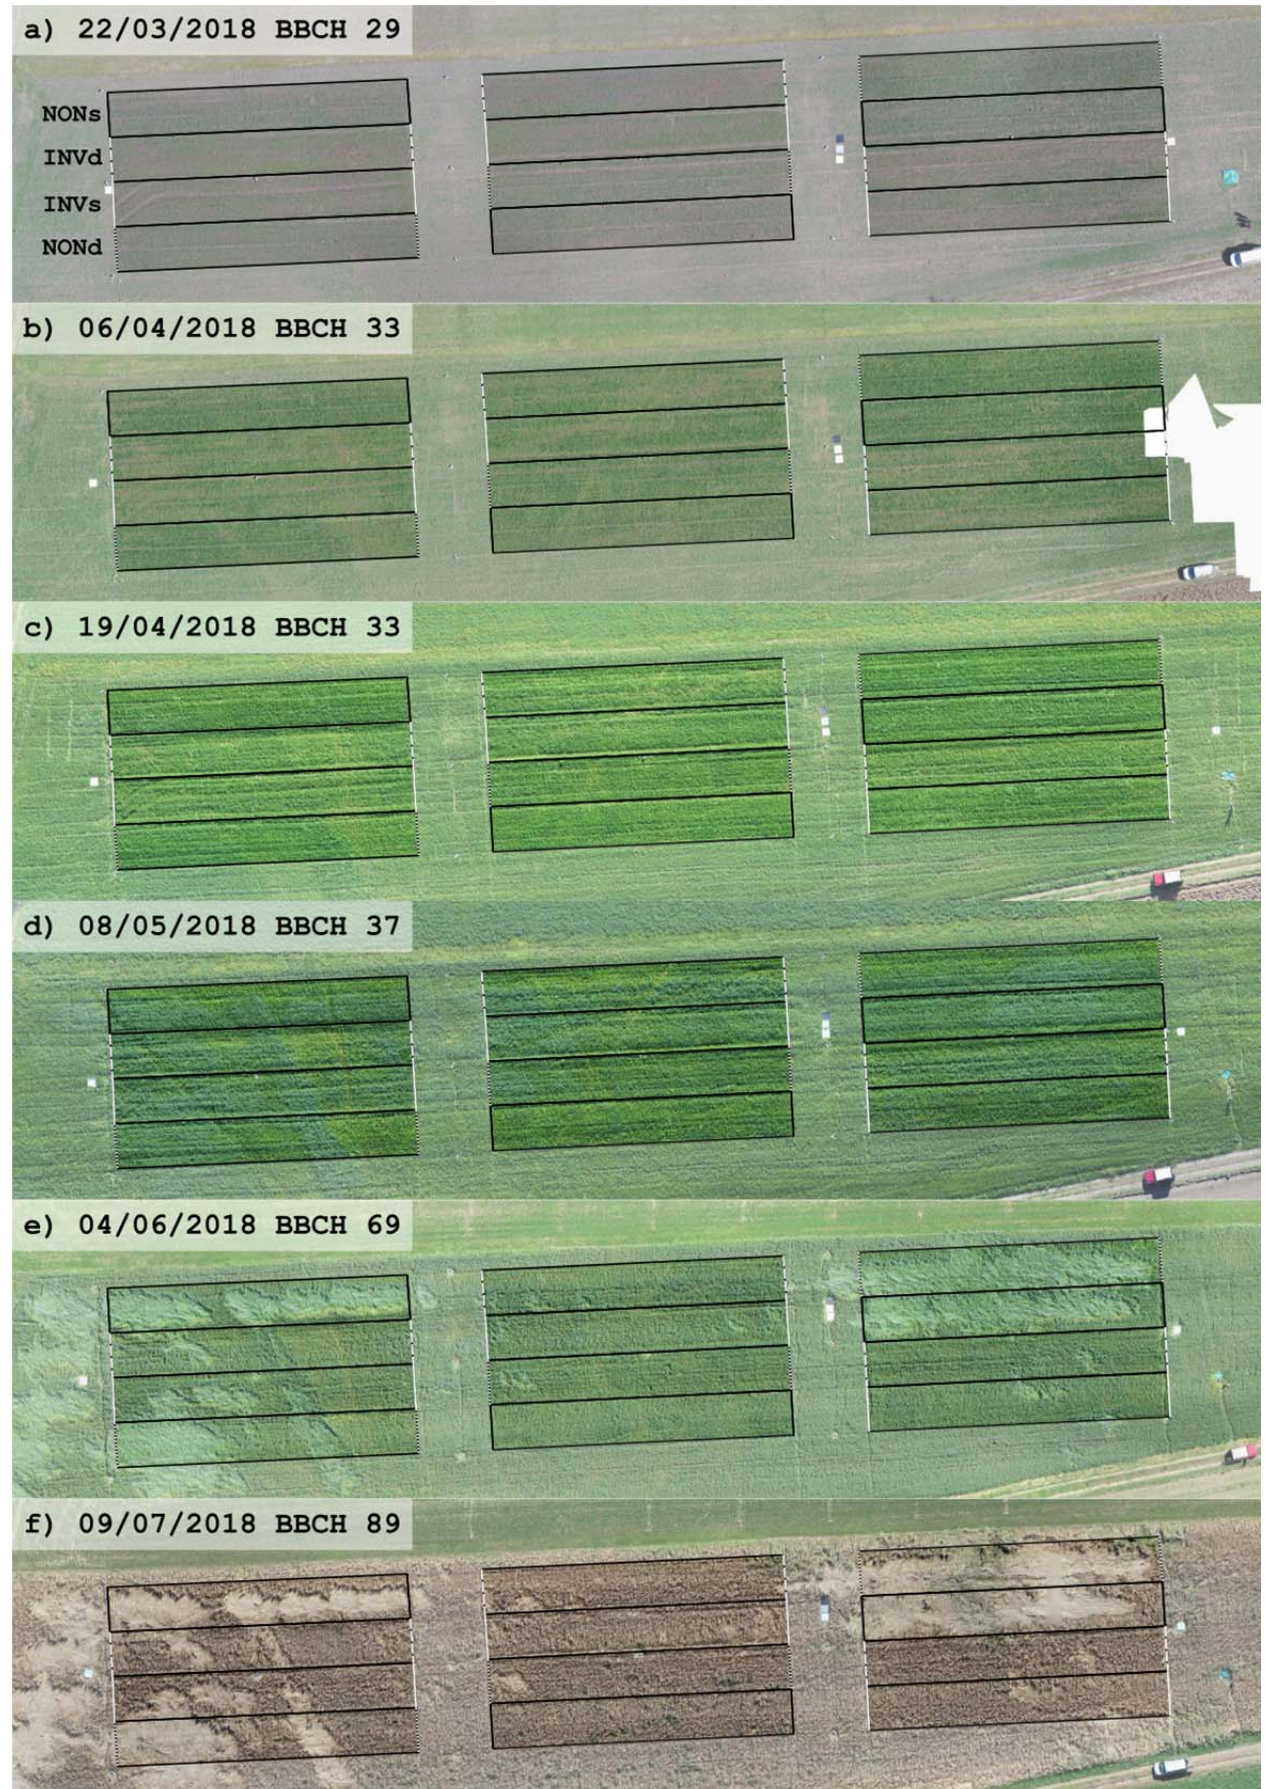
doi: 10.1007/s13593-014-0249-y.

GAO J.F., NUYTENS D., LOOTENS P., HE Y., PIETERS J.G. (2018): Recognising weeds in a maize crop using a random forest machine-learning algorithm and near-infrared snapshot mosaic hyperspectral imagery. *Biosystems Engineering* 170, 39–50.

doi: 10.1016/j.biosystemseng.2018.03.006.

- GARCIA-RUIZ F.J., WULFSOHN D., RASMUSSEN J. (2015):** Sugar beet (*Beta vulgaris* L.) and thistle (*Cirsium arvensis* L.) discrimination based on field spectral data. *Biosystems Engineering* 139, 1–15. doi: [10.1016/j.biosystemseng.2015.07.012](https://doi.org/10.1016/j.biosystemseng.2015.07.012).
- GRUBER S., CLAUPEIN W. (2009):** Effect of tillage intensity on weed infestation in organic farming. *Soil & Tillage Research* 105, 104–111. doi: <http://dx.doi.org/10.1016/j.still.2009.06.001>.
- JIN X., LIU S., BARET F., HEMERLÉ M., COMAR A. (2017):** Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery. *Remote Sensing of Environment* 198, 105–114. doi: <https://doi.org/10.1016/j.rse.2017.06.007>.
- MINK R., DUTTA A., PETEINATOS G.G., SOKEFELD M., ENGELS J.J., HAHN M., GERHARDS R. (2018):** Multi-Temporal Site-Specific Weed Control of *Cirsium arvense* (L.) Scop. and *Rumex crispus* L. in Maize and Sugar Beet Using Unmanned Aerial Vehicle Based Mapping. *Agriculture-Basel* 8. doi: [10.3390/agriculture8050065](https://doi.org/10.3390/agriculture8050065).
- TORRES-SÁNCHEZ J., PEÑA J.M., DE CASTRO A.I., LÓPEZ-GRANADOS F. (2014):** Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture* 103, 104–113. doi: <https://doi.org/10.1016/j.compag.2014.02.009>.
- ZISI T., ALEXANDRIDIS T.K., KAPLANIS S., NAVROZIDIS I., TAMOURIDOU A.-A., LAGOPODI A., MO-SHOU D., POLYCHRONOS V. (2018):** Incorporating Surface Elevation Information in UAV Multispectral Images for Mapping Weed Patches. *Journal of Imaging* 4, 132, <http://www.mdpi.com/2313-433X/4/11/132>.

Anhang



UAV based assessment of influence factors on canopy height and lodging severity using an objective threshold approach

UAV basierte Evaluierung von Einflussfaktoren auf die Kronendachhöhe und Lagerintensität unter Anwendung eines objektiven Schwellwertverfahrens

Norman Wilke¹, Bastian Siegmann¹, Lasse Klingbeil², Andreas Burkart³,
Sascha Heinemann¹, Uwe Rascher¹

¹Forschungszentrum Jülich, Institute of Bio- and Geosciences, Plant Sciences (IBG-2),
Wilhelm-Johnen-Straße, 52428 Jülich

²Rheinische Friedrich-Wilhelms-Universität Bonn, Institut für Geodäsie und Geoinformation,
Nußallee 17, 53115 Bonn

³JB Hyperspectral Devices UG, Am Botanischen Garten 33, 40225 Düsseldorf
E-Mail: n.wilke@fz-juelich.de

Abstract: *Unmanned Aerial Vehicles (UAVs) open new opportunities because data acquisition is timely flexible and the system can be operated very easily. The technology can provide plant breeders, insurance companies or farmers timely detailed information on plant traits with low monetary costs. In this study the potential of ultra-high spatially resolved UAV image data was investigated to assess the canopy height (CH) of barley using Structure from Motion (SfM) techniques. The results showed, that UAV derived information on the spatial height distribution of the canopy was influenced by the canopy structure and sowing density. In contrast classical plant height measurements only representing single points in the field. In conclusion, the UAV based CH is an autonomous trait which can only be compared with measured plant heights in field to a limited extent. The UAV derived CH was further used to determine the lodging percentage and the lodging severity of barley. Unmanned Aerial Vehicles (UAVs) open new opportunities because data acquisition is timely flexible and the system can be operated very easily. The technology can provide plant breeders, insurance companies or farmers timely detailed information on plant traits with low monetary costs. Especially breeding trials are extensive to monitor resulting in an increasing need for a faster selection of superior lines. In the following presentation the potential of ultra-high spatially resolved UAV image data was investigated to assess the canopy height (CH) of barley using Structure from Motion (SfM) techniques. The UAV derived CH was used to determine the lodging percentage and the lodging severity. Lodging is defined as the permanent displacement of a plant from the upright position. It is a major problem of cereals in agriculture because it leads to qualitative and quantitative yield losses up to 45 %. Traditionally lodg-*

ing assessment is based on field observations that are neither cost-efficient nor objective. For that reason, an objective threshold approach was proposed in this study to overcome subjective estimates and improve the accuracy in lodging determination. Compared to manual reference measurement the UAV based lodging percentage provided a very high correlation ($R^2 = 0.96$) when applied to breeding trials. As a proof of concept the method was additionally applied to a classical farmer field and let only to a slight overestimation of 2 % compared to reference data. Building on the parameter lodging percentage an approach was developed that allowed the assessment of lodging severity ($R^2 = 0.92$), an information that is important to estimate the yield impairment. The assessment of the two lodging parameters was tested on date sets with different ground sampling distances (GSDs). The strongest accuracies could be achieved for the data set containing the highest GSD (5 mm) but also lower spatial resolutions (15 mm) let to useful results what increases the practicability of the approach for larger areas. Traditionally lodging assessment is based on field observations that are neither cost-efficient nor objective. For that reason, an objective threshold approach was proposed in this study to overcome subjective estimates and improve the accuracy in lodging determination. Compared to manual reference measurement the UAV based lodging percentage provided a very high correlation ($R^2 = 0.96$) when applied to breeding trials. As a proof of concept the method was additionally applied to a classical farmer field and let only to a slight overestimation of 2 % compared to reference data. Building on the parameter lodging percentage an approach was developed that allowed the assessment of lodging severity ($R^2 = 0.92$), an information that is important to estimate the yield impairment. The assessment of the two lodging parameters was tested on date sets with different ground sampling distances (GSDs). The highest accuracies could be achieved for the data set containing the highest GSD (5 mm) but also lower spatial resolutions (15 mm) let to useful results what increases the practicability of the approach for larger areas. Furthermore, it was investigated that a freely available digital terrain model (DTM) based on airborne LIDAR data can serve as an alternative ground model for the CH retrieval and thus reduces the effort in data acquisition. A comparison of the derived plant traits using the UAV or DTM based ground model showed very high correlations (CH: $R^2 = 0.99$, lodging percentage: $R^2 = 0.94$).

Keywords: precision agriculture; remote sensing; unmanned aerial vehicles (UAVs); structure from motion; canopy height model; lodging percentage and severity.

Zusammenfassung: (auf Wunsch des Autors nicht abgedruckt – Anm. der Red.)

Methode zur Erfassung von Anbaugeräten durch Sensorfusion von Laserdistanzsensoren und Kameras für autonome Kupplungsvorgänge

Method using sensor fusion of laser distance sensors and cameras to track attachments for autonomous coupling processes

Julius Kirfel¹, Tristan Igelbrink², Jan Roters¹, Arno Ruckelshausen¹

¹Hochschule Osnabrück, Competence of Applied Agricultural Engineering (COALA),
Albrechtstraße 30, 49076 Osnabrück

²Kalverkamp Maschinenbau GmbH, Meppener Straße 9–11, 49597 Rieste
E-Mail: julius.kirfel@hs-osnabrueck.de

Zusammenfassung: Im Rahmen des hier vorgestellten Ansatzes werden die Orientierung und die Position von Anbaugeräten mithilfe von zwei Kameras und vier Laserdistanzsensoren erfasst. Diese Erkennung ist die Basis für autonome Kupplungsvorgänge. Zur Bestimmung der Lage des Anbaugerätes werden die Bilddaten der Kameras mit den Distanzinformationen aus den Laserdistanzsensoren fusioniert. Das Wechselspiel der Sensoren bei einem Kupplungsvorgang lässt sich anhand eines Zonenmodells beschreiben. Dabei werden die Informationen der einzelnen Sensoren sukzessiv miteinander kombiniert, bis die genaue Orientierung und Position des Anbaugerätes definiert ist. Der hier vorgestellte Ansatz lässt sich sowohl bei Feldrobotern als auch bei konventionellen Landmaschinen einsetzen und skalieren. Die Umsetzbarkeit wurde in einer Simulation mit *Gazebo* und *ROS* untersucht und nachgewiesen.

Deskriptoren: Autonomes Kuppeln, Digitaler Zwilling, *Gazebo*, Kameras, Laserdistanzsensoren, *OpenCV*, *ROS*, Sensorfusion, Simulation

Abstract: *The presented approach captures the orientation and position of implements by using two cameras and four laser distance sensors. This is the basis for autonomous coupling processes. To define the location of the attachment, the image data of the cameras are fused with the distance information from the laser distance sensors. The interplay of the sensors in the coupling process can be described using a zone model. The information from the individual sensors are successively combined until the exact position and orientation of the attachment has been provided. The approach presented here can be used with field robots as well as with conventional agricultural machines and can be scaled accordingly. The feasibility was investigated in a simulation with *Gazebo* and *ROS*.*

Keywords: *Autonomous coupling, digital twins, Gazebo, cameras, lasers distance sensors, OpenCV, ROS, sensor fusion, simulation*

1 Einleitung

Zur Bewirtschaftung von landwirtschaftlichen Flächen sind eine Reihe verschiedenster Anbaugeräte nötig. Das Kuppeln dieser Anbaugeräte an Traktoren oder Feldrobotern erfolgt in der Landwirtschaft manuell. Der Fahrzeugführer muss dabei die genaue Positionierung des Trägerfahrzeuges gegenüber dem Anbaugerät sicherstellen und die Ausrichtung zum Anbaugerät während des Kupplungsvorgangs permanent korrigieren. Der Wunsch, den gesamten Bewirtschaftungsprozess vollständig zu automatisieren, erfordert folglich auch die Automatisierung der Kupplungsvorgänge. Zusätzlich werden die Gefahren durch eine mögliche Fehlbedienung reduziert und der Komfort für den Anwender erhöht. Das Thema des autonomen Kuppelns beschäftigt sowohl Landmaschinenhersteller (JOHN DEERE 14) und Zulieferer (ZF FRIEDRICHSHAFEN 2017) als auch Forschungseinrichtungen (BLUME 2018). Die Basis für die Durchführbarkeit von autonomen Kupplungsvorgängen ist die präzise Erfassung von Orientierung und Position der Anbaugeräte bei Landmaschinen bzw. der Applikationen bei Feldrobotern.

Anhand des autonomen Feldroboters „BoniRob“ (RUCKELSHAUSEN, 2009) soll eine Methode zur Erfassung von Anbaugeräten mittels Laserdistanzsensoren und Kameras erläutert werden. Mit Hilfe der Fusion der Sensordaten lassen sich alle Freiheitsgrade der Anbaugeräte bestimmen. Durch die genaue Bestimmung der Lage des zu kuppelnden Systems kann der Roboter sich dem Ziel nähern und anschließend den Kupplungsvorgang durchführen. Mit der Simulationsumgebung *Gazebo* und dem *Robot Operating System* (ROS) wurde mit verschiedenen Simulationsszenarien die Umsetzbarkeit untersucht und nachgewiesen.

2 Prozess- und Systembeschreibung

Kupplungsvorgänge lassen sich grob in drei Phasen einteilen. Die erste Phase ist die Erfassung und die Bestimmung der Lage des Anbaugerätes. Die zweite Phase beschreibt die Fahrplanung und das Annähern des Fahrzeugs an das Anbaugerät. In der dritten und letzten Phase findet das mechanische Kuppeln von Fahrzeug und Anbaugerät statt. Die Phasen sind bei einem manuellen und einem autonomen Kupplungsvorgang identisch. Der Automatisierungsgrad hängt entscheidend von der Fahrzeugkinematik und den regelbaren Freiheitsgraden ab. So ermöglichen neue Fahrzeugkonzepte, wie z.B. der autonome Feldroboter „BoniRob“, vereinfachte Kupplungsvorgänge, da beispielsweise einzelne Räder individuell gelenkt werden können. Je nach Automatisierungsgrad kann der hier vorgestellte Ansatz als Assistenzsystem zur Positionierung oder als Messsystem für die Vollautomatisierung Verwendung finden. Eine Adaption der Methode auf Problemstellungen fernab der Landwirtschaft z.B. für Service- oder Trans-

portanwendungen ist ebenfalls vorstellbar. Dabei kann die Größe des Messsystems auf den jeweiligen Anwendungsfall passend skaliert werden.

Die Methode soll am Beispiel des Feldroboters „BoniRob“ vorgestellt werden (**Abbildung 1**). Die Methode wird mit Hilfe eines digitalen Zwillings mit dem Robot Operating System (ROS) und der Simulationsumgebung Gazebo näher betrachtet und untersucht.




Abbildung 1: a.) BoniRob 1&2 b.) BoniRob 1&2 – Digitale Zwillinge c.) Cornholio d.) Cornholio – Digitaler Zwilling e.) eWobot f.) eWobot – Digitaler Zwilling (LINZ 2019)

ROS ist ein *Open Source Framework* für die Programmierung von Robotern und unterstützt die Entwickler durch spezielle Werkzeuge und Bibliotheken. Mit Hilfe der 3D-Simulationsumgebung *Gazebo* lassen sich Roboter, Objekte und Sensoren in komplexen Umgebungen simulieren. Die **Abbildung 2** zeigt die Simulation mit *Gazebo*. Zu Simulationszwecken wird ein Einbaugerät in Form eines Quaders mit zwei Markerflächen verwendet. Der digitale Zwilling des „BoniRobs“ wird mit den entsprechenden Sensoren ausgestattet.




Abbildung 2: Simulation der Methode am Beispiel BoniRob; Darstellung in Gazebo

Verwendete Sensorik und passive Marker

Für die simulierten Sensoren werden die Eigenschaften realer Sensoren in die Simulation übertragen. Neben den aktiven Sensoren am Fahrzeug sind für die Detektion passive Marker am Anbaugerät notwendig. An das Markerlayout werden eine Reihe von Anforderungen gestellt, sodass ein neues Markerlayout entwickelt.

Es werden zwei LifeCam Studio Webcams der Firma Microsoft Corporation verwendet. Die Kamera hat eine Auflösung von 1920 x 1080 px und einen Autofokus zwischen 10 cm und 10 m. Der horizontale *Field of View* (FOV(H)) beträgt 75° (MICROSOFT 2018). Für eine generelle Überprüfung des Konzepts sind sie geeignet. Bei einer realen Applikation des Konzeptes sind dagegen robuste, für den Outdooreinsatz geeignete Kameras auszuwählen.

Zur Distanzmessung werden vier Dx35 Mid-Range Laserdistanzsensoren (LDS) der Firma SICK AG verwendet. Der Dx35 hat eine Auflösung von 0,1 mm bei einer Genauigkeit von ± 10 mm. Als Laser kommt ein Klasse-1 Laser zum Einsatz. Der Dx35 hat eine Fremdlichtsicherheit von 40klx. Der Messbereich liegt zwischen 0,05 m und 12 m auf natürlichen Objekten. Das Gehäuse des Dx35 hat die Abmessungen von 35 mm x 50 mm x 50 mm (B x H x T). Er ist mindestens IP65 klassifiziert (SICK 2013).

Für eine gute Detektierbarkeit muss sich der Marker durch seine Form eindeutig von natürlichen Objekten oder Maschinenbauteilen unterscheiden. Ein wichtiger Punkt ist die Empfindlichkeit des Markers gegenüber Verschmutzungen, da die im Marker enthaltenen Informationen verfälscht werden können. Zusätzlich muss der Marker sowohl in mehreren Metern Entfernung, sowie in direkter Nähe zur Kameralinse auswertbare Informationen liefern. Diese Anforderung macht ein verschachteltes Markerlayout not-

wendig. Die zentrale Aufgabe des Markers ist die Bestimmung des Mittelpunktes zur Zentrierung des Fahrzeugs gegenüber dem Anbaugerät bzw. der Applikation. Idealerweise liegt der Mittelpunkt des Markers im Zentrum der Kameraoptik, da der Mittelpunkt so über die gesamte Distanz optimal erfasst werden kann. Das Resultat ist ein Markerlayout aus konzentrischen Kreisen (**Abbildung 3**).



Abbildung 3: Markerlayout (um 90° gedreht dargestellt)

Das Layout ist relativ unempfindlich gegenüber Verschmutzung, weil mehrere Kreise für die Bestimmung des Mittelpunktes vorhanden sind. Der Marker lässt sich über eine große Distanz erkennen und kann, je nach Bedarf, erweitert und skaliert werden. Durch den bekannten Abstand der Mittelpunkte zueinander ist es möglich, Distanzen in der Bildebene optisch zu berechnen. Ein zunehmender Abstand vom oberen zum unteren Mittelpunkt erhöht die Genauigkeit bei der Messung. Auch ist es möglich, die Rotation aus dem Versatz der Mittelpunkte zu bestimmen. Der Marker hebt sich durch seine Form von natürlichen Objekten eindeutig ab und kann zuverlässig in Kamerabildern lokalisiert werden.

Gesamtkonzept zur Bestimmung aller Freiheitsgrade des Anbaugerätes

Das Gesamtkonzept zur Bestimmung aller Freiheitsgrade setzt sich aus den Kameras und den Laserdistanzsensoren (LDS) am Fahrzeug, sowie den Markern am Anbaugerät bzw. der Applikation zusammen. Durch die Kombination der Informationen aus den Kamerabildern und den Messwerten der LDS lassen sich alle sechs Freiheitsgrade des Anbaugerätes erfassen. **Abbildung 4** zeigt alle Informationsquellen zur Bestimmung der Freiheitsgrade des Anbaugerätes.




Abbildung 4: Gesamtkonzept zur Bestimmung aller Freiheitsgrade

In **Abbildung 4** ist links schematisch der Rahmen des „BoniRobs“ mit den LDS und den beiden Kameras abgebildet. Rechts ist eine virtuelle Ebene dargestellt, die die Lage des Anbaugerätes repräsentiert. Die Größe der Ebene ergibt sich aus dem Abstand zwischen den Sensoren am Rahmen. Die Distanzinformationen und die Kameradaten werden fusioniert. Die Kameras selbst befinden sich am Ende des Kuppelvorgangs auf der Höhe des mittleren, hier roten Mittelpunktes. Durch die Erfassung der Marker pro Seite können die Verschiebungen in Y-Richtung und Z-Richtung bestimmt werden. Die Rotation um die X-Achse (Rollen) kann durch den Höhenunterschied zwischen den Kameramittelpunkten und den Mittelpunkten der Marker der rechten und linken Seite ermittelt werden. Alternativ kann das Rollen auch durch den Versatz der drei Marker pro Seite bestimmt werden. Aus den Werten der LDS ergeben sich die Verschiebung in X-Richtung sowie die Rotationen um die Y-Achse (Nicken) und um die Z-Achse (Gieren).

Weiterführende Betrachtung des Kupplungsvorgangs

Damit die Bestimmung aller Freiheitsgrade möglich ist, sind einige Voraussetzungen zu erfüllen. **Abbildung 5** zeigt die verschiedenen Kupplungsregionen, die bei einem Kupplungsvorgang zu durchfahren sind und geht dabei auf die kritischen Freiheitsgrade und das Zusammenspiel der Sensorik ein.

Nach dem Eintritt in die Kupplungsregion müssen die drei Marker an der linken und rechten Seite von den Kameras erfasst werden. Dazu ist es wichtig, dass beide Kameras die jeweiligen Marker erfassen können. Deshalb muss im ersten Schritt die seitliche Verschiebung in Y-Richtung geregelt werden. Bei einem Fahrzeug mit aktiver Höhenverstellung ist daraufhin die Z-Achse auszuregulieren, damit die LDS auf das Anbaugerät treffen. Die Informationen aus den LDS werden benötigt, um die anderen Freiheitsgrade

des Systems erfassen zu können. In der Ausrichtungsregion liegen alle Informationen zur Bestimmung des Anbaugerätes vor. Idealerweise ist das Fahrzeug zu diesem Zeitpunkt schon ausreichend genau positioniert. Daher muss in der Präzisionsregion hauptsächlich der Abstand in X-Richtung verringert werden. Zum Abschluss des Kuppelvorgangs müssen alle Freiheitsgrade ausgegletzt sein. Hierfür ist es wichtig, dass die LDS die Markerplatten am Anbaugerät permanent treffen. Das Kuppeln unterliegt dem engen Toleranzfenster der verwendeten Kupplungsmechanik. Sind die genannten Voraussetzungen erfüllt, kann die Kombination aus Kameras, LDS und Markern alle Freiheitsgrade des Anbaugerätes bestimmen.




Abbildung 5: Kupplungsregionen mit Sensorik und kritischen Freiheitsgraden

3 Ergebnisse

Der Kupplungsvorgang wurde unter den idealen Bedingungen einer Simulation getestet. Verschiebungen und Rotationen an Fahrzeug oder Anbaugerät können präzise durchgeführt werden. In der Simulation lassen sich verschiedene, reproduzierbare Tests durchführen.

Zur Bestimmung der genauen Lage müssen beide Kameras die Marker erkennen und zusätzlich alle Distanzsensoren das Objekt erfassen. In der Simulation kann die berechnete Lage mit der tatsächlich simulierten Lage des Anbaugerätes verglichen und die Genauigkeit bei der Detektion berechnet werden. Die Größe der Markertafeln beträgt bei allen Versuchen 0,3 m mal 0,8 m.

Die **Abbildung 6** zeigt die gemittelten Abweichungen in der YZ-Ebene bei zunehmender Distanz zwischen Anbaugerät und Fahrzeug.

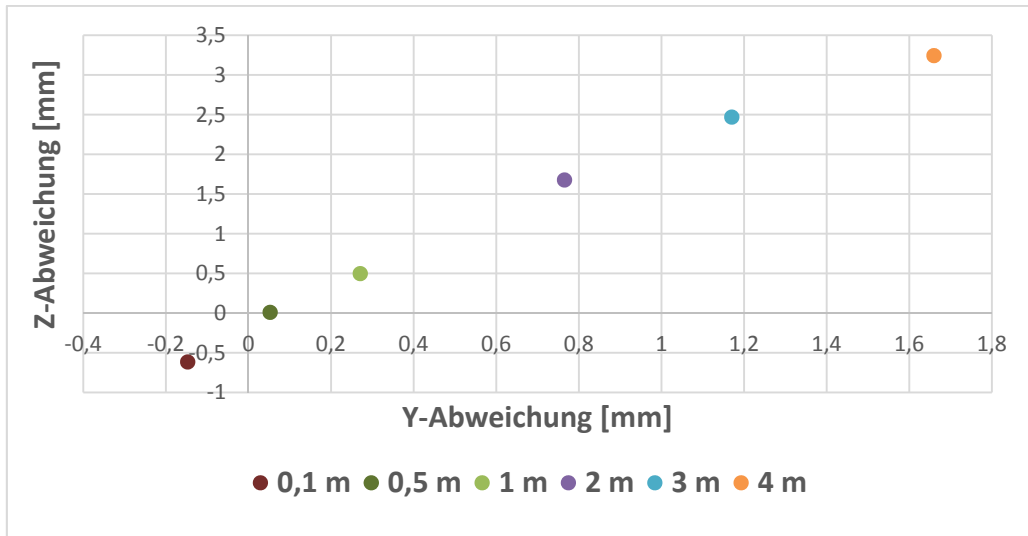


Abbildung 6 Gemittelte Abweichungen in YZ-Ebene zwischen Anbaugerät und Kamera bei verschiedenen Entfernungen in X-Richtung

Bei der ersten Simulation wurde ausschließlich die Distanz zwischen Anbaugerät und Fahrzeug in der X-Richtung verändert. Dabei führen alle Auftreffpunkte der LDS auf der Ebene die gleiche Bewegung aus und können daher gemittelt werden. So ergibt sich eine Gesamtabweichung des Anbaugerätes. Der Mindestabstand für eine Detektion liegt bei 10 cm. Das Anbaugerät kann zwischen 10 cm und 4 m eindeutig identifiziert werden. Die Ergebnisse des Versuchs zeigen ein nahezu lineares Verhalten zwischen der Distanz von Fahrzeug und Anbaugerät und der Genauigkeit der Positionsbestimmung des Anbaugerätes. Mit zunehmender Distanz sinkt die Genauigkeit der Detektion sowohl für die Y-Achse als auch für die Z-Achse.

Neben der reinen Translation wird hier auch auf Ergebnisse mit kombinierten Freiheitsgraden eingegangen. Die zeigt die Ergebnisse der zweiten Simulation mit kombinierten Freiheitsgraden. Die Werte wurden so gewählt, dass sie in etwa realistische Positionen des Anbaugerätes widerspiegeln (**Tabelle 1**).

Tabelle 1: Translation: X = 3,50m, Y = -0,20m, Z = 0,05 m; Rotation: Rollen = 1°, Nicken = -2°, Gieren = 5°

Punkt/Abweichung	X [m]	Y [m]	Z [m]
LDS oben, rechts	0,0089	0,0080	0,0087
LDS oben, links	0,0182	0,0076	-0,0055
LDS unten, rechts	0,0093	-0,0176	0,0090
LDS unten, links	0,0160	-0,0177	-0,0051

Bei der zweiten Simulation wird das Anbaugerät 3,50 m in X-Richtung, 0,20 m in negative Y-Richtung und 0,05 m in Z-Richtung verschoben. Zusätzlich wird das Anbaugerät 1° um die X-Achse, -2° um die Y-Achse und 5° um die Z-Achse rotiert. Die Abweichun-

gen wurden für die vier Auftreffpunkte der LDS berechnet. Die Ergebnisse der zweiten Simulation zeigen, dass die Lage des Anbaugerätes sehr genau erfasst werden kann. Die größten Abweichungen bei der Erfassung ergeben sich für die X-Achse. Die Abweichungen liegen mitunter an der geringen Genauigkeit von ± 10 mm der LDS.

4 Diskussion

Die Ergebnisse der hier vorgestellten Methodik zur Erfassung von Anbaugeräten zeigen, dass eine Bestimmung aller Freiheitsgrade durch Fusion von Kamera- und Laserdistanz-sensordaten möglich ist. Generell stellt sich bei Simulationsergebnissen immer die Frage nach der Übertragbarkeit in die Praxis, jedoch zeigen die Erfahrungen durch digitale Zwillinge (LINZ *et al.* 2019), dass eine erfolgreiche Simulation bereits ein signifikanter Schritt zum Nachweis der Machbarkeit und zur Umsetzung darstellt. Bei der Simulation wurde darauf geachtet, dass die Spezifikationen der simulierten Sensoren mit den realen Sensoren übereinstimmen. Erste Ergebnisse aus Realversuchen sind vielversprechend.

Literaturverzeichnis

- BLUME T. (2018):** Entwicklung neuer Assistenzsysteme für Traktoren mittels rückwärts gerichteter 3D-Time-of-Flight Kamera. Handout. Institut für mobile Maschinen und Nutzfahrzeuge, TU Braunschweig, https://www.tu-braunschweig.de/Medien-DB/ilf/forschung/handout_tof.pdf, Abruf: 25.10.2018.
- JOHN DEERE GMBH & CO. KG (2014):** Drei Medaillen für John Deere auf der SIMA 2015, Pressemitteilung, https://www.deere.de/de_DE/our_company/news_and_media/press_releases/2014/agriculture/sima.page; Abruf: 25.10.2018.
- LINZ A., HERTZBERG J., ROTERS J., RUCKELSHAUSEN, A. (2019):** „Digitale Zwillinge“ als Werkzeug für die Entwicklung von Feldrobotern in landwirtschaftlichen Prozessen. In: Proceedings zur 39. GIL-Jahrestagung, 18.-19. Februar 2019 in Wien, Austria.
- MICROSOFT CORPORATION (2018):** LifeCam Studio for Business. <https://www.microsoft.com/accessories/de-de/products/webcams/lifecam-studio/q2f-00015>; Abruf: 25.10.2018.
- RUCKELSHAUSEN A., BIBER P., DORNA M., GREMMES H., KLOSE R., LINZ A., RAHE R., RESCH R., THIEL M, TRAUTZ D., WEISS U. (2009):** BoniRob: An autonomous field robot platform for individual plant phenotyping. I: Precision Agriculture '09, ECPA, European Conference on Precision Agriculture, 7, pp. 841–847.
- SICK-VERTRIEBS-GMBH (2013):** Dx35 Mid-Range-Distanzsensoren. https://cdn.sick.com/media/docs/4/44/844/Product_information_Dx35_de_IM0049844.PDF, Abruf: 25.10.2018.
- ZF FRIEDRICHSHAFEN AG (2017):** ZF Innovation Tractor: Wegweiser für künftige Off-Highway-Anwendungen. Pressemitteilung. – https://press.zf.com/site/press/de_de/microsites/press/list/release/release_32654.html, Abruf: 25.10.2018.

Multi-wavelength laser line profiling (MWLP) System zur feldbasierten Bestimmung von 3D Strukturen, spektralen Eigenschaften und Wachstumsparametern von Pflanzen

Multi-wavelength laser line profiling (MWLP) system for field-based-determination of 3D structure, spectral features and growth parameters of plants

Christian Scholz, Matthias Igelbrink, Wolfram Strothmann, Arno Ruckelshausen

Hochschule Osnabrück, Sedanstraße 26, 49076 Osnabrück

E-Mail: c.scholz@hs-osnabrueck.de

Zusammenfassung: Die MWLP-Technologie stellt ein innovatives Verfahren zur scannenden Erfassung von 3D-Informationen sowie Spektral- und Rückstreuungseigenschaften von Objekten dar. Durch die freie Auswahl und anwendungsspezifische Kombinierbarkeit der Wellenlängen für die eingesetzten Laserlinien, in einem Bereich von ca. 400–1000 nm, ergibt sich eine hohe Flexibilität für mögliche Anwendungsfelder dieser Technologie.

Aktuell wurde das bereits vorgestellte Prototypensystem durch die Autoren zu einem integrierten System weiterentwickelt. Hierbei liegt der Fokus auf Kompaktheit, Variabilität und Skalierbarkeit, bei einer gleichzeitigen hohen Robustheit und geringen Anschaffungskosten des Systems für Outdoor- und Indoor-Anwendungen.

Im Rahmen dieser Arbeit wurden die Versuche zum Scannen von Pflanzen mit dem weiterentwickelten MWLP-System und dem Feldroboter BoniRob konsequent auf weitere Kulturarten, wie Raps und Senf ausgedehnt. Anhand der erzeugten Rohdaten lassen sich verschiedenste Pflanzeigenschaften ableiten.

Deskriptoren: Multi-wavelength, 3D, Spektrale Eigenschaften, Pflanzen, BoniRob, Feldversuche

Abstract: *The MWLP-technology represents an innovative method for scanning acquisition of 3D information as well as spectral and backscatter properties of objects. The free-selection and customized set-up of the laser lines and wavelengths, in a range of 400-1000 nm, ensure a high flexibility for possible applications of this technology.*

More recently, the prototype system has been transformed into an integrated system by the authors with optimizations in compactness, variability and scalability, combined with a high degree of robustness and low acquisition costs for outdoor and indoor applications.

In this work, the plant scanning experiments with the advanced MWLP system and the field robot BoniRob were consistently extended in field trials to other crops like rape and mustard. On the basis of the generated raw data, a wide variety of plant properties can be derived.

Keywords: Multi-wavelength, 3D, spectral information, plants, BoniRob, field trails

1 Einleitung

Feldbasierte Phänotypisierung von Pflanzen stellt ein stark wachsendes Anwendungsfeld bildgebender Sensorik dar. Aktuelle Forschungsergebnisse setzen hierbei auf die kombinierte Erfassung von 3D- und Spektraldaten der Objekte durch kombinierte Sensoren, wie multispektrale Stereokameras oder kombinierte Sensoreinheiten, z.B. PrimeSense (LIEBISCH *et al.* 2016) sowie durch Sensorfusionsansätze (BUSEMEYER *et al.* 2013). Gerade in frühen Wachstumsstadien oder zur genauen Analyse der Blattkonturen werden jedoch hochgenaue 3D-Daten im Millimeter und Submillimeter benötigt, die in scannenden, industriellen Anwendungen insbesondere mittels des Lichtschnittverfahren erfasst werden (GOCKEL 2006). Hierbei stellt der Lichtschnitt-basierte MWLP-Ansatz (Multiwavelength Laser Line Profile Sensing) eine Möglichkeit der Erfassung von Spektral und 3D-Daten von Pflanzen mit einem Sensor dar (STROTHMANN *et al.* 2014).

2 Material und Methoden

Hardware-Aufbau

Ausgehend vom bereits vorgestellten Prototyp wurde das System in einem kompakten Sensorkopf integriert und konsequent weiterentwickelt. Sämtliche Komponenten sind in einem schwarz eloxierten Aluminium-Gehäuse integriert, was eine hohe Robustheit gegenüber äußeren Störgrößen garantiert. Der integrierte Sensor umfasst eine Monochrome-Kamera USB 3.0, drei Linienlasern mit unterschiedlichen Wellenlängen und ein Embedded System vom Typ Nvidia Jetson TX2, welches die erforderliche Bildverarbeitung rechnet. Durch die hohe Flexibilität des Systems und die Standardisierung der notwendigen Kalibrierung können die Linienlaser in einem Wellenlängenbereich von ca. 400–1000 nm frei gewählt werden. Zusätzlich können der Austrittswinkel der Laser und das Objektiv der Kamera in einem bestimmten Bereich frei definiert werden.

Diese Hardwarekonfigurationen ermöglichen eine hohe Anpassung an die jeweiligen Einsatzgebiete des Systems. Bedingt durch die scannende Erfassung der Objekte (Lichtschnittverfahren) ist ein Drehgeber/Encoder zwingend erforderlich. Hierbei kann ein Drehgeber entweder direkt an die vorhandenen GPIO-Pins des Jetsons angeschlossen werden oder die Bewegungsinformationen werden von einem (Navigations-) Rechner des Trägerfahrzeugs via Ethernet zur Verfügung gestellt. Die nachfolgende **Abbildung 1** zeigt den schematischen Aufbau des Sensorkopfs mit einigen ausgewählten Spezifikationen. Das MWLP-System kann mit einer Spannung von 12–24 V / DC

betrieben werden und verfügt über eine externe USB 2.0- und Gigabit-Ethernet Schnittstelle.




Abbildung 1: Schematische Darstellung des MWLP-Systems

Die Auflösung des Systems ist abhängig von der Framerate und beträgt bei 80 fps ca. 0,6 mm sowie bei 300 fps 1,5 mm. Die gesamte Software des MWLP-Systems ist auf dem Nvidia Jetson TX2 Embedded-System implementiert. Aufgrund der optischen Leistung der verwendeten Linienlaser ist die Laserklasse 2M angegeben. Um die Handhabung – in Bezug auf die Lasersicherheit – weiter zu erhöhen, verfügt das System über einen Sicherheitsschalter am Gehäuse. Dieser Schalter muss vom Anwender vor der Aufnahme aktiv betätigt werden.

Softwarepakete und Bedienung

Die Software des MWLP-Systems umfasst ein Linux Betriebssystem in der Distribution Ubuntu und weitere Pakete, wie ROS (Robot Operating System, www.ros.org), opencv (zur Bildverarbeitung) (opencv.org) und PCL (Point Cloud Library; zur 3D-Datenverarbeitung) (www.pointclouds.org). **Abbildung 2** zeigt die grafischen Elemente der MWLP-Software zur Darstellung der Sensordaten. Hierbei ist a) der selbst implementierte *overlay_viz_controller*, mit dem die Daten der einzelnen Linienlaser ausgewählt und für die Berechnung der Farbvisualisierung aktiviert/deaktiviert werden können. Die ausgewählten Sensordaten werden dann, unter b) im Tool *rviz* als farbige 3D-PointCloud sichtbar. Zusätzlich zu PointClouds kann auch ein Bilder-Stream (fortlaufendes 2D Bild) der 3D Daten angezeigt werden. Diese Darstellung ist unter c) zu finden. Die Abbildung zeigt die PointCloud und das Bild für die Überlagerung von allen 3 Linienlasern (ROT, GRÜN, NIR). Hierbei ist der grüne Linienlaser grün eingefärbt, der rote Linienlaser rot und der NIR Linienlaser blau eingefärbt. Die farbliche Zuordnung kann beliebig angepasst wer-

den. Dargestellt sind hier Pflanzendaten von Raps, welche mit dem System im Feld erhoben wurden.

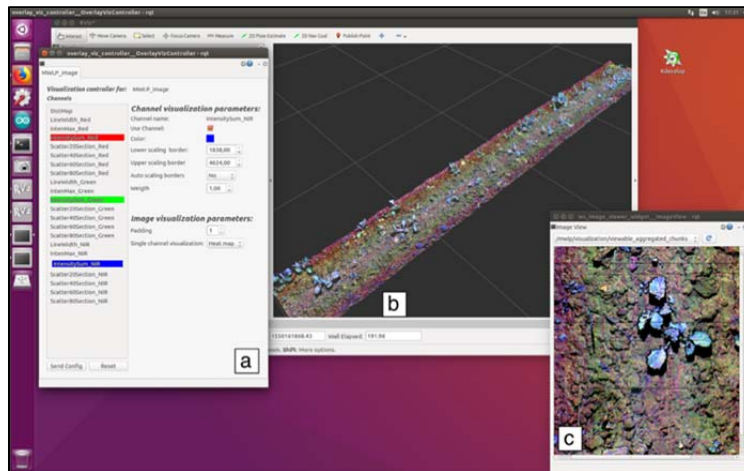


Abbildung 2: Softwarepakete zur Konfiguration des MWLP-Systems

Durch die Verwendung von ROS können die entsprechenden Sensordaten auch als bagfiles (<http://wiki.ros.org/Bags>) gespeichert werden und wieder abgespielt werden. Zusätzlich können die aufgenommenen Sensordaten auch in die Software MATLAB (www.mathworks.com) als .mat Files integriert oder als .pcd Files (Point Cloud Data) konvertiert werden. Außerdem ist eine Konvertierung der 3D Daten in 2D Bilder als .png Files möglich.

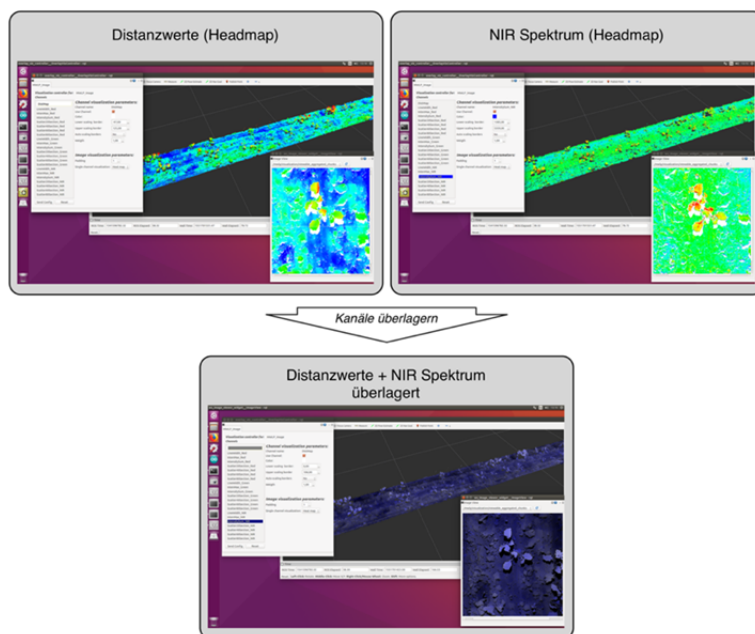


Abbildung 3: Überlagerung von einzelnen Kanälen

Durch die beschriebene Software und die notwendige Kalibrierung des Systems ergeben sich einzigartige Möglichkeiten zur Überlagerung der einzelnen Laserlinien und

somit die Nutzung der jeweiligen Eigenschaften für eine spätere Interpretation. Die nachfolgende **Abbildung 3** zeigt die Überlagerung der Distanzwerte (oben, links) und der NIR Spektralwerte (oben, rechts) für jedes Pixel zu einer Ausgabe. Die Darstellung der Überlagerung ist nur ein Beispiel für die Eigenschaften des MWLP-Systems. Aufgrund der pixelbasierten Aufgabe und der Anzahl von Kanälen ergeben sich vielfältige Möglichkeiten zur Überlagerung.

3 Feldversuche

Für die Outdoor-Anwendung der feldbasierten Phänotypisierung wird das MWLP System in Plattformen zur Phänotypisierung – wie z.B. BreedVision – oder in dem von Bosch, den Amazonen-Werken und der Hochschule Osnabrück entwickelten Feldroboter BoniRob eingesetzt (MÖLLER *et al.* 2016, BANGERT *et al.* 2013). Im Rahmen der hier vorgestellten Arbeiten wurde das MWLP-System für den Feldroboter BoniRob als ein Applikationsmodul (App) implementiert. Hierbei dient der BoniRob als Trägerplattform und Energieversorgung für das System. Die nachfolgende **Abbildung 4** zeigt die „MWLP-App“ zusammen mit BoniRob während eines Feldversuchs in Raps im November 2018.



Abbildung 4: Feldroboter BoniRob mit MWLP-App

Nachdem mit dem ersten MWLP-Forschungsprototypen bereits Feldtests in den Kulturen Feldsalat und Möhren durchgeführt wurden (mit Fokus auf Anwendungen zur Beikrautregulierung) wurden die Feldversuche im letzten Jahr mit dem neuen System auf die Kulturen Senf und Raps erweitert und hier in beiden Kulturen Felddaten erhoben. Hierbei liegt der Raps im Fokus der Phänotypisierungsanwendung. Der Feldversuch wurde in der Ultraspätsaat in ausgewählten Parzellen der DSV (Deutsche Saatveredelung AG) am Standort Asendorf, Niedersachsen durchgeführt.

4 Ergebnisse und Diskussion

Die nachfolgende **Abbildung 5** zeigt einen Auszug der aufgenommenen Felddaten der Kulturen Raps und Senf. Hierbei sind bei Raps (**Abbildung 5**, links) die Linienlaser ROT, GRÜN und NIR visuell dargestellt und entsprechend Rot, Grün und Blau eingefärbt. Bei Senf (**Abbildung 5**, rechts) sind nur die Linienlaser ROT und GRÜN dargestellt und mit Rot und Grün eingefärbt. Durch diese hochauflösenden Sensordaten können auch kleinste Strukturen, wie Blattkonturen aufgelöst werden und in der Klassifizierung berücksichtigt werden.




Abbildung 5: MWLP-Felddaten von Raps und Senf

Basierend auf diesen aufgenommenen Daten und der pixelbasierten Klassifizierung der MWLP-Daten, welche für Beikrautregulierung in Möhren entwickelt wurde (STROTHMANN *et al.* 2017), wurden erste Tests zur Klassifizierung in Raps und Senf durchgeführt. **Abbildung 6** zeigt das durchgeführte Labeling der Daten für Raps und Senf. Hierbei wird der Boden mit „Schwarz“ markiert, mit „Grün“ werden die Nutzpflanzen und mit „Rot“ das Beikraut in der Aufnahme markiert.

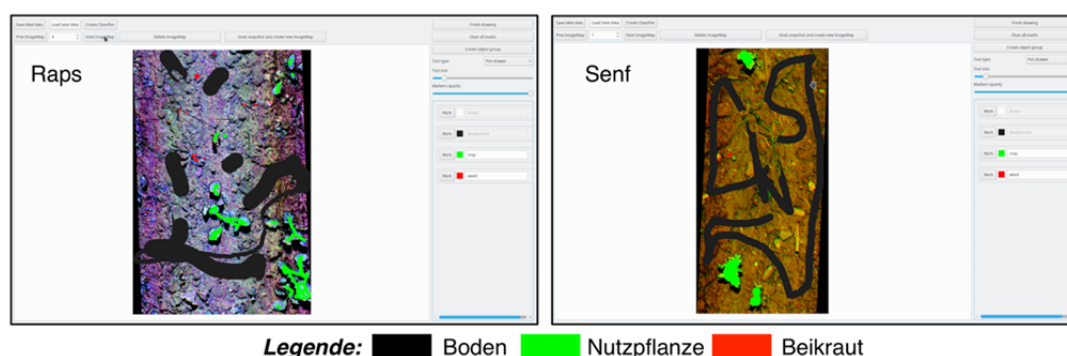


Abbildung 6: Labeling der aufgenommenen MWLP-Daten

Durch den pixel-basierten Labeling- und Lernansatz ist die Adaption auf andere Pflanzenarten durch ein einfaches Labeling von wenigen Beispieldaten möglich. Der zu erzeugende Klassifizierer nutzt anschließend die Spektralwerte zur Pflanzen/Boden Klas-

sifikation und 3D-Merkmale (Flicker, Radius-based Surface Deskription) zur Klassifizierung von Pflanzenarten (STROTHMANN *et al.* 2017).

Anschließend wird die Klassifizierung für die aufgenommenen Daten der beiden Kulturen angewendet und so eine Unterscheidung zwischen Boden, Nutzpflanze und Beikraut hergestellt. Die nachfolgende **Abbildung 7** zeigt die Anwendung der Klassifizierung auf die Daten. In der Abbildung sind jeweils ein Eingangsbild und Ausgangsbild der beiden Kulturen aufgetragen. Das Bild zeigt im oberen Bereich die jeweiligen Rohdaten. Im unteren Bereich des Bildes sind die Ausgangsbilder nach der beschriebenen Klassifizierung dargestellt. Die Ergebnisse zeigen eine gute Filterung der Bereiche der Nutzpflanzen (Grün). Hierbei werden sowohl die Bereiche des Bodens als auch der Beikräuter (**Abbildung 7**, rechts oben) von den Pixeln der Nutzpflanzen separiert. Somit kann der Großteil der Daten bereits vor der Objekterkennung auf Pixelebene von den Nutzpflanzenpixeln getrennt werden, die im eigentlichen Fokus der Anwendung stehen.

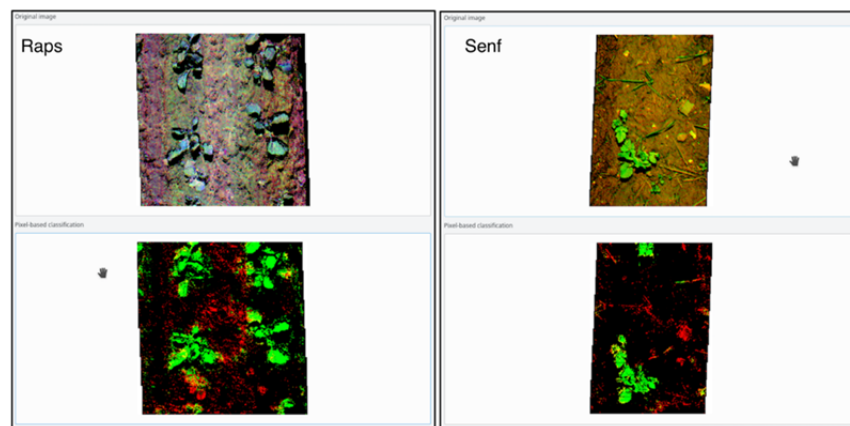


Abbildung 7: Ergebnisse der Klassifizierung für Raps und Senf

Auf diesen bereitgestellten Klassifizierungsdaten und 3D- + Spektraldaten wird im Folgenden gezeigt, wie Pflanzenmerkmale extrahiert werden können. Für die Merkmalsextraktion werden in der weiteren Verarbeitung nur die Punkte der Punktwolke analysiert, welche bereits als Nutzpflanzenpixel identifiziert wurden. Dies erlaubt eine erhebliche, mehrstufige Datenreduktion der Rohdaten vor Berechnung der Objekterkennung und Merkmalsextraktion als Ausgangsgrößen der Phänotypisierung. Die beschriebenen Schritte sind in der nachfolgenden **Abbildung 8** schematisch dargestellt. Der dargestellte Aufbau der MWLP-Datenverarbeitung – innerhalb einer mehrstufigen Verarbeitungs- und Datenreduktionskette – ist online-fähig und kann somit dem Züchter die Merkmalsinformationen unmittelbar nach der Überfahrt bereitstellen. Weiterhin können die Daten nach jedem Reduktionsschritt optional (sequenziell oder durchgehend) abgespeichert werden, damit diese als Zusatzinformationen visualisiert werden können. Dies ermöglicht es, die Datenintensität der Aufzeichnung entsprechend den Anforderungen der Anwendung flexibel zu skalieren.

Das beschriebene MWLP-System zusammen mit der dargestellten Klassifizierung und den ersten Ergebnissen zu dieser Technologie ermöglichen somit die weitere Entwicklung von Pflanzenparametern zur sensorbasierten Phänotypisierung von Raps.

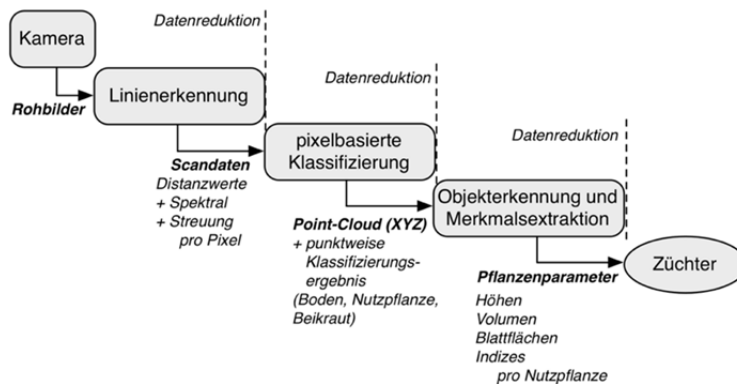


Abbildung 8: Schematische Darstellung der Schritte zur Bestimmung von Pflanzenparametern

Danksagung

Diese Arbeit ist im Rahmen des Forschungsprojekts RapiD entstanden und wird durch das BMEL (Bundesministerium für Ernährung und Landwirtschaft) sowie durch die FNR (Fachagentur Nachwachsende Rohstoffe e.V.) und die GFPi (Gemeinschaft zur Förderung von Pflanzeninnovation e. V.) gefördert.

Literaturverzeichnis

- BANGERT W., KIELHORN A., RAHE F., ALBERT A., BIBER P., GRZONKA S., HAUG S., MICHAELS A., MENTRUP D., HÄNSEL M., KINSKI D., MÖLLER K., RUCKELSHAUSEN A., SCHOLZ C., SELLMANN F., STROTHMANN W., TRAUTZ D. (2013):** Field-Robot-Based Agriculture: „RemoteFarming.1“ and „BoniRob-Apps“, 71. Tagung LAND.TECHNIK – AgEng, 439–446.
- BUSEMEYER L.; MENTRUP D.; MÖLLER K.; WUNDER E.; ALHEIT K.; HAHN V.; MAURER H.P.; REIF J.C.; WÜRSCHUM T.; MÜLLER J.; RAHE F.; RUCKELSHAUSEN A. (2013):** BreedVision – A Multi-Sensor Platform for Non-Destructive Field-Based Phenotyping in Plant Breeding, Sensors, (13), 2830–2847.
- GOCKEL, T. (2006):** Interaktive 3D-Modellerfassung mittels One-Shot-Musterprojektion und Schneller Registrierung. Universitätsverlag Karlsruhe, Karlsruhe.
- LIEBISCH F., PFEIFER J., KHANNA R., LOTTES P., STACHNISS C., FALCK T., SANDER S., SIEGWART R., WALTER A. & GALCERAN E. (2016):** Flourish – A robotic approach for automation in crop management. – In: Bornimer Agrartechnische Berichte (93), 53–63, 22. Workshop Computer-Bildanalyse und Unbemannte autonom fliegende Systeme in der Landwirtschaft Wernigerode.
- MÖLLER K.; JENZ M.; KROESEN M.; LOSERT D.; MAURER H.-P.; NIEBERG D.; WÜRSCHUM T.; RUCKELSHAUSEN A. (2016):** „Feldtaugliche Multisensorplattform für High-Throughput Getreidephänotypisierung – Aufbau und Datenhandling“, Referate der 36. GIL-Jahrestagung, 22.–23. Februar, Osnabrück, 137–140.

- STROTHMANN W., RUCKELSHAUSEN A., HERTZBERG J. (2014):** Multiwavelength laser line profile sensing for agricultural crop characterization, Proc. SPIE 9141, Optical Sensing and Detection III, 91411K.
- STROTHMANN W., TSUKOR V., HERTZBERG J., RUCKELSHAUSEN A. (2015):** Konfigurationsmöglichkeiten und Datenkonzepte des Multiwavelength Line Profiling (MWLP) Systems, Bornimer Agrartechnische Berichte, (88), 42–52.
- STROTHMANN W., RUCKELSHAUSEN A., HERTZBERG J., SCHOLZ C., LANGSENKAMP F. (2017):** Plant classification with In-Field-Labeling for crop/weed discrimination using spectral features and 3D surface features from a multi-wavelength laser line profile system, Computers and Electronics in Agriculture, 134(3), 79–93.

Einsatz von Deep Learning zur Klassifikation landwirtschaftlicher Kulturen auf Basis hyperspektraler Fernerkundungsdaten

Deep Learning for Agricultural Crops Classification based on Hyperspectral Remote Sensing Data

Lucas Wittstruck, Thomas Jarmer und Martin Kanning

Institut für Informatik, Wachsbleiche 27, 49090 Osnabrück

E-Mail: lucas.wittstruck@uni-osnabrueck.de

Zusammenfassung: In der vorliegenden Studie wurde eine pixelbasierte Klassifikation von Nutzpflanzen auf Basis von hyperspektralen Aisa-DUAL-Daten in der Nähe der Stadt Köthen (Deutschland) durchgeführt. Zu diesem Zweck wurde ein CNN verwendet um tiefe spektrale Merkmale der insgesamt acht vorkommenden landwirtschaftlichen Kulturen zu extrahieren. Die Validierung der Klassifizierungsergebnisse basierte auf verfügbaren Daten des Integrierten Verwaltungs- und Kontrollsystems der EU (InVeKos). Das Ergebnis der Studie wies insgesamt eine Klassifikationsgenauigkeit von 82,6 % auf. Spektral ähnliche Getreidearten konnten dabei mit einer hohen Genauigkeit klassifiziert werden. Über die post-klassifikative Ableitung von feldspezifischen Klassenzuordnungen ließ sich das Ergebnis nachträglich verbessern. Infolgedessen konnte das Potenzial von CNNs für die Klassifikation landwirtschaftlicher Flächen im Hinblick auf die Kontrolle der Agrarsubventionen der EU festgestellt werden.

Deskriptoren: AisaDUAL, Convolutional Neural Networks, Feldfrüchte, Landnutzungs-klassifizierung

Abstract: *In this work, a pixelwise classification of agricultural crops on AisaDUAL airborne hyperspectral data was performed near the city of Köthen (Germany). For this purpose, a CNN was used to extract deep spectral features of eight agricultural crop types. The validation of the classification results was based on available data from the Integrated Administration and Control System (IACS). The result of the study revealed an overall accuracy of 82.6%. In particular, cereals that have very similar spectral properties, could be classified with high accuracies. The post-classificative derivation of field-specific class assignments enabled a subsequent improvement of the result. As a consequence, it appears that the application of CNNs is potentially suitable for the monitoring of agricultural fields in respect to EU agricultural subsidy controls.*

Keywords: *AisaDUAL, Convolutional Neural Networks, Crops, Land Use Classification*

1 Einleitung

Die Klassifikation landwirtschaftlicher Kulturen ist im Rahmen der Gemeinsamen Agrarpolitik (GAP) der EU von großem Interesse. Die GAP legt für jeweils sieben Jahre EU-Förderleitlinien und die dazugehörige finanzielle Unterstützung für Landwirte fest. Mit der Inanspruchnahme der Subventionen verpflichtet sich ein Landwirt, die Förderleitlinien bei der Bewirtschaftung seiner Flächen einzuhalten (EUROPÄISCHE KOMMISSION 2007). In der Praxis werden für die Überwachungen sogenannte Vor-Ort-Kontrollen sowie Methoden aus der Fernerkundung angewendet. Insbesondere letzteres „reduziert den Prüfaufwand deutlich, da nur im Zweifelsfall einzelne Flächen in einer Nachkontrolle vor Ort überprüft werden müssen“ (LANDWIRTSCHAFTSKAMMER NORDRHEIN-WESTFALEN 2017).

Der korrekten Bestimmung der Anbaukulturen aus fernerkundlichen Bilddaten kommt daher eine wichtige Bedeutung zu. Eine sehr genaue Erfassung des charakteristischen Spektralverhaltens von Oberflächen ist durch den Einsatz von Hyperspektralsensoren möglich. Allerdings stellt die Klassifikation von landwirtschaftlichen Kulturen weiterhin eine Herausforderung dar, die in erster Linie auf das sehr ähnliche spektrale Verhalten der Kulturen zurückzuführen ist. Darüber hinaus kann die hohe Datendimensionalität als Problem (Hughes Phänomen) benannt werden (PAOLETTI *et al.* 2018).

Ein Klassifikationsverfahren, das besonders in den letzten Jahren an Aufmerksamkeit gewonnen hat, ist das *Convolutional Neural Network* (CNN). CNNs bilden einen speziellen Typ der weit verbreiteten tiefen Lernalgorithmen (*Deep Learning Models*) und zeichnen sich besonders durch gute Ergebnisse bei komplexen nichtlinearen Problemstellungen aus. Anwendungen zeigen sich im Besonderen in der Bildklassifikation, wobei auch erste Arbeiten das Potenzial eindimensionaler CNNs für die pixel-basierte Klassifikation hyperspektraler Fernerkundungsdaten darlegten (CHEN *et al.* 2016, HU *et al.* 2015, PAOLETTI *et al.* 2018). Die Klassifikation über CNNs besteht aus zwei Verfahren: der Merkmalsextraktion sowie der anschließenden eigentlichen Klassifikation. Die Extraktion wichtiger Merkmale über die spektrale Reflektanz ermöglicht hierbei in direkter Weise die genannte Dimensionsproblematik bei Hyperspektraldaten zu reduzieren.

Bislang wurden vergleichsweise wenige Studien im Bereich der monotonalen Klassifikation landwirtschaftlicher Kulturen über CNNs unter Berücksichtigung der spektralen Informationen durchgeführt. HU *et al.* (2015) und CHEN *et al.* (2016) zeigten am Beispiel der frei verfügbaren Hyperspektraldatensätze *Indian Pines* und *Salinas* die gute Trennbarkeit zahlreicher Nutzpflanzen auf Basis eindimensionaler CNNs. In Bezug auf die Differenzierung von spektral sehr ähnlichen Klassen wie Getreide- oder Grünlandarten (WILSON *et al.* 2014), die häufige Anbaukulturen der Landwirtschaft im deutschen Raum darstellen (DESTATIS 2018), liegen vergleichsweise wenige Studien vor.

Das Ziel der vorliegenden Studie war daher die pixelbasierte Klassifikation eines hyperspektralen Datensatzes des AisaDUAL-Sensors zur Identifikation landwirtschaftlicher Kulturen. Hierbei sollte die Eignung eines pixelbasierten CNNs für die Klassifikation spektral sehr ähnlicher Kulturen überprüft und diskutiert werden.

2 Untersuchungsgebiet und Datengrundlage

Das Untersuchungsgebiet befand sich in Sachsen-Anhalt (Deutschland), nahe der Stadt Köthen. Das zu untersuchende Gebiet umfasste insgesamt eine Fläche von ungefähr 84 km². Aufgrund zumeist nährstoffreicher Böden (Löss) sowie dem gemäßigten Klima werden die Flächen fast ausschließlich landwirtschaftlich genutzt, wobei der Schwerpunkt auf einer intensiven Acker- und Grünlandnutzung liegt. Zum Zeitpunkt der Arbeit überwog die Nutzung durch Getreideanbau.

Als Datengrundlage für die Klassifikation dienten flugzeuggestützte Hyperspektraldaten des AisaDUAL-Sensors vom 24.05.2012. Die Bilddaten wiesen eine räumliche Auflösung von 3 Metern pro Pixel auf, wobei das spektrale Signal zwischen 400 und 2.500 nm aufgenommen wurde. Die Bilddaten waren geometrisch und radiometrisch vorprozessiert, wobei letztendlich durch das Zusammenführen benachbarter Kanäle (*Binning*) sowie durch das Entfernen rauschbehafteter Signalbereiche (400–430 nm und 2.390–2.500 nm) insgesamt 98 Kanäle für die Analysen verblieben (SIEGMANN 2016).

Für die Kalibrierung sowie der Validierung der Klassifikation wurde auf Felddaten des Integrierten Verwaltungs- und Kontrollsystems (InVeKoS) zurückgegriffen. Inhalt dieser Daten war die Information zur jeweiligen Anbaukultur im Untersuchungsgebiet zum Zeitpunkt der Befliegung.

3 Methodik

Für die Analyse der Bilddaten wurden unbedeckte Flächen, urbane Räume sowie Kulturen, die nur durch wenige oder kleine Flächen im Untersuchungsgebiet repräsentiert wurden, aus der Klassifikation ausgeschlossen. Eine ausreichende Anzahl an Flächen für jede Kulturart ist in Bezug auf die Kalibrierung sowie die Validierung der Ergebnisse von großer Relevanz. Insgesamt ergaben sich für das Untersuchungsgebiet sieben unterschiedliche Kulturarten, deren Häufigkeiten in der **Tabelle 1** dargestellt sind.

Tabelle 1: Zu klassifizierende Kulturarten sowie deren Vorkommen im Untersuchungsgebiet nach Anzahl der Pixel und Felder im Hyperspektraldatensatz

	Hartweizen	Winterweizen	Winterroggen	Winterraps	Wintergerste	Wiesen	Weiden
Anzahl der Pixel	4186	202050	8730	90352	54187	10661	8545
Anzahl der Felder	7	156	8	63	41	32	18

In der methodischen Umsetzung der Klassifikation wurde zunächst ein *Resampling* der Bilddaten auf eine räumliche Auflösung von 10 m pro Pixel vorgenommen. Hierdurch ließen sich spektral sehr unterschiedliche Ausprägungen innerhalb einzelner Kulturarten insgesamt reduzieren, wodurch sich die Trennbarkeit der Klassen verbesserte. Für das

Training und die Validierung der Klassifikation wurden die landwirtschaftlichen Felder auf Basis der vorliegenden InVeKoS-Daten aufgeteilt. Dabei wurden für jede Kulturart zwei Drittel der Felder für die Kalibrierung und ein Drittel für die Validierung verwendet.

Die Qualität der überwachten Klassifikation wird maßgeblich von der Auswahl der Trainingsgebiete beeinflusst. Daher wurden aus den Trainingsdaten für eine jeweilige Klasse (Kulturart) manuell 2000 möglichst homogene und repräsentative Pixel ausgewählt. Für die Validierung wurden zufällig 1000 Pixel pro Klasse aus den Validierungsdaten entnommen, sodass insgesamt eine gleichverteilte Anzahl für alle Klassen vorlag.

Die Klassifikation der Kulturarten erfolgte auf Basis einer CNN-Architektur. Die Funktionsweise der CNNs basiert in Grundzügen auf dem Schichtenmodell künstlicher neuronaler Netze (ATKINSON & TATNALL 1997). So funktionieren CNNs als vorwärtsgerichtete Netze, welche sich durch sogenannte *Convolutional* und *Pooling Layer* auszeichnen. Diese können paarweise verwendet und beliebig oft wiederholt werden (CHEN *et al.* 2016). Neuronen der *Convolutional Layer* zeichnen sich durch lokale Verbindungen zur vorausgehenden Schicht aus (HU *et al.* 2015). Die Eingabe eines Neurons berechnet sich dabei in der Folge über sogenannte Filterkernel, die sich in Abhängigkeit ihrer Filtergröße über die Eingabe bewegen und charakteristische Merkmale in Form von Filterschichten extrahieren. In der vorliegenden Studie wurden anhand der *Convolutional Layer* besondere Merkmale aus den Spektren der Trainingspixel erzeugt. Da die Gewichte der Filterkernel für jede Filterschicht gleich sind, müssen insgesamt weniger Parameter gelernt werden als in klassischen Neuronalen Netzen. *Pooling Layer* verstärken diesen Prozess, indem sie die extrahierten Informationen in ihrer Dimension reduzieren und lediglich deutliche Merkmale erhalten. Damit lässt sich die Rechenkomplexität des Netzes deutlich reduzieren (HU *et al.* 2015). Über die mehrfache Anwendung von *Convolutional* und *Pooling Layer* können die Informationen zunehmend aggregiert und der Datenraum hierdurch reduziert werden. Die Klassifikation erfolgte abschließend über die Anwendung einfacher neuronaler Layer.

Die verwendete Architektur setzte sich aus insgesamt drei *Convolutional Layer* und jeweils drei nachfolgenden *Max Pooling Layer* zusammen. Letzteres stellt eines der am häufigsten angewendeten Pooling-Verfahren dar. Die *Max-Pooling*-Funktion gibt grundsätzlich den Maximalwert der betrachteten Teilregion der Eingabe zurück (HU *et al.* 2015). Für die Skalierung der Ausgangswerte wurde die Aktivierungsfunktion *ReLU* genutzt, wodurch negative Ausgaben der Neuronen auf null gesetzt wurden. Zur Reduzierung einer zu starken Anpassung des Netzes an die Trainingsdaten wurden *Dropouts* verwendet. *Dropouts* verhindern die Ausgabe von schwachen Neuronen, sofern ein bestimmter Schwellwert nicht erreicht wird (LEE & KWON 2017). Das Training des Netzes erfolgte mit einer Lernrate von 0,01 bei 100 Wiederholungen. Die komplette Architektur des CNNs veranschaulicht **Abbildung 1**.

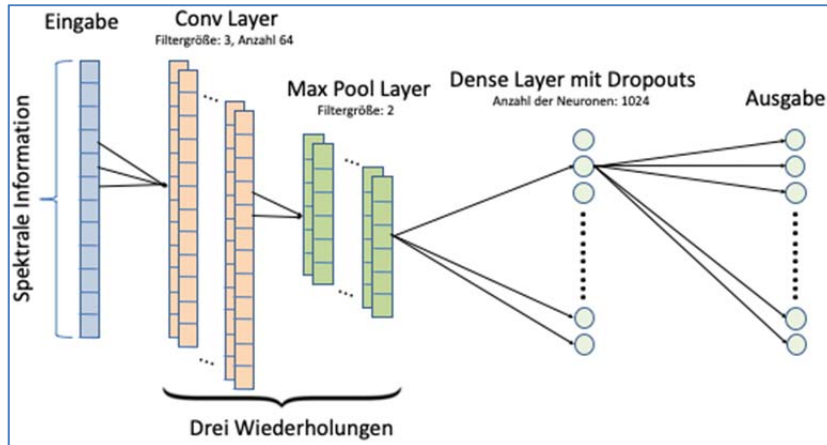


Abbildung 1: Angewandte CNN-Architektur

Das übergeordnete Ziel dieser Arbeit war die Identifizierung der Kulturart jeder landwirtschaftlich genutzten Fläche. Aus diesem Grund wurde ein post-klassifiktiver Ansatz entwickelt, der auf Basis des Klassifikationsergebnisses und der Feldgrenzen aus den InVeKoS-Daten über eine Mehrheitsentscheidung die Zuweisung einer Klasse für ein jeweiliges Feld vornimmt. Damit wird letztendlich jedem Feld die Klasse zugewiesen, die am häufigsten innerhalb der Fläche klassifiziert wurde.

4 Ergebnisse und Diskussion

Das Ergebnis der Klassifikation ist in der **Abbildung 2** dargestellt. Wie deutlich zu erkennen ist, konnten die landwirtschaftlichen Felder überwiegend korrekt ihrer Kulturart zugewiesen werden. Die Felder wurden dabei zu großen Teilen homogen klassifiziert und wiesen nur geringfügiges Rauschen auf. Die quantitative Beurteilung der Klassifikation auf Basis der extrahierten Validierungsdaten bestätigte das gute Ergebnis (**Tabelle 2**). Mit einer Gesamtgenauigkeit von 82,6 % erreichte der CNN-Ansatz eine gute Klassifikation der landwirtschaftlichen Kulturen. Wie der **Tabelle 2** zu entnehmen ist, ließen sich jedoch für die einzelnen Kulturarten unterschiedliche Klassifikationsgüten erzielen.

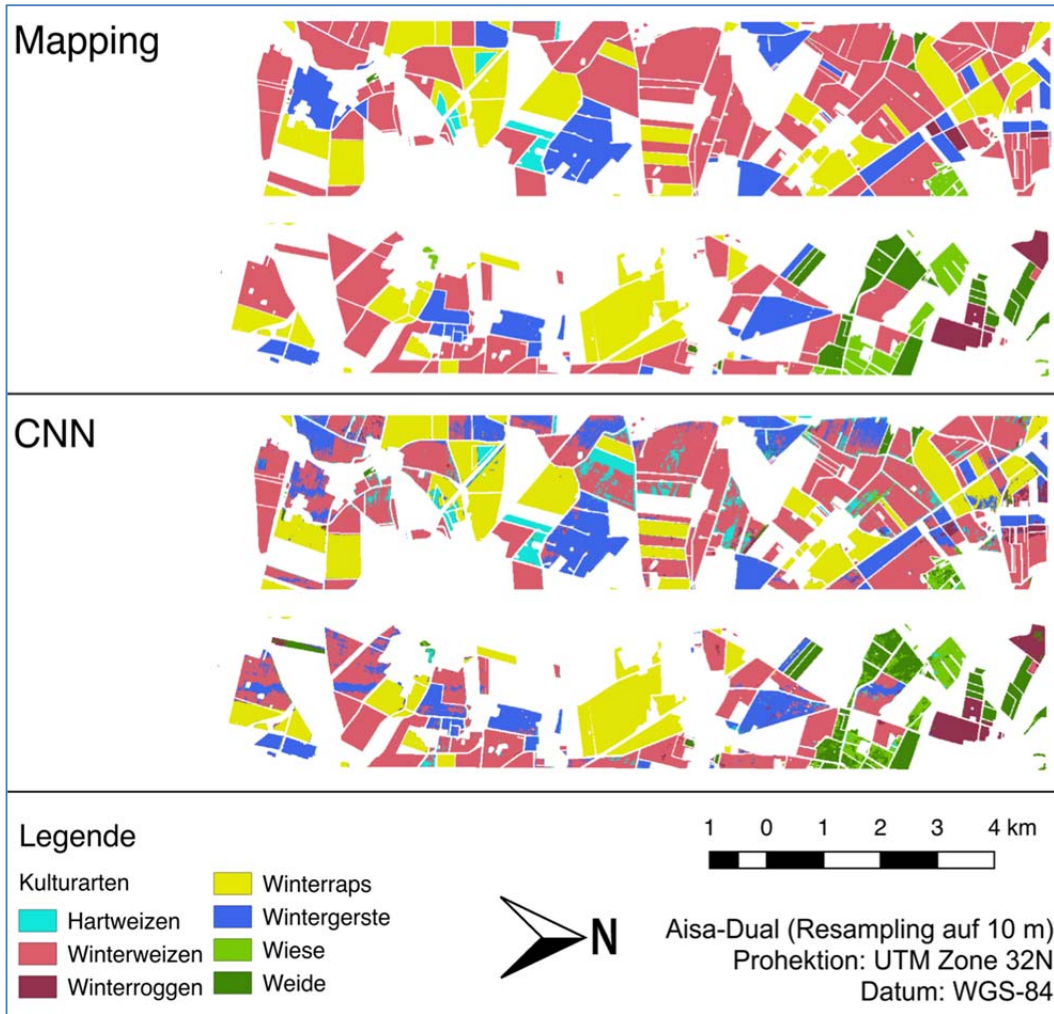


Abbildung 2: Ergebnis der CNN-Klassifikation

Auf Basis der Konfusionsmatrix war festzustellen, dass die größte Übereinstimmung für die Klasse Raps vorlag. Mit insgesamt 96,7 % korrekt klassifizierter Pixel war eine Identifikation dieser Kulturart in den meisten Fällen möglich. Fehlklassifikationen beschränkten sich überwiegend auf ein einzelnes Feld im Nordwesten des Untersuchungsgebietes.

Tabelle 2: Konfusionsmatrix (links), die Produzenten- (PA) und Nutzergenauigkeiten (UA) (rechts) sowie die feldbezogenen Genauigkeiten basierend auf dem Mehrheitsvotum (unten)

	Hartweizen	Winterweizen	Winterroggen	Winterraps	Wintergerste	Wiesen	Weiden	PA %	UA %
Hartweizen	884	30	0	9	26	26	5	88.4	90.20
Winterweizen	6	824	94	0	72	2	0	82.4	82.57
Winterroggen	6	19	825	1	7	1	0	82.5	96.04
Winterraps	68	0	0	967	1	0	0	96.7	93.34
Wintergerste	31	118	72	22	888	2	2	88.8	78.24
Wiesen	5	9	9	1	2	663	263	66.3	69.64
Weiden	0	0	0	0	4	306	730	73.0	70.19
Feldbezogene Genauigkeit	7/7	139/156	6/8	63/63	30/41	21/32	16/18		

Die Ursache für die Falschzuweisung war möglicherweise auf das mangelnde Pflanzenwachstum zurückzuführen. Über die feldspezifische Mehrheitsentscheidung wurde die Anzahl der korrekt identifizierten Felder in Abhängigkeit ihres Gesamtvorkommens im Untersuchungsgebiet bestimmt (**Tabelle 2**). Für den Raps ergab sich, dass alle Felder korrekt dieser Klasse zugewiesen werden konnten. Mit hohen Genauigkeiten konnten auch die Getreidearten zugeordnet werden. Getreidearten lassen sich in der Regel aufgrund ihrer sehr ähnlichen spektralen Ausprägung nur sehr schwer voneinander unterscheiden (WILSON *et al.* 2014). Die erreichten Genauigkeiten zwischen 82 und 88 % sind im Vergleich zu anderen Studien (NIDAMANURI *et al.* 2012, OLESIUUK *et al.* 2009) daher als sehr positiv zu bewerten. Besonders sehr ähnliche Getreidearten waren in diesen Studien nur schwer voneinander trennbar.

Ferner ergaben sich für die Klasse Winterweizen systematische Fehlzuordnungen im Osten des Untersuchungsgebietes. In Form eines schmalen Streifens wurde von Norden nach Süden die Klasse Weizen als Gerste klassifiziert. Ursprung dieses Artefaktes waren womöglich Einflüsse in der Bildvorprozessierung. Die feldspezifischen Genauigkeiten waren für die jeweiligen Getreidearten unterschiedlich. Während alle Anbauflächen mit Hartweizen korrekt identifiziert wurden, gelang für Gerste trotz einer pixelbezogenen Genauigkeit von 88 % in nur etwa drei Vierteln der Fälle eine richtige Zuordnung des Feldes. Im Fall der Gerste war dies auf die Fehlklassifikation von zumeist kleineren Flächen zurückzuführen. Für die Klassen Wiese und Weide ergaben sich zumeist sehr ähnliche spektrale Ausprägungen im Untersuchungsgebiet. Mit Genauigkeiten von über 66 bzw. 73 % ließen sich beide Klassen jedoch überwiegend korrekt klassifizieren.

5 Schlussfolgerungen und Ausblick

Die vorliegende Studie konnte zeigen, dass der vorgestellte Ansatz ein großes Potenzial für die Klassifikation landwirtschaftlicher Kulturen bietet. Besonders spektral ähnliche Kulturarten ließen sich in den meisten Fällen korrekt identifizieren. Für den praktischen Einsatz, wie beispielsweise dem Monitoring von Kulturarten im Rahmen der EU-Agrar-subsventionskontrolle, sollte mittels weiterer Studien auch mit anderen Kulturarten das Ergebnis dieser Studie überprüft werden. Außerdem ist die Anwendung von dreidimensionalen CNNs denkbar, die zusätzlich räumliche Informationen zur Trennung der Klassen berücksichtigen. Ebenso erscheint eine Durchführung des Verfahrens auf multitemporalen Daten sinnvoll, um die phänologischen Veränderungen der Kulturarten im Laufe der Anbauperiode als weitere Kriterien für die Klassifikation zu berücksichtigen.

Danksagung

Die Aufnahme der Hyperspektraldaten wurde durch die Raumfahrt-Agentur des Deutschen Zentrums für Luft- und Raumfahrt e.V. mit finanziellen Mitteln des Bundesministeriums für Wirtschaft und Technologie aufgrund eines Beschlusses des Deutschen Bundestages unter dem

Förderkennzeichen FKZ 50EE1014 gefördert. Ganz besonders möchten wir uns bei Dr. Bastian Siegmann für die Vorverarbeitung der Bilddaten bedanken.

Literaturverzeichnis

- ATKINSON P.M. & TATNALL A.R.L. (1997):** Introduction neural networks in remote sensing. *International Journal of Remote Sensing*. 18(4): 699–709.
- CHEN Y., JIANG H., LI C., JIA X., & GHAMISI P. (2016):** Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*. 54(10): 2094–2107.
- DESTATIS (2018):** Feldfrüchte und Grünland. Zugriff unter: <https://www.destatis.de/DE/ZahlenFakten/Wirtschaftsbereiche/LandForstwirtschaftFischerei/FeldfruechteGruenland/FeldfruechteGruenland.html#Tabellen> (abgerufen am 18.02.2019).
- EUROPÄISCHE KOMMISSION (2007):** Fact Sheet. Umsichtige Verwaltung des Agrarhaushalts. Generaldirektion Landwirtschaft und ländliche Entwicklung. Zugriff unter: https://ec.europa.eu/agriculture/sites/agriculture/files/publi/fact/clear/2007_de.pdf (abgerufen am 18.02.2019).
- HU W., HUANG Y., WEI L., ZHANG F. & LI H. (2015):** Deep convolutional neural networks for hyperspectral image classification. *Journal of Sensors*. 2015(2): 1–12.
- LANDWIRTSCHAFTSKAMMER NORDRHEIN-WESTFALEN (2017):** Wochenblatt für Landwirtschaft und Landleben Kompakt. Ratgeber Förderung. Zugriff unter: <https://www.landwirtschaftskammer.de/foerderung/pdf/ratgeber-foerderung-2017wl.pdf> (abgerufen am 18.02.2019).
- LEE H. & KWON H. (2017):** Going deeper with contextual cnn for hyperspectral image classification. *IEEE Trans. Image Processing*. 26(10): 4843–4855.
- NIDAMANURI R.R., & ZBELL B. (2012):** Existence of characteristic spectral signatures for agricultural crops - Potential for automated crop mapping by hyperspectral imaging. *Geocarto International*. 27(2): 103–118.
- OLESIUK D., BACHMANN M., HABERMEYER M., HELDENS W. & ZAGAJEWSKI B. (2009):** Crop classification with neural networks using airborne hyperspectral imagery, *Roczniki Geomatyki*. 7(32): 107–112.
- PAOLETTI M., HAUT J., PLAZA J. & PLAZA A. (2018):** A new deep convolutional neural network for fast hyperspectral image classification. *Journal of Photogrammetry and Remote Sensing*. 145(A): 120–147.
- SIEGMANN B. (2016):** Hyperspectral remote sensing for winter wheat leaf area index assessment in precision agriculture. PhD thesis, 148 pages.
- WILSON J.H., ZHANG C. & KOVACS J.M. (2014):** Separating crop species in northeastern Ontario using hyperspectral data. *Remote Sensing*. 6(2): 925–945.

Quantifying of Wheat Resistance to *Fusarium* Head Blight with Hyperspectral Imaging

Bewertung der Resistenz von Weizen gegenüber der partiellen Taubährigkeit mittels hyperspektraler Imaging Technologien

Elias Alisaac¹, Jan Behmann¹, Matheus T. Kuska¹, Heinz-W. Dehne¹,
Anne-Katrin Mahlein^{1,2}

¹*Institute of Crop Science and Resource Conservation (INRES),
Plant Diseases and Plant Protection, Rheinische Friedrich-Wilhelms Universität Bonn,
Nussallee 9, 53115 Bonn*

²*Institute of Sugar Beet Research (IfZ), Holtenser Landstraße 77, 37079, Göttingen
E-Mail: alisaac@uni-bonn.de*

Zusammenfassung: Die Anfälligkeit von Weizen gegenüber Ährenfusariosen (*Fusarium* Head Blight, FHB) unterscheidet sich je nach Weizensorte, *Fusarium*-Art, Pilzisolat und Wetterbedingungen. Für die Charakterisierung und Bewertung von Krankheiten wird eine objektive Methode verlangt. Daher wurden Hyperspektralsensoren in einem automatisierten Verfahren verwendet, um die FHB-Empfindlichkeit Weizensorten für im sichtbaren Nahinfrarot (VIS-NIR, 400–1000 nm) und im Kurzwellen-Infrarot (SWIR, 1000–2500 nm) zu phänotypisieren. Mit diesem System wurden die optischen Reflektanzeigenschaften von mit *F. graminearum* oder *F. culmorum* infizierten Ähren in Zeitreihenversuchen aufgezeichnet. Spektrale Vegetationsindizes (SVIs) wurden aus diesen abgeleitet und mit dem Schweregrad der Erkrankung (DS) korreliert. Basierend auf dem mittleren Reflexionsspektrum oder den SVIs der Spitzen wurde ein SVM-Klassifikator (*Support Vector Machine*) angewendet. Im Hinblick auf das Sorten-Ranking wurde die Fortschrittskurve für den Bereich „*Under Disease*“ (AUDPC) mit einem vollautomatisierten Ansatz unter Verwendung des nicht-metrischen *Multi-Dimensional Scaling* (NMDS) verglichen. Der Schweregrad der Erkrankung korrelierte stark mit der spektralen Signatur bei 430 bis 525 nm, 560 bis 710 nm und 1115 bis 2500 nm. Darüber hinaus zeigten SVIs eine hohe Korrelation mit DS. Die SWIR erwies sich als empfindlich für FHB, was durch die Indizes NDNI, CAI und MSI angezeigt wird. Der SVM-Klassifikator erreichte eine hohe Genauigkeit > 76%, bei der Trennung von gesunden und infizierten Ähren und von mit *F. graminearum* und mit *F. culmorum* infizierten Ähren zu unterscheiden. Die Studie zeigt die Möglichkeit auf, hyperspektrale Bildgebung zu verwenden, um Weizensorten mit dem NMDS-Ansatz genau und automatisch zu phänotypisieren.

Deskriptoren: Weizen, *F. graminearum*, *F. culmorum*, Phänotypisierung, Hyperspektralphotometrie, spektrale Signatur, Spektrale Vegetationsindizes (SVIs)

Abstract: Susceptibility of wheat to *Fusarium* head blight (FHB) differs according to wheat variety, *Fusarium* species, fungal isolate and weather conditions. For disease characterization and rating, an objective method is demanded. Therefore, hyperspectral sensors were used to develop an automated method to phenotype wheat varieties to FHB susceptibility in the visible-near infrared (VIS-NIR, 400–1000 nm) and shortwave-infrared (SWIR, 1000–2500 nm). The optical properties of spikes infected with *F. graminearum* or *F. culmorum* were recorded in time-series experiments. Spectral vegetation indices (SVIs) were derived from reflectance data and correlated to Disease Severity (DS). A Support vector machine (SVM) classifier was used based on the mean spectral reflectance or SVIs of the spikes. For variety ranking, Area Under Disease Progress Curve (AUDPC) was compared with a fully-automated approach using Non-metric Multi-Dimensional Scaling (NMDS). The disease severity was highly correlated to the spectral signature in 430–525 nm, 560–710 nm and 1115–2500 nm. In addition, SVIs showed high correlation with DS. The SWIR showed to be sensitive for FHB indicated by the indices NDNI, CAI and MSI. The SVM classifier showed high accuracy (acc. > 0.76) to differentiate between healthy and infected spikes and between *F. graminearum* and *F. culmorum* infected spikes. The study indicates the possibility to use hyperspectral imaging to phenotype wheat varieties accurately and automatically using the NMDS approach.

Keywords: Wheat, *F. graminearum*, *F. culmorum*, Phenotyping, Hyperspectral imaging, Spectral signature, Spectral vegetation indices (SVIs), Support Vector Machine (SVM), Area Under Disease Progress Curve (AUDPC), Non-metric multidimensional scaling (NMDS).

1 Introduction

Fusarium head blight (FHB) is one of the main wheat diseases, not only because of yield loss resulted from the infection but also because that the infected kernels are shrunken with poor technological qualities (JOHNSON *et al.* 2003; McMULLEN *et al.* 2012; SALGADO *et al.* 2015; KREUZBERGER *et al.* 2015). Additionally, these kernels are contaminated with mycotoxins produced by the fungus during pathogenicity. The main mycotoxins resulted from *Fusarium* infection are trichothecenes, especially deoxynivalenol (DON) and its acetylated derivatives as well as zearalenone, fusaric acid and enniatins (BIRZELE *et al.* 2002; FERRIGO *et al.* 2016). More than 17 *Fusarium* species could be involved in *Fusarium* infection. However, the main species are *Fusarium graminearum*, *F. culmorum*, *F. poae*, *F. avenaceum* (PARRY *et al.* 1995; O'DONNELL *et al.* 2004; AOKI *et al.* 2014).

The pathogen overwinters in the debris of the former crop. The infection starts during the anthesis of wheat spikes which is the most susceptible stage for *Fusarium* infection. The favorable weather conditions are 100% relative humidity (RH) and warm temperature >25° (BUSHNELL *et al.* 2003; OSBORNE & STEIN 2007). The main symptoms on in-

fectured spikelets are water-soaked spots, chlorophyll decomposition and bleached spikelets in the last stage of infection (TRAIL 2009).

Effective management of FHB can be achieved by combining different control measures e.g. crop rotation, biological control or fungicides application (GILBERT & HABER 2013). Breeding resistant wheat varieties contribute substantially to the integrated control of FHB (DWEBA *et al.* 2017). However, the phenotyping process is a limiting factor in plant breeding, because it is laborious and cost intensive (MAHLEIN 2016). In the case of FHB, phenotyping is challenging because *Fusarium* species can infect the wheat spikes without visual symptoms. For this, optical sensors are a helpful.

This study was designed to develop a non-invasive method to quantify wheat resistance to FHB using hyperspectral imaging (HSI).

2 Material and Methods

The experiments have been performed under greenhouse conditions using seven wheat varieties differing in their resistance to FHB: (1–9 scale where 1 is highly resistant and 9 is highly susceptible): Thasos (3), Triso (4), Passat (4), Scirocco (4), Chamsin (5), Taifun (6) and Sonett (6). Two *Fusarium* species have been used in the inoculation *Fusarium graminearum*, isolate S.19, and *F. culmorum*, isolate 3.37. The inoculation has been done at anthesis stage by spraying the spore suspension (10^5 conidia mL⁻¹) on the spikes followed by incubating the plants for 48 h at 22–25°C and 95% RH.

Visual assessment for disease severity has been done at 4, 6, 8, 10, 13, 17, 21 and 30 days after inoculation (dai) according to the following formula:

$$\text{disease severity} = \frac{\text{symptomatic area of the spike}}{\text{whole area of the spike}} * 100$$

Time series hyperspectral images have been taken to the spikes in a dark room in the visible near-infrared range (VIS-NIR 400–1000 nm) and the shortwave infrared range (SWIR 1000–2500 nm). The open source software HSVaP (“Hyperspectral Visualization and Processing”) <https://github.com/janBehmann/HSVAP> was used to mask and visualize the image data of each spike. The mean spectral reflectance of the spikes was done in MATLAB 2013a. Fifteen spectral vegetation indices (SVIs) were calculated from the spectral reflectance of each spike in the VIS-NIR and SWIR ranges.

Support vector machine (SVM) approach has been used for two class classification (healthy/infected) and multiclass classification (healthy / *F. graminearum* / *F. culmorum*) using SVIs and the entire spectral reflectance inputs for the classifier.

Non-metric multidimensional scaling (NMDS) was used to reduce the information of the relevant vegetation indices in a one-dimensional ordinal scale. This scale represents the disease severity sensed by the hyperspectral camera.

3 Results

Visible symptoms of FHB started 4 dai and developed gradually. Severe symptoms have been shown 4 dai on Scirocco inoculated with *F. graminearum*. A gradual increase in disease symptoms has been observed in moderately resistant varieties, while these symptoms increased rapidly in susceptible ones. In general, disease symptoms of *F. graminearum* were higher than *F. culmorum* in all tested varieties.

All varieties showed identical spectral signature of control spikes along the electromagnetic spectrum until 21 dai. Due to the natural senescence, an increase in the spectral reflectance of control spikes could be observed starting from 21 dai. The differences in the spectral reflectance of infected spikes of different varieties could be observed starting from 4 dai. These differences were more pronounced in the spectral range 460–670 nm and along the SWIR. Susceptible varieties showed higher reflectance compared with resistant ones along the electromagnetic spectrum.

Positive correlation of $r > 0.75$ has been shown between disease severity and the spectral reflectance in the VIS and SWIR ranges. While in the NIR range, negative correlation of $r < -0.6$ was observed. Moreover, the fifteen investigated vegetation indices showed a high correlation with disease severity until 21 dai.

Fusarium infection affected the spikes weight at harvest. This effect was more pronounced in the case of *F. graminearum* infected spikes compared with *F. culmorum* infected ones. SVIs showed a gradual increase in correlation with spike weight at harvest until 13 dai and 21 dai. Using SVM, it was possible to discriminate healthy and *Fusarium*-infected spikes using SVIs as an input for the classifier. Classification accuracy increased overtime until 17 dai. Afterward, classification accuracy decreased due to the natural senescence in control spikes.

Seven SVIs highly correlated to disease severity from VIS-NIR and SWIR ranges were projected by NMDS to a one-dimensional ordinal scale. This scale refers to disease severity sensed by the hyperspectral cameras. Comparison between disease severity calculated as the area under disease progress curve (AUDPC) and as NMDS showed that the ranking of most varieties stayed in the same position either based on AUDPC or NMDS.

4 Discussion

The main symptoms of *Fusarium* head blight are chlorosis and disruption in the water system of the infected spike. The severity of these symptoms is based on *Fusarium* pathogen and the resistance of the host plant (TRAIL 2009; HA *et al.* 2016). Previous studies proved the feasibility of hyperspectral imaging to assess symptoms caused by fungal pathogens (BAURIEGEL *et al.* 2011, DELALIEUX *et al.* 2009, MAHLEIN 2010). The spectral signature in the VIS-NIR and SWIR ranges refers to the plant pigments, tissue structure and water content of the plant (MAHLEIN 2018). In the current study, the spectral signature of the spikes was affected according to the resistance of the variety to

FHB. The spectral reflectance of the susceptible varieties was higher than resistant ones along the entire spectral signature. This is due to the chlorosis, collapse in tissue structure and disruption in the water content of the spikes.

MAHLEIN *et al.* (2010) showed that the correlation between disease severity and the spectral reflectance differs according to the symptoms caused by the fungus. MERZLYAK *et al.* (1999) proved that the increase in the spectral reflectance in the spectral ranges 400–530 nm and 550–740 nm resulted from chlorophyll decomposition in plant tissue. This is in accordance with the results of the current study that proved a high correlation between disease severity and the spectral reflectance in the VIS-NIR range as well as with the SVIs derived from these ranges. The spectral bands in the SWIR ranges refer to the water content of the plant (MAHLEIN *et al.* 2018). Early senescence is one of the main symptoms resulted from FHB infection accompanied by loss of the water content of the spikes (TRAIL 2009). This explains the high correlation between disease severity and spectral reflectance and SVIs in the SWIR range proved in this study. RUMPF *et al.* (2010) used the spectral reflectance as an input for SVM approach to discriminate different sugar beet diseases. In the current study, it was possible to discriminate healthy and *Fusarium*-infected wheat spikes based on the SVIs of the spikes with high accuracy. The decrease in accuracy during the advanced stages of pathogenicity is due to the natural senescence of the control spikes. The conventional rating method of plant disease severity depends on AUDPC which transfers several observations of disease severity into one value (SIMKO & PIEPHO 2012). In this study, it was possible to reproduce AUDPC with high accuracy by transferring several SVIs into one value using NMDS.

The main output of this study is the automated method to produce AUDPC based on SVIs derived from VIS-NIR and SWIR ranges.

References

- AOKI T., O'DONNELL K. and GEISER D. M. (2014):** Systematics of key phytopathogenic *Fusarium* species: Current status and future challenges. *Journal of General Plant Pathology*, 80, 189–201.
- BAURIEGEL E., GIEBEL A., GEYER M. SCHMIDT, U. and HERPPICH W. B. (2011):** Early detection of *Fusarium* infection in wheat using hyper-spectral imaging. *Computer and Electronics in Agriculture*, 75, 304–312.
- BIRZELE B., MEIER A., HINDORF H., KRÄMER J., and DEHNE H.-W. (2002):** Epidemiology of *Fusarium* infection and deoxynivalenol content in winter wheat in the rhineland, Germany. *European Journal of Plant Pathology*, 108, 667–673.
- BUSHNELL W. R. HAZEN B. E. and PRITSCH C. (2003):** Histology and physiology of *Fusarium* head blight. In K. J. Leonard and W. R. Bushnell (Ed.), *Fusarium Head Blight of Wheat and Barley* (pp. 44–83): St. Paul, Minnesota: APS Press.
- DELALIEUX S., SOMERS B., VERSTRAETEN W. W., VAN AARDT J. A. N., KEULEMANS W., AND COPPIN P. (2009):** Hyperspectral indices to diagnose leaf biotic stress of apple plants, considering leaf phenology. *International Journal of Remote Sensing*, 30, 1887–1912.

- DWEBA C. C., FIGLAN S., SHIMELIS H. A., MOTAUNG T. E., SYDENHAM S., MWADZINGENI L., and TSILO T. J. (2017):** *Fusarium* head blight of wheat: Pathogenesis and control strategies. *Crop Protection*, 91, 114–122.
- FERRIGO D., ALESSANDRO RAIOLA A. and ROBERTO R. (2016):** *Fusarium* toxins in cereals: occurrence, legislation, factors promoting the appearance and their management. *Molecules*, 21, 627.
- GILBERT, J. AND HABER, S. (2013):** Overview of some recent research developments in *Fusarium* head blight of wheat. *Canadian Journal of Plant Pathology*, 35, 149–174.
- HA X., KOOPMANN B. AND VON TIEDEMANN A. (2016):** Wheat blast and *Fusarium* head blight display contrasting interaction patterns on ears of wheat genotypes differing in resistance. *Phytopathology*, 106, 270–281.
- JOHNSON D. D., FLAKERUD G. K., TAYLOR R. D. and SATYANARAYANA V. (2003):** Quantifying economic impacts of *Fusarium* head blight in wheat. In K. J. Leonard and W. R. Bushnell (Ed.), *Fusarium Head Blight of Wheat and Barley* (pp. 461–484): St. Paul, Minnesota: APS Press.
- KREUZBERGER M., LIMSUWAN S., EGGERT K., KARLOVSKY P. and PAWELZIK, E. (2015):** Impact of *Fusarium* spp. infection of bread wheat (*Triticum aestivum* L.) on composition and quality of flour in association with EU maximum level for deoxynivalenol. *Journal of Applied Botany and Food Quality*, 88, 177–185.
- MAHLEIN A.-K., STEINER U., DEHNE H.-W. and OERKE, E.-C. (2010):** Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. *Precision Agriculture*, 11, 413–431.
- MAHLEIN A.-K. (2016):** Present and future trends in plant disease detection. *Plant Disease*, 100, 241–251.
- MAHLEIN A. K., KUSKA M. T., BEHMANN J., POLDER G., WALTER, A. (2018):** Hyperspectral sensors and imaging technologies in phytopathology: state of the art. *Annual Review of Phytopathology*, 56, 535–558.
- McMULLEN M., BERGSTROM G., DE WOLF E., DILL-MACKY R., HERSHMAN D., SHANER G., and VAN SANFORD, D. (2012):** A unified effort to fight an enemy of wheat and barley: *Fusarium* head blight. *Plant Disease*, 96, 1712–1728.
- Merzlyak M. N., Gitelson A. A., Chivkunova O. B., and Rakitin V. Y. (1999):** Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiologica Plantarum*, 106, 135–141.
- O'DONNELL K., WARD T. J., GEISER D. M., KISTLER H. C. and AOKI T. (2004):** Genealogical concordance between the mating type locus and seven other nuclear genes supports formal recognition of nine phylogenetically distinct species within the *Fusarium graminearum* clade. *Fungal Genetics and Biology*, 41, 600–623.
- OSBORNE L. M., and STEIN J. M. (2007):** Epidemiology of *Fusarium* head blight on small-grain cereals. *International Journal of Food Microbiology*, 119, 103–108.
- PARRY D. W., JENKINSON P., and McLEOD L. (1995):** *Fusarium* ear blight (scab) in small grain cereals—a review. *Plant Pathology*, 44, 207–238.

RUMPF T., MAHLEIN A.-K., STEINER U., OERKE E.-C., DEHNE H.-W., and PLÜMER L. (2010): Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. *Computers and Electronics in Agriculture*, 74, 91–99.

SALGADO J. D., MADDEN L. V., and PAUL P. A. (2015): Quantifying the effects of *Fusarium* head blight on grain yield and test weight in soft red winter wheat. *Phytopathology*, 105, 295–306.

Simko I., and Piepho H.-P. (2012): The Area Under the Disease Progress Stairs: Calculation, Advantage, and Application. *Phytopathology*, 102, 381–389.

TRAIL F. (2009): For blighted waves of grain: *Fusarium graminearum* in the postgenomics era. *Plant Physiology*, 149, 103–110.

Hyperspektrale Erfassung eines mit unterschiedlichen Wirtschaftsdüngern aus Miscanthus-Häckselgut versorgten Wintergerstenbestandes zum Zeitpunkt der Vollreife

Hyperspectral assessment of winter barley, after the fertilization of different farm manures, based on chopped-miscanthus, at the time of full maturity

Michael Stotter^{1,2}, Martin Hamer¹, David Bohnenkamp³, Jan Behmann³,
Kevin Leitenberger⁴, Ralf Pude^{2,4}

¹*Internationales Zentrum für Nachhaltige Entwicklung, Hochschule Bonn-Rhein-Sieg,
Grantham-Allee 20, 53757 Sankt Augustin*

²*Institut für Nutzpflanzenwissenschaften und Ressourcenschutz, Nachwachsende Rohstoffe,
Rheinische Friedrich-Wilhelms-Universität Bonn, Klein-Altendorf 2, 53359 Rheinbach*

³*Institut für Nutzpflanzenwissenschaften und Ressourcenschutz, Pflanzenkrankheiten und
Pflanzenschutz, Rheinische Friedrich-Wilhelms-Universität Bonn, Nussallee 9, 53115 Bonn*

⁴*Außenlabore Campus Klein-Altendorf, Rheinische Friedrich-Wilhelms-Universität Bonn,
Klein-Altendorf 2, 53359 Rheinbach
E-Mail: michael.stotter@uni-bonn.de*

Zusammenfassung: Hinsichtlich der regional hohen N-Eintragungsmengen durch die Landwirtschaft sowie der bevorstehenden erneuten Verschärfung der Düngeverordnung, ist die Kenntnis über die Dynamik der N-Mineralisierung verschiedener Wirtschaftsdünger unerlässlich. Insbesondere bei der Etablierung neuartiger organischer N-Dünger ist deren Umweltwirkung, namentlich die der reaktiven Stickstoffverbindungen, von größter Relevanz. Damit zukünftig kosten- und zeitintensive destruktive Bonituren durch nicht invasive ersetzt werden können, bedarf es der Erprobung und Validierung der sensorbasierten Methodik. Dazu werden im Rahmen des INTERREG-Projektes „food pro.tec.ts“ verschiedene Wirtschaftsdünger, vor allem aus *Miscanthus*-Häckselgut, in einem Feldversuch mit Wintergerste appliziert und die N-Aufnahmemenge erfasst. Eine einmalige Hyperspektralmessung im Wellenlängenbereich von 500 nm bis 900 nm, mittels einer Drohne zum Zeitpunkt der Vollreife, dokumentiert den Zustand des Bestandes. Mithilfe zweier Indizes lassen sich kurz vor der Ernte noch Unterschiede zwischen einigen Varianten erkennen und auf den N-Versorgungszustand schließen.

Deskriptoren: Hyperspektralkamera, Stickstoffversorgung, Präzisionslandwirtschaft

Abstract: *With regard to the regional high quantity of nitrogen-input by farmers as well as by further tightening of the new fertilizer regulation, the knowledge about the dynamic of nitrogen mineralization of organic manures are essential. Especially, in the*

establishment of new organic nitrogen fertilizers, their environmental impact, in particular, the reactive nitrogen compounds, have great relevance. For the replacement of expensive and time-consuming destructive observations by non-invasive methods, the application of sensors need to be tested and validated. Within the framework of the INTERREG-Project „food pro.tec.ts“, various farm manures, namely farm manures based on chopped-miscanthus, are tested in a field trial and the uptake of nitrogen by winter barley is measured. A hyperspectral camera was used to detect the condition of crop plants, once at the time of full maturity. The sensor covered the spectral range between 500 nm and 900 nm. Just before harvesting, differences between several variations get indicated and conclusions on their nitrogen supply can be drawn using two spectral indices.

Keywords: *hyperspectral camera, nitrogen supply, precision agriculture*

1 Einleitung

Im Zuge des Reformprozesses für die Gemeinsame Agrarpolitik (GAP) 2017 wurde *Miscanthus* als *greening*-fähige Kultur anerkannt. Als Besonderheit ist die Biomasseverwertung für stoffliche und energetische Zwecke erlaubt (LWK NRW, 2018). Damit sind eine Ausdehnung der Anbaufläche von *Miscanthus* und insbesondere eine Zunahme der innerbetrieblichen Verwertung in Form von Einstreu im Tierbereich zu erwarten. Das dadurch entstehende Produkt, ein Mist aus *Miscanthus*-Einstreu, ist bislang weder charakterisiert noch ist die Dynamik der Stickstoffmineralisierung nach Ausbringung auf Ackerkulturen bekannt. Werte zur N-Anrechenbarkeit für die Düngebedarfsermittlung fehlen ebenso wie der Einfluss auf die Stickstoffmobilität beziehungsweise -verfügbarkeit im Boden. Die derzeitige Verwendung des neuartigen Mistes findet damit ohne Kenntnis hinsichtlich seiner Umwelteinwirkungen statt und kann damit nicht nach guter fachlicher Praxis eingesetzt werden. Die bevorstehende erneute Verschärfung der Düngeverordnung von 2017, um immense Strafzahlungen an die EU wegen unzureichender Maßnahmen zum „Schutz der Gewässer und vor Verunreinigung durch Nitrat“ (EuGH, 2018) abzuwenden, zeigt die Brisanz und damit den notwendigen Erkenntnisgewinn auf (BMEL, 2019). Daher werden innerhalb dieses Feldversuches organische Wirtschaftsdünger aus Zusätzen von *Miscanthus*-Häckselgut hinsichtlich ihrer Stickstoff-Düngewirkung in der Wintergerste mit vorwiegend destruktiven Methoden untersucht. Zum Zeitpunkt der Vollreife wurden mithilfe einer Drohne und einer Hyperspektralkamera die spektralen Eigenschaften des Wintergerstenbestandes erfasst, um daraus den N-Versorgungszustand der Pflanzen abzuleiten. Zur Validierung der hyperspektralen Daten erfolgte die destruktive Bestimmung ertragsrelevanter Pflanzenparameter zum selben Zeitpunkt. Ziel ist es zum einen die hyperspektralen Daten und die konventionell erfassten Pflanzenparameter in Abhängigkeit des N-Versorgungszustandes zu bewerten und damit das Einsatzpotenzial und die Praxistauglichkeit von Hyperspektralsensoren zur Vollreife zu bestimmen. Zum anderen soll die generelle Einsatzmöglichkeit der nicht destruktiven Methode zur Identifizierung von Unterschieden zwischen den Düngevarianten zum Erntezeitpunkt erprobt werden.

2 Material und Methoden

Auf dem Campus Klein-Altendorf der Universität Bonn wurde innerhalb des EU-INTERREG-Projektes „Food Pro.tec.ts“ ein Feldversuch durchgeführt. In dem Versuch „Bodentyp Parabraunerde“ wurden vor der Wintergerstenaussaat 60 kg/ha Gesamtstickstoff (N_{ges}) verschiedener organischer Wirtschaftsdünger in dreifacher Wiederholung ausgebracht. Dies sind eine Rindergülle (RG), eine Mischung aus Rindergülle und *Miscanthus* (Verhältnis 5:1; RG-Mis), eine Mischung aus Rindergülle und gehäckseltem Weizenstroh (Verhältnis 8,5:1; RG-WS), ein Rindermist aus *Miscanthus*-Einstreu (RM-Mis) und ein Rindermist aus Weizenstroh-Einstreu (RM-WS). Zum Vegetationsbeginn wurden im darauffolgenden Frühjahr von obigen Varianten weitere 110 kg/ha N_{ges} appliziert. Die mineralisch gedüngte Variante erhielt im Herbst keine N-Gabe, hier wurden ab dem Frühjahr über drei N-Gaben 170 kg/ha N_{ges} in Form einer Ammoniumnitrat-Harnstoff-Lösung (AHL) aufgebracht. Die Nullvariante bekam keine N-Gabe (Null). Die N-Gehalte der Varianten sind der **Tabelle 1** zu entnehmen. Die Verhältnisse der Mischungen ergeben sich aus dem maximalen Aufnahmevermögen als Masseanteile von Rindergülle zu *Miscanthus* beziehungsweise gehäckseltem Weizenstroh.

Tabelle 3: N-Gehalte der applizierten Düngevarianten

	RG [kg/m ³]	RG-Mis [kg/t]	RG-WS [kg/t]	RM-Mis [kg/t]	RM-WS [kg/t]	AHL [kg/t]
N_{ges} -N	4,6	4,2	5,1	5,6	8,3	280
NH_4^+ -N	2,3	1,4	1,1	0,5	0,2	70
C/N	9	26	15	30	12	-

Von der Aussaat bis zur Ernte wurden verschiedene Bonituren der Pflanzenbiomasse durchgeführt (Pflanzenbiomasse je m², Anzahl ährentragender Halme, Pflanzenhöhe, Pflanzenchlorophyll-Gehalt mithilfe des SPAD-502, CNS-Gehalt in der Ganzpflanze). Zum Zeitpunkt der Vollreife wurde eine Drohne (Matrice 600, DJI, China) mit einer Hyperspektralkamera (Rikola, Senop, Finnland) eingesetzt, die einen Wellenlängenbereich von 500 nm bis 900 nm abdeckt. Aus den Reflexionseigenschaften des mit unterschiedlichen Wirtschaftsdüngern applizierten Wintergerstenbestandes wurde für jedes Einzelspektrum eine Mittelwertbildung durchgeführt. Diese dienten der Berechnung zweier Indizes, dem *Plant Senescence Reflectance Index* (PSRI; MERZLYAK *et al.* 1999) und dem *Normalized Difference 800/680* (ND 800/680; TUCKER 1979), die wiederum zur Interpretation der destruktiv erfassten N-Aufnahmemenge der oberirdischen Gerstenbiomasse dienen. Die Indizes sind definiert als

$$\text{PSRI} = (R_{678} - R_{500}) / R_{750}$$

$$\text{ND 800/680} = (R_{800} - R_{680}) / (R_{800} + R_{680}).$$

3 Ergebnisse

Die erste Applikation von organischen Wirtschaftsdüngern auf einem Ackerschlag nach jahrelanger mineralischer Düngung zeigte in der Tendenz die zu erwarteten Ergebnisse. Die aufgebrauchte N-Menge über AHL wurde vollständig von der Wintergerste aufgenommen. Danach folgte auf deutlich niedriger Ebene die N-Aufnahme aus der RG und mit weiterem Abstand die der Mist-Varianten, die sich mit der Ausnahme von RM-WS untereinander nicht unterscheiden.




Abbildung 1: N-Aufnahmemenge der Wintergerste nach Aufbringung verschiedener N-Düngevarianten zum Zeitpunkt der Vollreife

Die N-Aufnahme der Nullvariante war am niedrigsten (**Abbildung 1**). Durch den zum selben Zeitpunkt erfassten PSRI wird ein Unterschied in der Reflektanz zwischen der AHL-Variante und den restlichen weniger gut versorgten Parzellen deutlich (**Abbildung 2**). Die organisch gedüngten sowie die Null-Variante zeigten eine höhere Reflektanz im Vergleich zur optimal mit Stickstoffverbindungen versorgten AHL-Variante auf (**Abbildung 2**). Der *Normalized Difference 800/680* zeigt eine geringere Reflektanz. Sie ist in den AHL-Parzellen im Mittel höher, als in allen anderen, schlechter versorgten Varianten. Ein Unterschied zwischen den organisch gedüngten sowie der Null-Parzellen kann zum Zeitpunkt der Vollreife nicht mehr detektiert werden (**Abbildung 3**).




Abbildung 2: Mittelwert der Reflektanz nach dem PSRI




Abbildung 3: Mittelwert der Reflektanz nach dem Normalized Difference 800/680 (ND 800/680)




Abbildung 4: Spektren von einer mit unterschiedlichen Wirtschaftsdüngern applizierten Wintergerste zum Zeitpunkt der Vollreife

Die Spektren in **Abbildung 4** zeigen keinen typischen Verlauf, wie es von einem vitalen Blatt mit einem Peak im Wellenlängenbereich um 550 nm und einem Anstieg ab circa 690 nm bekannt ist. Vielmehr steigt das Spektrum der AHL-Variante kontinuierlich mit Zunahme der Wellenlängen an und unterscheidet sich von den restlichen Varianten durch niedrigere Reflektanz. Die Reflektanzen der organisch gedüngten sowie die der Null-Variante liegen über der der AHL-Variante. Unter diesen ist die Reflektanz der Null-Variante am niedrigsten und damit der AHL-Variante am ähnlichsten. Das Spektrum der mit RM-WS versorgten Variante ist am höchsten. Alle organisch gedüngten sowie die Null-Parzellen zeigen im Gegensatz zur AHL-Variante einen Abfall des Spektrums im Wellenlängenbereich um 645 nm.

4 Diskussion

Die unterschiedlichen N-Aufnahmemengen von Wintergerste nach der Düngung verschiedener organischer und einer mineralischen Variante resultieren aus den unterschiedlichen N-Formen der jeweiligen Varianten. AHL beinhaltet ausschließlich mineralische Stickstoffverbindungen, die im Jahr der Aufbringung vollständig pflanzenverfügbar sind. Im Gegensatz dazu liegt in organischen Wirtschaftsdüngern ein großer Teil

des Stickstoffs organisch gebunden vor. Die N-Anrechenbarkeit im Jahr der Ausbringung liegt in einer flüssigen Rindergülle um das Doppelte höher als in Festmist, womit die leicht höhere N-Aufnahmemenge der RG-Variante im Vergleich zu den festen Wirtschaftsdünger-Varianten Erklärung findet.

Eine Äquivalenz der zeitaufwändigen destruktiven Bestimmung der absoluten N-Aufnahmemenge und Hyperspektralaufnahmen konnte zum Zeitpunkt der Vollreife nicht bestätigt werden. Diese destruktiv erfasste absolute N-Aufnahme konnte mithilfe von Hyperspektralaufnahmen soweit bestimmt werden, dass durch Anwendung von Indizes Abstufungen zwischen den Varianten konstatiert wurden. Der berechnete PSRI zeigt Unterschiede im Seneszenz-Fortschritt der Pflanzen zwischen den einzelnen Varianten. MERZLYAK *et. al.* (1999) beschreibt durch den PSRI eine Abnahme der Reflektanz eines Blattes mit sinkendem Chlorophyll-Gehalt. Des Weiteren ist bekannt, dass sich der Chlorophyllgehalt im Blatt mit fortschreitender Seneszenz verringert, sowie eine höhere N-Versorgung einen späteren Eintritt in die Seneszenz bewirkt. Somit kann aus der niedrigeren Reflektanz der AHL-Parzellen eine höhere N-Versorgung abgeleitet werden. Aus den anderen Varianten lässt sich keine eindeutige Abfolge des Seneszenz-Fortschritts und damit der N-Versorgung deduzieren.

Bei Anwendung des ND 800/680 kann ebenso wie durch den PSRI ein Unterschied zwischen der AHL-Variante und den organischen Varianten und der Null-Parzellen erfasst werden. Ein wesentlicher Unterschied befindet sich in der niedrigeren Reflektanz der gut mit Stickstoff versorgten Parzellen im Vergleich zu den unterversorgten. Dies gebührt aus der höheren Reflexion besser versorgter Bestände im nahen Infrarotbereich (ab 780 nm), die beim ND 800/680 Verwendung findet. Für die Detektion der geringen Unterschiede zwischen den organisch gedüngten Parzellen, wie sie mit der destruktiven N-Bestimmung erfasst werden konnten, wird der Gerstenbestand zu weit in der Abreife fortgeschritten gewesen sein. Möglicherweise befinden sich diese Varianten auf demselben Seneszenz-Level und die Aufnahme des Spektrums hätte für eine Unterscheidung frühzeitiger erfolgen müssen. Darauf weist auch der Verlauf der Spektren aller Varianten hin (**Abbildung 4**). Diese zeigen keinen wie für ein vitales Blatt typischen Verlauf mit einem Peak bei 550 nm sowie einen starken Anstieg ab circa 690 nm. Durch eine fortgeschrittene Seneszenz werden nur noch unwesentliche Chlorophyllmengen im Gerstenblatt vorhanden gewesen sein, um diese zu detektieren und anhand dessen auf die Stickstoffversorgung schließen zu können. Vielmehr ähnelt das Spektrum das eines Bodensignals, das in der Intensität vom unterschiedlichen Biomasseaufwuchs beeinflusst wird und insbesondere in Beständen mit einem LAI < 1,5 deutlich ausfallen kann (LILIENTHAL 2013). Zudem sind die organischen Wirtschaftsdünger im Frühjahr als Stickstoffdünger oberirdisch ohne einzuarbeiten auf die Wintergerste ausgebracht worden. Eine vollständige Verrottung hat bis zur Ernte nicht stattgefunden, sodass auch diese die Spektralsignatur wesentlich beeinflusst haben müssen. Dieser Eindruck wird durch das Spektrum der Null-Variante gestärkt. Dieses Spektrum der Variante mit der geringsten Biomasse verläuft dichter am Spektrum der Variante mit der höchsten Biomassebildung als alle anderen, die sich in ihrer Biomasse aber mehr der

AHL-Variante ähneln als die Null-Variante. Die RM-WS-Variante zeigt die höchste Reflektanz. Die Ausbringung der Menge an organischer Substanz war in der RM-WS-Variante am höchsten, sodass dadurch die Reflektanz ergiebiger ausgefallen sein wird als sie durch das Bodensignal ausgeübt worden sein muss. Letztendlich sind keine hyperspektralen Aufnahmen der verschiedenen organischen Wirtschaftsdünger sowie des Bodensignals durchgeführt worden. Daher wird empfohlen, einen frühzeitigeren Termin für die hyperspektrale Erfassung eines Pflanzenbestandes unter Einbeziehung des Bodensignals sowie eingesetzter Wirtschaftsdünger vorzunehmen.

Literaturverzeichnis

- BUNDESMINISTERIUM FÜR ERNÄHRUNG UND LANDWIRTSCHAFT (BMEL) (2019):** Pressemitteilung Nr. 32 vom 01.02.2019: „Schutz des Grundwassers geht uns alle an“. <https://www.bmel.de/SharedDocs/Pressemitteilungen/2019/032-Duengeverordnung.html>.
Letzter Zugriff: 19.02.2019.
- EUROPÄISCHER GERICHTSHOF (EuGH) (2018):** Urteil des Gerichtshofs (Neunte Kammer) vom 21.06.2018, ECLI:EU:C:2018:481, Rechtssache C-543/16.
- LANDWIRTSCHAFTSKAMMER NORDRHEIN-WESTFALEN (LWK NRW) (2018):** Wegweiser Biodiversität in der Landwirtschaft. Maßnahmenblatt: Ökologische Vorrangflächen im Greening – Flächenmaßnahmen: Stilllegung, Zwischenfrucht, Leguminosen, Nachwachsende Rohstoffe. <https://www.landwirtschaftskammer.de/landwirtschaft/naturschutz/biodiversitaet/pdf/mb-oevf-flaechen.pdf>. Letzter Zugriff: 19.02.2019.
- LILIENTHAL, H. (2012):** Optische Sensoren in der Landwirtschaft: Grundlagen und Konzepte. JKI Braunschweig, Vortrag auf der Hanse-Agro Wintertagung, 3.
- MERZLYAK M.N., GITELSON A.A., CHIVKUNOVA O.B. und RAKITIN V.Y. (1999):** Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiologia plantarum*, 106(1), pp. 135–141.
- TUCKER C.J. (1979):** Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), pp. 127–150.

Erkennung und Zählung von Weizenähren mit Hilfe von bodengestützten Bildaufnahmen

Detection and counting of wheat ears by means of ground-based image acquisition

Jana Kierdorf, Laura Zabawa, Lukas Lucks, Lasse Klingbeil, Heiner Kuhlmann

Rheinische Friedrich-Wilhelms-Universität Bonn, Nußallee 17, 53115 Bonn,

E-Mail: s7jakier@uni-bonn.de

Zusammenfassung: Durch die schnell wachsende Weltbevölkerung steigt auch der Nahrungsmittelbedarf, was die landwirtschaftliche Produktion vor große Herausforderungen stellt. In dem Zusammenhang der globalen Ernährungssicherung spielt der Anbau von Weizen als eine der wichtigsten Kulturen weltweit eine entscheidende Rolle. Um den Weizenanbau nachhaltiger zu gestalten und ein präziseres Management zu ermöglichen, ist eine kontinuierliche Überwachung des Weizenpflanzenwachstums notwendig. Um dieses Verfahren zu optimieren und zu automatisieren, können Computeralgorithmen helfen. In dieser Arbeit wird eine neue Methode zur Zählung von Weizenähren präsentiert. Die Daten bestehen aus digitalen RGB-Bildern, die in den Testfeldern der Universität Bonn aus einer Höhe von 2 m aufgenommen wurden. Ein *Random Forest*-Algorithmus unterteilt Pixel in „Weizenähre“ und „Nicht-Weizenähre“. Dabei wird eine Gesamtklassifikationsgenauigkeit von 93,25 % erreicht. Anschließend werden die verbleibenden Pixel automatisiert in verbundene Komponenten gruppiert. Um eine Zählung zu realisieren, wird ein zweiter *Random Forest* Klassifikator verwendet, um diese Objekte („Ährencluster“) hinsichtlich der Anzahl der sich überschneidenden Weizenähren, die sie enthalten, zu klassifizieren. Aus dem Ergebnis kann die Gesamtzahl der Weizenähren abgeleitet werden, indem die Anzahl der Ähren pro Cluster addiert wird. Vergleiche mit Referenzdaten zeigen, dass im Durchschnitt 97 % der Weizenähren erkannt werden. Dennoch kommt es zu Abweichungen zwischen den Bildern, insbesondere in Bezug auf den Reifegrad der Weizenähren und der Menge sich überschneidender Ähren.

Schlagworte: Ährendetektion, Ährenzählung, Klassifikator, *Random Forest*

Abstract: *With the rapidly growing world population, the demand for food is also increasing, which poses great challenges for agricultural production. In the context of global food security, the cultivation of wheat, one of the world's most important crops, plays a decisive role. In order to make wheat cultivation more sustainable and to enable more precise management, continuous monitoring of wheat plant growth is necessary.*

Computer algorithms are needed to optimize and automate this process. In this work, a new method for counting wheat is developed. The database consists of digital RGB images taken from a height of 2m. A "Random Forest" algorithm divides the pixels into "wheat ear" and "non-wheat ear" pixels. An overall classification accuracy of 93.25 % is achieved. The remaining pixels are then automatically grouped into connected components. To enable counting, a second Random Forest classifier is used to classify these objects according to the number of overlapping wheat ears they contain. From the result, the total number of wheat ears can be derived by adding the number of ears per cluster. Comparisons with reference data show that on average 97 % of wheat ears are detected. Nevertheless, there are variations between the images, especially with regard to the degree of maturity of the wheat ears and the number of overlapping ears.

Keywords: Ear detection, ear counting, classifier, random forest

1 Einleitung

Motivation

Die wachsende Population stellt eine große Herausforderung für die Versorgung der Weltbevölkerung dar. Aus dem steigenden Bedarf an Nahrungsmitteln folgt nicht nur eine erhöhte Nachfrage nach unterschiedlichen Nutzpflanzen, sondern auch eine steigende Flächeninanspruchnahme. Hierbei ist der Aspekt der Nachhaltigkeit ein wichtiger Gesichtspunkt, der in Bezug auf Ertrag pro Fläche beachtet werden muss. Die Überwachung des Ertrags ist folglich eine Aufgabe für die zukünftige Versorgung der Weltbevölkerung. In dem Zusammenhang der globalen Ernährungssicherung spielt der Anbau von Weizen als eine der wichtigsten Kulturen weltweit eine entscheidende Rolle. Unter aktuellen Umständen geschieht dessen Monitoring über einzelne Proben, in denen die Weizenähren manuell gezählt werden. Daraus resultieren nicht nur ein hoher Mitarbeiterbedarf, sondern auch ein hoher Zeitaufwand, der für die Zählung benötigt wird, woraus wiederum hohe Kosten entstehen.

FRÉDÉRIC *et al.* (2012) hat sich bereits mit einer Methode der Ährenzählung basierend auf RGB-Bildern auseinandergesetzt. Sie verwendet eine Grauwertematrix, aus der sich verschiedene Maße für die Textur ableiten lassen. Mittels der MAP-Segmentierung (Maximum A Posteriori) lassen sich so die Ähren detektieren. Die Fehlklassifikationsrate liegt dabei im Mittel bei 10 %. LUMME *et al.* (2008) schätzen die Ährenanzahl mithilfe eines Algorithmus, der auf einer Voxelrepräsentation der Punktwolke basiert. Dabei werden vertikal übereinanderliegende Voxel mit einer Mindestpunktanzahl als Ähre detektiert. Aufgrund fehlender Referenzdaten ist allerdings keine quantitative Überprüfung des Verfahrens möglich.

In dieser Arbeit wird nun ein Verfahren präsentiert, mittels dessen das Monitoring mit Hilfe automatischer Bildanalyse optimiert und automatisiert wird. Die Problemstellung wird hierbei als Klassifikationsproblem erfasst und mittels eines *Random Forest* Klassifikators (BREIMAN 2001) gelöst.

Überblick über die Prozesskette

Die Prozesskette ist in zwei Schritte unterteilt. Im ersten Schritt werden Pixel, die Weizenähren enthalten, innerhalb der aufgenommenen RGB-Bilder detektiert (*Ährendetektion*). Die Problemstellung wird als binäres Klassifikationsproblem behandelt. Die resultierenden Ährencluster gehen als neue Eingangsgröße in die *Ährenzählung* ein, die den zweiten Schritt der Kette darstellt. Auch die Problemstellung der *Ährenzählung* wird als Klassifikationsproblem behandelt, sodass am Ende eine möglichst genaue Anzahl an vorhandenen Ähren pro Bild ausgegeben wird. Beide Klassifikatoren werden unabhängig voneinander trainiert.

2 Material und Methoden

Datengrundlage

Das in dieser Arbeit präsentierte Verfahren basiert auf digitalen RGB-Bildern, welche mittels einer an einem Traktor angebrachten Kamera aufgenommen wurden. Die zur Datenaufnahme genutzte Kamera ist eine Canon 1200D mit einer Brennweite von 28 mm, die in einer Höhe von etwa 2 m über dem Bestand an dem Traktor montiert wurde. Die Bilder wurden im ersten Drittel des Wachstumsprozesses aufgenommen. Dieser Reifegrad wurde ausgewählt, da hier eine geringe Überlappung der Weizenähren, eine ähnliche Größe der Ähren sowie die größte Differenz hinsichtlich des Erscheinungsbildes der Farbe der Ähren gegenüber den Blättern vorliegt. Zusätzliche Referenzdaten dienen der späteren Evaluierung. Neun unterschiedliche Personen haben die Ähren von 10 beispielhaft ausgewählten Bildern manuell gezählt. Daraus wurden der Mittelwert sowie die Standardabweichung berechnet.

Ährendetektion

Im Folgenden wird zunächst genauer auf den Schritt der *Ährendetektion* eingegangen. Wie es bei einem Klassifikationsproblem üblich ist, wird eine Stichprobe der Daten zum Trainieren genutzt. Die ausgewählten Daten werden in die Klassen ‚Ähre‘ und ‚Nicht-Ähre‘ unterteilt, wodurch das Problem binär wird. Für diese Trainingsdaten werden u.a. ausgewählte Farb- und Nachbarschaftsmerkmale extrahiert. Diese Merkmale (*Features*) werden mittels der Variante der sequentiellen Vorwärtsauswahl aus einer Menge von *Features* ausgewählt. Diese sind beispielsweise das ‚*Maximum der Farbsättigung*‘ oder die ‚*Glattheit der Luminanz*‘ der RGB Bilder. Zusätzlich werden noch drei weitere *Features* nach (HARALICK 1997) für die spätere Klassifikation berechnet. Diese beschreiben die Korrelation, den Mittelwert, sowie die Entropie, basierend auf den Graustufenwerten der Bilder. Auf diesen *Features* wird ein *Random Forest* Klassifikator nach (BREIMAN 2001) gelernt. Diese Methode der Klassifikation wird der Klasse der Ensemblemethoden zugeordnet. Hierbei werden mehrere einfache Klassifikatoren, wie in diesem Falle Entscheidungsbäume, genutzt um die Daten zu präzisieren. Für jeden Entscheidungsbaum wird ein Satz zufällig ausgewählter Datenpunkte sowie *Features* genutzt, sodass

jeder Baum individuell auf den Trainingsdaten gelernt wird. Der gelernte *Random Forest* wird auf die Eingangsbilder angewandt. Um das Rauschen des Prädiktionsergebnisses zu verbessern, findet anschließend eine Filterung der Ergebnisse mittels des morphologischen Operators *Opening* statt, siehe (MATHERON 1967). Zuletzt werden die einzelnen Pixel in zusammenhängenden Komponenten zusammengefasst, sodass das Ergebnis eine Menge bereinigte Ährencluster darstellt.

Ährenzählung

Im weiteren Verlauf wird auf den Schritt der *Ährenzählung eingegangen*. Die Ergebnisbilder der *Ährendetektion* dienen als Eingangsgröße. Wie auch bei der *Ährendetektion* liegt hier ein Klassifikationsproblem vor, sodass wiederum eine Stichprobe der Daten für das Labeln und Lernen genutzt wird. Der Klassifikator, der wiederum ein *Random Forest* ist, ist hierbei unabhängig vom vorherigen Klassifikator. Als Merkmale werden Formfeatures, wie beispielsweise die Fläche, Dichte oder Kontur der einzelnen Ährencluster, gewählt. Das Ziel der Klassifikation in diesem Schritt ist es, die Eingangskluster aus der *Ährendetektion* in die Klassen „eine Ähre“ (Klasse 1), „zwei Ähren“ (Klasse 2), „drei Ähren“ (Klasse 3), „vier Ähren“ (Klasse 4) und „mehr oder gleich fünf Ähren“ (Klasse 5) zu unterteilen.

Tabelle 1: Anzahl der gesamt zur Verfügung stehenden Trainingsdaten und dessen Aufteilung für den aus drei Modellen bestehenden Klassifikator

Klasse	Gesamtzahl	I	II	III
1	8813	1174	2088	-
2	2088	1174	2088	-
3	749		-	191
4	254	1174	-	191
5	171		-	171

An dieser Stelle tritt die Problematik einer hohen Variabilität innerhalb der Verteilung der Trainingsdaten für die unterschiedlichen Klassen auf. Wie in **Tabelle 1** zu erkennen, sind beispielsweise wesentlich mehr Trainingsdaten der Klasse 1 gegenüber der Klasse 5 vorhanden.

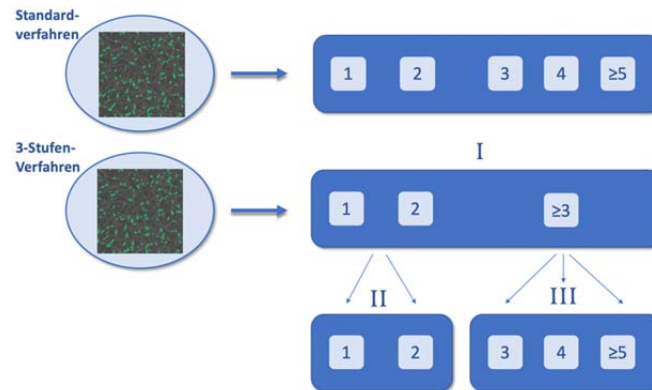


Abbildung 1: Gegenüberstellung des Standardverfahrens und des 3-Stufen-Verfahrens zur Bestimmung eines Klassifikators

Da der *Random Forest* seine Datenpunkte aus der gesamten Trainingsstichprobe zufällig auswählt, kann es dazu kommen, dass die gering vertretenen Klassen beim Lernen des Klassifikators nicht, oder nur sehr selten auftreten. Um dieses Problem zu umgehen, werden zunächst synthetische Daten auf Basis der Datengrundlage erstellt. Dies geschieht über Anwendung von Rotationen sowie Skalierungen. Des Weiteren wird ein hierarchisches 3-Stufen-Verfahren eingeführt, welches drei verschiedene Klassifikatoren auf Basis einer unterschiedlichen Anzahl an Trainingsdaten und unterschiedlicher Vertretung der Klassen lernt. Die endgültige Prädiktion erfolgt dann aus Kombination dieser drei Klassifikatoren. Die Aufteilung der Daten ist in **Tabelle 1** dargestellt. **Abbildung 1** zeigt den Ablauf des 3-Stufen-Verfahrens. Hierbei werden zunächst die Daten der Klasse 4 und 5 der Klasse 3 zugeordnet und zusätzlich zu den Klassen 1 und 2 mit der entsprechenden Anzahl an Trainingsdaten je Klasse, siehe Tabelle, gelernt. Die zweite Stufe (II) besteht lediglich aus Trainingsdaten der Klasse 1 und 2. Die letzte Stufe (III) beinhaltet ausschließlich Datenpunkte der Klassen 3, 4 und 5.

Nach dem Lernen der drei Modelle findet die Prädiktion statt. Wie **Abbildung 1** zeigt, werden die gefundenen Ährencluster aus der *Ährendetektion* als Eingangsgröße genommen und mittels des ersten Klassifikators gelernt. Die Ährencluster werden hinsichtlich der Anzahl der sich überschneidenden Weizenähren, die sie enthalten, klassifiziert. Die Ährencluster, die als Klasse 1 und 2 prädiziert worden sind, werden im zweiten Schritt mittels des zweiten Klassifikators erneut prädiziert. Zuletzt werden die Ährencluster, die im ersten Schritt als Klasse 3 prädiziert wurden mittels des dritten Klassifikators in die Unterklassen 3, 4 und 5 prädiziert. Aus dem Ergebnis kann die Gesamtzahl der Weizenähren abgeleitet werden, indem die Anzahl der Ähren pro Cluster addiert wird.

3 Ergebnisse und Diskussion

In diesem Abschnitt findet eine Analyse der Ergebnisse der aus Kapitel 2 beschriebenen Methodik statt. Hierbei werden die beiden Schritte *Ährendetektion* und *Ährenzäh-*

lung zunächst unabhängig voneinander betrachtet und bewertet. Zu guter Letzt findet eine Analyse der Leistung des gesamten Systems statt.

Ährendetektion

Für die *Ährendetektion* wird in **Abbildung 2** ein beispielhaftes Ergebnis dargestellt. Der Großteil der Ähren wird mittels des Klassifikators erkannt und richtig prädiziert. Der Klassifikator der *Ährendetektion* erreicht eine Gesamtgenauigkeit von 93,25 %, wobei diese den Anteil der korrekt klassifizierten Fälle an der Gesamtzahl aller Beobachtungen angibt.




Abbildung 2: Zwischenergebnisse der *Ährendetektion*. Das erste Bild zeigt das Eingangsbild (Input). Nach der Prädiktion erfolgt das klassifizierte Bild, wobei rot die Klasse 'Nicht-Ähre' und grün die Klasse 'Ähre' darstellt. Zuletzt wird das gefilterte Ergebnis der endgültigen Ährencluster abgebildet.

Die Klassifikation scheint somit geeignet zu sein, um nach der Filterung verbleibende Pflanzenpixel von den Ährenpixeln zu trennen. Die mittlere Klassengenauigkeit beträgt 91,91 %, wodurch die Klassifikation insgesamt als erfolgreich bewertet werden kann. Der Teil, der der falschen Klasse zugeordnet wird, kann unter anderem auf die ähnliche Struktur der Pflanzen gegenüber den Ähren zurückgeführt werden. Des Weiteren liegen ein ähnliches Farbschema sowie Schattenwurf vor, was die Detektion zusätzlich erschwert.

Ährenzählung

Weiterführend geht es um die Analyse der *Ährenzählung*. Beispielhafte Ergebnisse werden in **Abbildung 3** dargestellt. Die drei Bilder zeigen dabei unterschiedliche Ährendichten sowie unterschiedliche Verteilungen der einzelnen Klassen. Um hier eine objektive Aussage über die erzielten Resultate liefern zu können, werden über manuelle Zählungen der resultierenden Ährencluster aus der *Ährendetektion* Referenzdaten erzeugt.




Abbildung 3: Ergebnisse der Ährenzählung nach Anwendung des 3-Stufen-Verfahrens. Dabei stellt blau Klasse 1, cyan Klasse 2, grün Klasse 3, gelb Klasse 4 und orange Klasse 5 dar.

Abbildung 4 zeigt die relative Anzahl gefundener Ähren in Bezug zu den Referenzdaten. Hierbei werden beispielhaft fünf Bilder betrachtet. Zudem werden die Ergebnisse des 3-Stufen-Verfahrens denen des Standardverfahrens gegenübergestellt. Die Ergebnisse sowie der Mittelwert der beiden Verfahren zeigen, dass das 3-Stufen-Verfahren allgemein mehr Ähren zählt, als das Standardverfahren. Dies ist der Fall, da die Datenpunkte der gering vertretenen Klassen durch das neue Verfahren eine höhere Gewichtung erhalten.

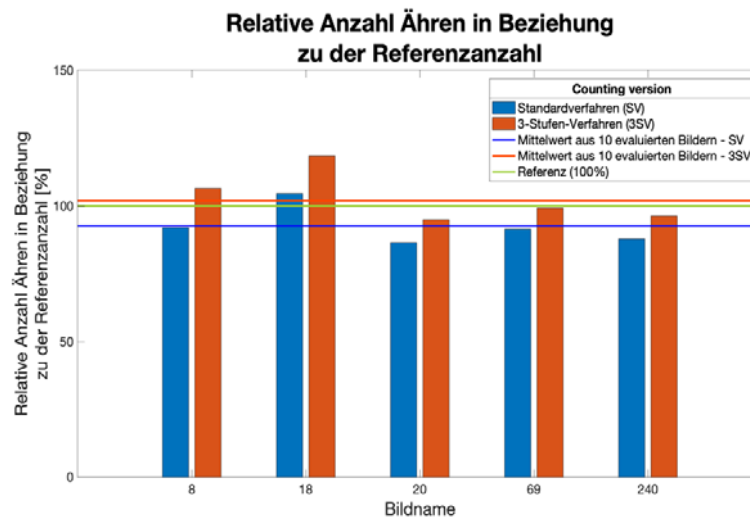


Abbildung 4: Darstellung der relativen Anzahl an prädizierten Ähren aus dem Standardverfahren und dem 3-Stufen-Verfahrens in Relation zu den Referenzdaten. Beispielhaft werden die Ergebnisse von fünf prädizierten Bildern abgebildet. Die Ergebnisse der Einzelbilder werden dem berechneten Mittelwert aus 10 zum Klassifikator unabhängigen Bildern gegenübergestellt.

Das 3-Stufen-Verfahren zählt im Mittel mehr Ähren als die Referenzdaten zeigen, trotzdem sind hiermit genauere Ergebnisse erzielt worden, als mit dem Standardverfahren. Dies wird auch in **Abbildung 5** ersichtlich, die die Klassengenauigkeiten der beiden Verfahren gegenüberstellt. Die Problematik der vierten und fünften Klasse liegt weiterhin daran, dass die Beispielbilder wenige Ährencluster dieser Klassen beinhalten und

generell eine große Komplexität innerhalb dieser Klassen vorliegt, wodurch eine richtige Prädiktion zusätzlich erschwert wird. Dies wird jedoch als nicht sehr gravierend eingeschätzt, da sich diese Klassen im Falle einer Fehlklassifikation auf die Nachbarklassen aufteilen. Diese Abweichung ist aufgrund des geringen Anteils der größeren Ährencluster gering in Bezug auf das Gesamtergebnis.




Abbildung 5: Gegenüberstellung der Klassengenauigkeit des Standardverfahrens und des 3-Stufen-Verfahrens mit integrierter Darstellung des jeweiligen Mittels

Gesamtergebnis

Um eine objektive Aussage über das Gesamtsystem treffen zu können, wird auch hier ein Vergleich zur manuell ermittelten Ährenzahl erstellt. Letztere wurde, wie bereits erwähnt, aus den Mittelwerten der visuellen Zählung von neun verschiedenen Personen berechnet (zusammen mit der Standardabweichung dargestellt in **Abbildung 6**).

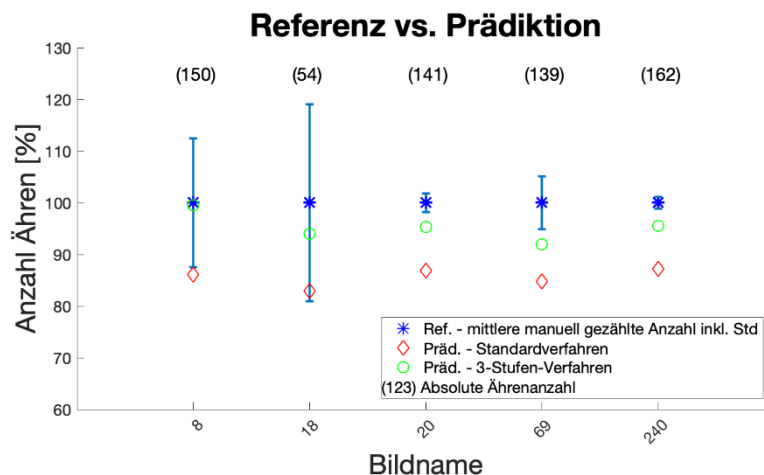


Abbildung 6: Gegenüberstellung der Referenzanzahl zu prozentual prädizierter Anzahl an Ähren durch das Standardverfahren sowie das 3-Stufen-Verfahren für fünf beispielhaft ausgewählte Bilder.

Diesem werden die Ergebnisse der Ährenzählung des 3-Stufen-Verfahrens sowie des Standardverfahrens gegenübergestellt. Es ist zu erkennen, dass die Ergebnisse des

3-Stufen-Verfahrens sich dichter an die Referenzdaten annähern, als die des Standardverfahrens. Dennoch scheinen die Ergebnisse der automatischen Zählung systematisch unterhalb der manuellen Zählung zu liegen. Ein Grund dafür könnte die Zahl der in der *Ährendetektion* nicht gefundenen Ährenpixel und -cluster sein. Es können natürlich maximal die Ähren gezählt werden, die auch vorher gefunden werden. Ein anderer Grund könnte in der *Ährenzählung* liegen, die Schwierigkeiten damit hat Cluster einer höheren Klasse zu präzisieren, so dass die Cluster eher niedrigeren Klassen zugeordnet werden. Durchschnittlich werden jedoch 97 % aller Ähren gezählt.

4 Zusammenfassung

Insgesamt kann gesagt werden, dass der Schritt der *Ährendetektion*, in Bezug auf ihre erreichten Genauigkeiten, erfolgreich ist. Dennoch liegen Schwierigkeiten vor, die entsprechenden Ähren zu detektieren. Dies ist zu einem auf die starken Ähnlichkeiten, hinsichtlich der Farbe, Form und Struktur zwischen den Weizenähren und Blättern der Pflanze zurückzuführen. Zum anderen liegt es an den Trainingsdaten, die in den Klassifikator eingehen, da diese selten schwer zu erkennende Ähren (selbst für das menschliche Auge) beinhalten. So werden verdeckte bzw. abgedunkelte Ähren fälschlicherweise der falschen Klasse zugeordnet. Die Entwicklung des 3-Stufen-Verfahrens für das Lernen und die Prädiktion der Anzahl an Ähren pro Ährencluster ermöglicht eine Verbesserung der Ergebnisse anstelle des Standardverfahrens der Klassifikation. Die vorliegende Steigung der Komplexität mit der Anzahl Ähren pro Klasse ist weiterhin aufgrund der geringen Datenbasis ein Problem. Durch eine zusätzliche Aufnahme von Daten kann dieses Problem mit hoher Wahrscheinlichkeit reduziert werden. Die größere Datengrundlage ist speziell für die größeren Klassen von Bedeutung.

Zusammenfassend kann gesagt werden, dass das entwickelte Verfahren dieser Arbeit für zukünftiges automatisiertes Monitoring eine gute Methode darstellt. Auch wenn nicht alle Ähren gefunden oder exakt gezählt werden konnten erreicht das Ergebnis im weitesten Sinne die Ergebnisse der Referenzdaten. Dabei ist jedoch zu beachten, dass die Prozessierung insgesamt mit viel weniger Zeitaufwand und Kosten verbunden ist, als das Monitoring auf dem Feld.

Danksagung

Diese Arbeit wurde teilweise finanziell unterstützt durch das BmBF im Rahmen des Projektes NoviSys (FKZ 031A349). Die Bilder zum Trainieren und Evaluieren der Klassifikatoren wurden innerhalb des durch das BLE geförderten Projektes CropWatch (FKZ 2815702315) erfasst und freundlicherweise von Andreas Honecker und Henrik Schumacher zur Verfügung gestellt.

Literaturverzeichnis

BREIMAN L. (2001): Random forest. Machine learning, 45(1),
<https://doi.org/10.1023/A:1010933404324>

FRÉDÉRIC, C., LUDOVIC, J., GILLES, R., CHRISTIAN, G., DAVID, O., MARIE-FRANCE, D., & AMBROISE, M. (2012): Texture, color and frequential proxy-detection image processing for crop characterization in a context of precision agriculture. In Agricultural.

HARALICK R.M. (1997): Statistical and structural approaches to texture. Proceedings of the IEEE (Volume: 67, Issue: 5, May 1979).

LUMME, J., KARJALAINEN, M., KAARTINEN, H., KUKKO, A., HYYPPÄ, J., HYYPPÄ, H., JAAKKOLA, A., & KLEMOLA, J. (2008): Terrestrial Laser Scanning of Agricultural Crops. Organising Committee of the XXI International Congress for Photogrammetry and Remote Sensing. 37(B5).

MATHERON G. (1967): Eléments pour une théorie des milieux poreux.

UAV-based Field Monitoring for Precision Farming

UAV-basierte Feld Beobachtungen für die Präzisionslandwirtschaft

Philipp Lottes¹, Nived Chebrolu¹, Frank Liebisch² and Cyrill Stachniss¹

¹Universität Bonn – Institut für Geodäsie und Geoinformation, Nussallee 15, 53115 Bonn

²ETH Zurich – Institut für Agrarwissenschaften, Eschikon 33, 8315 Lindau, CH

E-Mail: frank.liebisch@usys.ethz.ch

Zusammenfassung: Um dem ständig steigenden Bedarf an Nahrungsmitteln und Energie gerecht zu werden, müssen wir zukünftig auf eine effektivere und nachhaltigere Pflanzenproduktion setzen. Damit Landwirte und Züchter die tägliche Bewirtschaftung optimieren können, müssen sie über den aktuellen Zustand ihrer Felder informiert werden, z.B. über den aktuellen Stand der Pflanzenentwicklung oder den Unkrautdruck. Unbemannte Luftfahrzeuge (UAV) dienen als Überwachungsplattform, um große Flächen in vergleichsweise geringer Zeit zu beobachten. In diesem Beitrag behandeln wir die Analyse von UAV-Bildern hinsichtlich der automatischen Erfassung der raumzeitlichen Verteilung von Nutzpflanzen und Unkräutern. Wir verwenden für die Klassifikation eigens für den Agrarbereich optimierte maschinelle Lernverfahren und verknüpfen die analysierten Bilddaten über mehrere Zeitpunkte, sodass wir auf Wachstumsparameter und Merkmale schließen können, welche sich auf den Bestand und auf einzelne Pflanzen beziehen.

Deskriptoren: Agrarrobotik, maschinelles Lernen, Präzisionslandwirtschaft

Abstract: *To cope with an ever increasing demand for food and energy, we rely on a more effective and sustainable crop production in the future. To enable farmers and breeders to optimize their day-to-day crop management, they need to be provided with information about the actual status of their fields, e.g. the current status of the crop development or weed pressure. Unmanned aerial vehicles (UAVs) serve as an excellent monitoring platform for observing large areas of farm land in a comparably small amount of time. In this paper, we present a machine learning based approach for UAV imagery of different crop fields to analyze the spatio-temporal distribution of crop plants and weeds. We treat the crop-weed classification as a semantic segmentation using Convolutional Neural Networks and associate the image data over time allowing us to infer growth parameters and crop traits moving from canopy level to the level of individual plants.*

Keywords: Crop Monitoring, Machine Learning, Precision Farming

1 Introduction

The increasing demand for food and energy induced by an ever-growing world population is a global challenge. A high and stable crop production is key to satisfy these needs, but arable land is limited and the environmental footprint of agricultural production needs to be reduced. Agrochemicals are intensively used in conventional agriculture for effective weed control and to attain high yields. Whole fields are typically treated uniformly with a single herbicide dose, spraying the soil, crop and weed in the same way. Agrochemicals, however, can have a negative impact on the environment and biodiversity, and consequently affect human health (HORRIGAN *et al.* 2002). For the development of more effective crop cultivars and crop production strategies, we have to increase our understanding about the crop and its interaction with the environment.

Thus, an effective and future-oriented agriculture needs to focus on both high productivity and sustainability. One major goal of sustainable farming is to increase yield while reducing the reliance on agrochemicals. Precision farming techniques seek to address these conflicting targets by (i) monitoring fields for key indicators of crop health, spatial distribution of crop traits and weeds and (ii) providing targeted measures for selectively treating only those plants that actually need it. By monitoring the field status and automatically inferring statistics about the development of the crops, we can gain a better understanding about the growth process and at the same time minimize the use of applied agrochemicals (WALTER *et al.* 2018).



Figure 1. Left: UAV system (DJI Inspire II). Right: Sugar beet field in early season analyzed with our approach. We estimate the spatial distribution of crop (green) and weed (purple) and the per-plant canopy cover. This information directly leads to concrete suggestions for the farmers.

A popular way to monitor farmland is through the use of aerial vehicles such as UAVs. UAVs can cover large areas in a comparably short amount of time without interacting with the environment as ground vehicles do. For an effective on-field intervention, it is important to know the spatial distribution of the weeds on the field already at an early state. The earlier mechanical or chemical weeding actions are executed, the higher the chances for obtaining a high yield. A prerequisite to trigger weeding and intervention task is a detailed knowledge about the spread of weeds. Additionally, UAVs can be employed over an entire crop season to monitor important traits for the crop plants. This provides a temporal dimension to monitoring of the field which is necessary for under-

standing how the field status is evolving and to trigger certain field management tasks. For breeders, the monitoring of genotype performance within field selection trials is a crucial part for the development of better varieties. Presently, this analysis is mostly done manually, which is laborious. Therefore, it is important to have an automatic perception pipeline that monitors and analyzes the crops automatically and provides a report about the status of the field over time.

2 Material und Methods

In this work, we address the problem of analyzing RGB-only imagery captured by UAVs to inspect the status of a field in terms of the spatio-temporal crop and weed distribution. We treat the classification problem as one of semantic segmentation (BADRINARAYANAN *et al.* 2017) providing a pixel-wise classification of the entire image by using state-of-the-art **Fully Convolutional Neural Networks (FCNs)**. We focus on the detection on a per-plant basis to estimate the amount of crop plants as well as various weed species. We furthermore associate the data obtained by multiple UAV flight sessions over the crop season and can provide information of dynamic crop development over time directly to the farmers and breeders. The experiments show the performance of our plant classification system on several crop fields under different acquisition conditions. Our approach efficiently adapts to different crop and weed species with comparably small amount of training data. We demonstrate that we are able to exploit classifier output, i.e., the spatial and the semantic field information, (i) to associate the acquired data over multiple UAV flight sessions and (ii) to extract canopy cover over time.

Vision-Based Plant Classification using FCNs

The main goal of our vision-based plant classification system is to segment the plants and weeds in UAV images to estimate their spatial distribution in the field and to allow for their precise and individual mapping. Our classification further serves as a basis for inferring growth parameters and crop traits moving from canopy level to the level of individual plants. The classification system used in this work is based on our previously published FCN approach in LOTTES *et al.* (2018) with slight modifications such that it can deal with *RGB-only* input as well as work on images with a size of 1500 x 2000 pixels. **Figure 1** and **Figure 4** illustrate exemplary outputs of our classification system.

SLAUGHTER *et al.* (2008) state that a major challenge for vision-based plant classification systems in agricultural fields is their adaptation to changing conditions such as different crop and weed types in new fields and rapidly changing environments. These changes lead to a different distribution of the data which may not be properly modeled by the classifier. This holds especially for UAV images as they are directly affected by natural illumination conditions (**Figure 4**). To address these challenges, we apply supervised transfer learning, i.e., fine-tuning a pre-trained model, to adapt the classifier to new envi-

ronments. We achieve a good transferability by using a comparably small amount of labeled training data of the new field.

Semi-Supervised Rapid Labeling

Labeling of images with pixel accuracy is a laborious task, which is not scalable from a practical application point of view. Therefore, we propose two strategies to rapidly obtain labeled data for a new field in a semi-supervised way. For both strategies, we first segment the vegetation from the background, i.e. soil, by using a threshold based approach applied to the Excess-Green-Index (MEYER & NETO 2008, KHANNA *et al.* 2015). The output from this step is a binary image representing vegetation and soil.




Figure 2. Left: Labeling strategy based on crop row detection. Right: Labeling strategy using Random Forest. We only manually annotated the vegetation pixels within the red box.

The first approach (**Figure 2**) for semi-automated data labeling is to exploit the crop row structure. We employ a variant of the Hough transform on the binary vegetation image as proposed in (LOTTE *et al.* 2017b) providing us the crop rows in the image. We then automatically assign the label crop to all vegetation pixels within a certain threshold distance to the estimated crop row. Remaining vegetation pixels in the image are considered to be weeds. A limitation of this strategy is that weeds located along the crop row are wrongly labeled. Despite the rough labeling procedure, our FCN classifier is able to adapt to new field conditions.

In case a field has no strict crop row structure (**Figure 2**), we follow strategy two employing a standard Random Forest (RF) classifier (BREIMAN 2001) that is capable of solving multi-class problems. Here, we exploit the fact that RF can be trained with a comparably small amount of data and use it to rapidly produce predictions. For the features, we are using the ones proposed in our earlier work (LOTTE *et al.* 2017a). To initialize this procedure, the user only has to provide a few labels for some of the vegetation pixels, which are then used to train the RF. Then, in the prediction step, the RF provides labels for the entire vegetation mask.

Temporal Image Data Association

Nowadays, commercial UAVs are typically equipped with low cost GPS sensors providing a global positioning accuracy of around 5-10m. However, the monitoring of growth parameters of individual plants requires a temporal data association at centimeter level accuracy. A common technique to obtain a more precise image registration is by matching visual descriptors computed on the images. Such descriptors, however, are not suited to cope with the large differences in appearance such in agricultural environments over time, which leads to an unreliable registration.

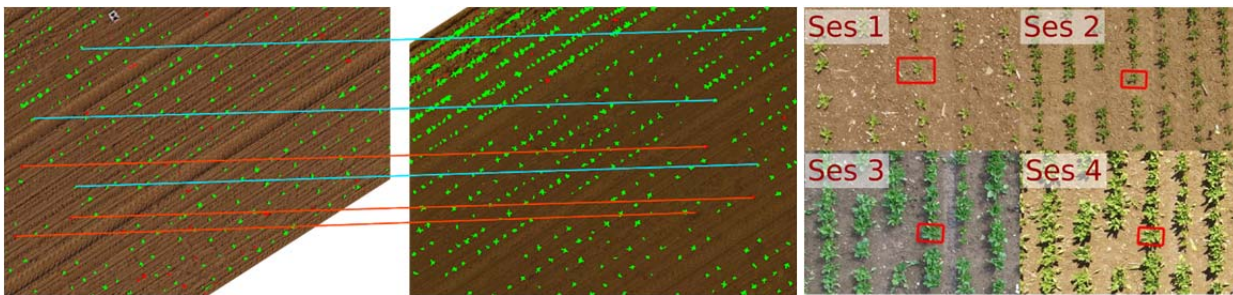


Figure 3. Data association between images with a temporal difference of one week. We only allow crops to match with crops (blue) and weeds with weeds (orange). Note, we only visualize a few correspondences.

With the presented approach we are able to obtain a temporal correspondence between the image data by exploiting the distribution of crop and weed locations as well as the semantic information obtained from the FCN classification. The details of our approach are described in (CHEBROLU *et al.* 2018). It allows to register images with the accuracy required for a plant-wise data association (**Figure 3**). We use the classification results to allow only correspondences between same class labels. Given the associations, we are able to register the two images in a common reference frame and compare different plant properties such as canopy cover or class labels.

To illustrate the data association on plant level, we draw a box around a specific crop in **Figure 3** (right). Given that we registered the image data temporally, we can track the same plant across multiple sessions as visualized by the red boxes. By this we can monitor and compute growth parameters on a per-plant basis over the whole field.

3 Experiments

The experiments presented here, demonstrate the ability the approach to detect different crop and weed types in aerial RGB imagery. Even, with limited training data, our FCN classifier is able to adapt to the new situations. Furthermore, we show two exemplary applications, where the temporal data association supported by the classifier output enables us (i) to monitor the development of individual plants in the field over time and (ii) to analyze the effect of fertilization in crop fields.

Crop-Weed Detection in Different Crop Fields

For the evaluation of the crop-weed detection performance, we acquired image data from multiple crop fields using different UAV systems. Table 1 summarizes the datasets used in this paper. We use the software package METASHAPE (Agisoft) to register the single images captured during a UAV flight and compute the orthomosaics for each field. To obtain an appropriate image size for further analysis with the FCN classifier, we cut the orthomosaics into tiles (ortho-tiles) of size 1500 x 2000 pixels (**Figure 4**). For each dataset, we labeled five ortho-tiles using the labeling strategies described in chapter Material and Methods to obtain the training data. For all experiments, we fine-tuned the same pre-trained FCN, which was trained on independent data from different fields from our previous publication (LOTTE *et al.* 2017b).

We evaluate and report the segmentation performance on a per pixel basis. To obtain the performance metrics, we thoroughly labeled 10 ortho-tiles for each dataset forming a high quality ground truth. The accumulated average precision (P) and recall (R) values are shown in **Table 1**. As average, we consider the respective means of the class-wise P/R values, i.e., for crop, weed, soil, and toxic weed. Our evaluation suggests that we are able to obtain a recall of 87 % and a precision of 84 % over all datasets. For the peppermint dataset, we achieved class-specific recall of 95 % for the toxic weeds. This is crucial for the farmers as they need to guarantee that the quantity of toxic weeds in the field is below a permissible limit.

Table 1. Key parameters of the datasets and classification performance using recall (R) and precision (P)

	UAV	Images	Tiles	GSD	Classes	avg. R	avg. P
Sugar beet	DJI Mavic	192	42	8mm	Crop, weed, soil	83%	81%
Pumpkin	DJI Inspire II	219	80	5mm	Crop, weed, soil	85%	81%
Strawberry	DJI Inspire II	75	59	3mm	Crop, weed, soil	95%	85%
Peppermint	DJI Phantom 4	330	165	5mm	Crop, weed, toxic weed, soil	88%	86%




Figure 4. Per Crop: RGB-tiles (left) of size 1500x2000 pixels cropped from the orthomosaic and analyzed images (right). Colors refer to different classes, i.e., sugar beet / pumpkin (green), strawberry (yellow), peppermint (bright blue), toxic weeds (blue), and general weed (red)

Monitoring Early Crop Growth as Affected by Nitrogen Status

The variation of canopy cover within a field reflects differences between growth factors which are often soil moisture and nutrient availability, among which nitrogen plays a vital role. Therefore, detection of growth differences in early stages enables site-specific management such as variable rate fertilization or precision spraying of pesticides.




Figure 5. Top row: Orthomosaics of sugar beet field recorded on the 25th April (left) and the 18th May (right) in 2017. Bottom row: The same zoomed area.

This experiment illustrates that we are able to analyze the effect of fertilizer on the growth of sugar beets at an early growth stage based on UAV images. The field trial consisted of 4 nitrogen fertilization regimes (0, 40, 80 and 120 kg N/ha) with 6 plot replicates of 36 m² each. A detailed description of the experimental field setup is also described in SA *et al.* (2018). We acquired images with a UAV on two dates, on 25th April (39 days after sowing, DAS) with a *DJI Inspire II* and on the 18th May (62 DAS) with a *DJI Matrice 200*, corresponding to an average growth stage of BBCH of 12 and 16, respectively. **Figure 5** illustrates the two orthomosaics from the respective acquisition dates as well as the arrangement of the plots. After performing the classification of the sugar beets and weeds, we used our data association procedure as described in chapter Material und Methods aligning the two orthomosaics to automatically derive the growth parameters for the same area of interest.

To analyze the growth, we monitor the canopy cover (**Figure 6**) as a proxy and correlate it with the amount of fertilizer applied to the plots. Plants count per area and canopy cover are important parameters to evaluate crop performance, vitality and estimate potential yield. Both parameters are of particular interest during early growth stages. The number of plants is a result of the germination rate and the young plant survival. Canopy cover at a given time reflects growth of the crop integrating biomass, leaf area, number of leaves as developed until image acquisition. We compute the total canopy cover

(TCC), which is the surface in a plot covered by classified sugar beets as well as the average canopy cover (ACC), which is TCC divided by the number of single plants in a plot. We observe increased growth up to 80 kg N/ha, whereas higher N fertilization did not result in further growth of the sugar beets. This trend is already visible in the TCC from at the 25th April.

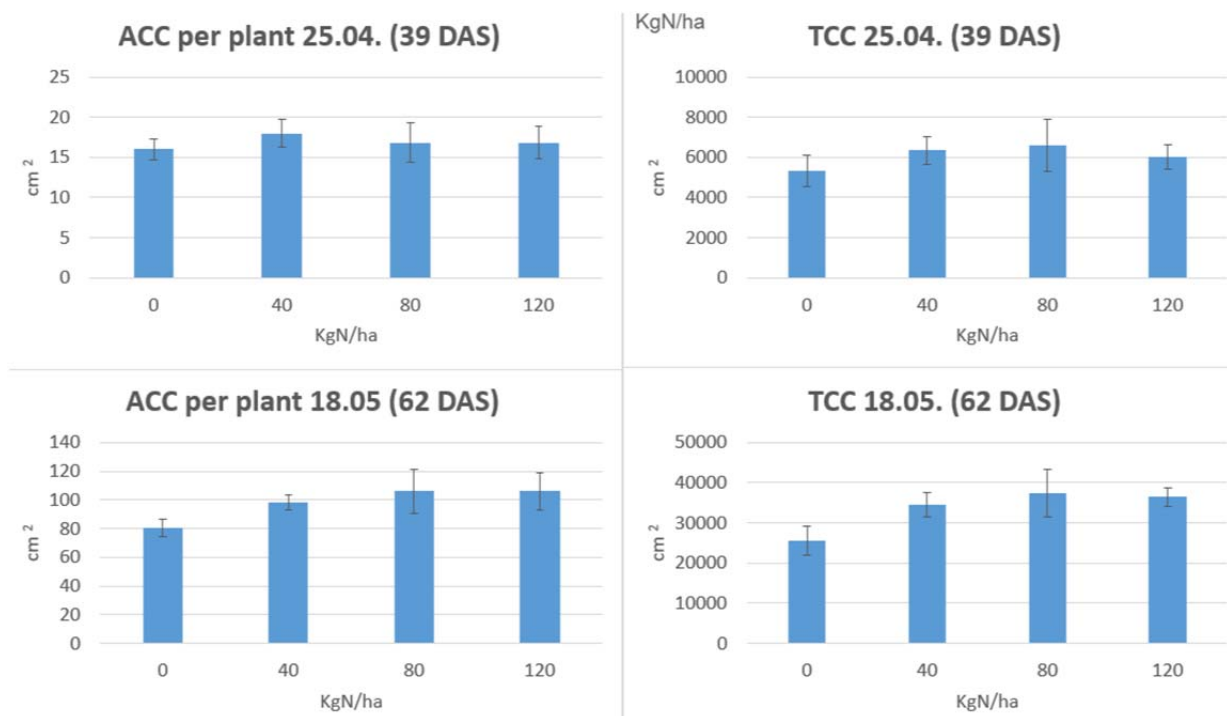


Figure 6. Total and average canopy cover per plant as affected by Nitrogen fertilizer treatment

4 Discussion and Conclusion

In this paper, we propose a UAV-based plant classification system for crop monitoring enabling precision agriculture applications by automatically inferring growth parameters and crop traits moving from the canopy level to the level of individual plants. We show the ability of the classifier to identify multiple crops and weed types under different environment conditions. As an application, we study effects of fertilization by analyzing canopy cover data obtained by our classification system. The results indicate that these measurements might enable site specific fertilization in crops at an early growth stage and can be used when methods based on canopy reflectance or greenness are failing due to a low canopy coverage. Furthermore, such a system can potentially support soil sampling based fertilization strategies which are often limited in spatial representation due to a high labor and financial costs of the soil sampling and lab analysis. Such applications are done in sugar beets, but also in winter cereals.

References

- BADRINARAYANAN, KENDALL, CIPOLLA (2015):** SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, vol. 39, iss. 12, pp. 2481–2495.
- BREIMAN (2001):** Random forests. *Machine Learning*, 45(1):5–32.
- CHEBROLU, LÄBE, STACHNISS (2018):** Robust Long-Term Registration of UAV Images of Crop Fields for Precision Agriculture, *IEEE Robotics and Automation Letters*, vol. 3, iss. 4, pp. 3097–3104.
- HORRIGAN L, LAWRENCE RS, WALKER P (2002):** How sustainable agriculture can address the environmental and human health harms of industrial agriculture. *Environ Health Perspect*, 110:445–56.
- KHANNA, MÖLLER, PFEIFER, LIEBISCH, WALTER, SIEGWART (2015):** Beyond point clouds – 3d mapping and field parameter measurements using uavs. In *Proc. of the IEEE Int. Conf. on Emerging Technologies Factory Automation (ETFA)*, pages 1–4.
- MEYER, NETO (2008):** Verification of color vegetation indices for automated crop managing applications. *Computers and Electronics in Agriculture*, 63(2):282–293.
- LOTES, HÖFERLING, SANDER, STACHNISS C. (2017A):** Effective vision-based classification for separating sugar beets and weeds for precision farming. *Journal of Field Robotics*.
- LOTES, KHANNA, PFEIFER, SIEGWART, STACHNISS (2017B):** UAV-Based Crop and Weed Classification for Smart Farming. In *Proc. of the IEEE Int. Conf. on Robotics & Automation (ICRA)*.
- LOTES, BEHLEY, CHEBROLU, MILIOTO, STACHNISS (2018):** Joint Stem Detection and Crop-Weed Classification for Plant-specific Treatment in Precision Farming. In *Proc. of the IEEE/RSJ Intl. Conf. on Intelligent Robots and Systems (IROS)*.
- SA, POPOVIĆ, KHANNA, CHEN, LOTES, LIEBISCH, NIETO, STACHNISS, WALTER, SIEGWART (2018):** WeedMap: A Large-Scale Semantic Weed Mapping Framework Using Aerial Multispectral Imaging and Deep Neural Network for Precision Farming. *Remote Sens.* 2018, 10(9), 1423.
- SLAUGHTER, GILES, DOWNEY (2008):** Autonomous robotic weed control systems: A review. *Computers and Electronics in Agriculture*, 61(1):63–78.
- WALTER, KHANNA, LOTES, STACHNISS, SIEGWART, NIETO, LIEBISCH (2018):** Flourish-A robotic approach for automation in crop management. Conference paper. At 14th International Conference on Precision Agriculture.

Biomasseabschätzung im Feldfutterbau mittels SfM-gestützter RGB-Aufnahmen

Biomass prediction in forage production by SfM-based RGB-imaging

Esther Grüner, Thomas Astor, Michael Wachendorf

*Universität Kassel, Grünlandwissenschaft und Nachwachsende Rohstoffe,
Steinstraße 19, 37213 Witzenhausen
E-Mail: esther.gruener@uni-kassel.de*

Zusammenfassung: Zu den bisherigen traditionellen Messmethoden für die Ertragsabschätzung im Feldfutterbau und Grünland zählen destruktive Probenahmen, die Höhenmessung mit einem Zollstock, sowie der *Rising Plate Meter*, welche auf großen Flächen als zeit- und arbeitsintensiv gelten. Die Verwendung von RGB-Sensoren, die an einem kleinen unbemannten Luftfahrzeug (Drohne) angebracht werden, stellten eine kostengünstige und schnelle Alternative dar. In der vorliegenden Studie wurden RGB-Aufnahmen für die Ertragsabschätzung in einem Futterbauversuch mit zwei Leguminosen-Gras-Mischungen (Klee- und Luzernegras) sowie der Leguminosen- und Gras-ReinSaat verwendet. Im Vegetationsjahr 2017 wurden alle zwei Wochen drohnen-gestützte RGB-Aufnahmen durchgeführt. Parallel zu jedem Flug wurden Referenzdaten in Form von destruktiven Biomasseproben sowie manuellen Höhenmessungen (50 Messungen pro Parzelle) erhoben. Mit Hilfe von *Structure-from-Motion* (SfM) wurde aus den RGB-Aufnahmen die räumliche Information und die daraus abgeleitete Bestandeshöhe (CH) ermittelt, welche als Schätzmaß für den Trockenmasseertrag (TME) verwendet wurde. Die Ergebnisse zeigen, dass die SfM-basierte Höhenmessung mittels RGB-Aufnahmen ähnlich gute Vorhersagegenauigkeiten für den TME wie die manuelle Höhenmessung aufweist und somit eine vielversprechende Alternative zu den traditionellen Messmethoden darstellt.

Deskriptoren: Futterbau, Ertragsabschätzung, Bestandeshöhe, Drohne, RGB-Aufnahmen, Structure-from-Motion

Abstract: *Traditional measurement techniques for yield estimation in forage production and grassland include destructive biomass sampling, height measurements with a ruler and the rising plate meter, which are considered to be time and labor intensive on large areas. The utilization of RGB sensors mounted on small unmanned aerial vehicles (UAV) represent a low-cost and fast alternative. In the present study, RGB images were used for yield estimation in a forage experiment with two legume grass mixtures (clover-*

and lucerne-grass) and the pure stand of legume and grass. In the vegetation period of 2017, UAV RGB images were taken every second week. In parallel to each flight mission reference data as destructive biomass samples and manual height measurements (50 measurements per plot) were collected. The special information and the derived canopy height, which were determined by structure-from-motion (SfM) by means of the RGB images, were used as a predictor for dry matter yield (DMY). The results show that the SfM-based height measurement has similar prediction accuracies for DMY as the manual height measurement and thus represents a promising alternative to traditional measurement methods.

Keywords: Forage production, biomass estimation, canopy height, UAV, RGB-imaging, structure-from-motion

1 Einleitung

Die destruktive Probenahme von Biomasse im Grünland und Futterbau gilt als die genaueste, aber auch als die arbeitsintensivste Methode zur Ertragsabschätzung. Weitere Messmethoden beruhen auf der Beurteilung der Bestandeshöhe, welche positiv mit der Biomasse korreliert (FRICKE & WACHENDORF 2013), wozu die Höhenmessung mit dem Zollstock und der *Rising Plate Meter* zählen. Diese traditionellen Methoden benötigen eine erhebliche Anzahl an Messwiederholungen in Kombination mit einer gleichmäßigen räumlichen Verteilung für eine zuverlässige Ertragsabschätzung. Eine neue Methode, um auch große Flächen schnell abzudecken, ist die Aufnahme von Rot, Grün, Blau (RGB)-Bildern durch eine hochauflösende Digitalkamera, welche an einer Drohne angebracht ist. Durch *Structure-from-Motion* (SfM), welches eine photogrammetrische Verarbeitung dieser digitalen Bilder in 3D-Punktwolken darstellt, können räumliche Informationen der Bestandeshöhe generiert werden. Bisherige Studien zeigen, dass ein Zusammenhang zwischen der Höheninformation aus RGB-Aufnahmen und der Biomasse in homogenen Getreidebeständen, wie Sommergerste (BENDIG *et al.* 2014) und Winterweizen (SCHIRRMANN *et al.* 2016), besteht.

Ziel dieser Studie ist die Bewertung einer Biomasseabschätzung über die Bestandeshöhe mittels drohnengestützter RGB-Aufnahmen in heterogenen Futterbaubeständen (Klee- und Luzernegras) als Alternative zu traditionellen Messmethoden. Darüber hinaus wurden von den Leguminosen-Grass-Mischungen die jeweilige Reinsaat an Leguminosen (100 % Leguminosen) und Gras (0 % Leguminosen) untersucht um das breite Spektrum des Leguminosenanteils im praktischen Grünland abzudecken.

2 Material und Methoden

Die Messungen wurden in einem Futterbauversuch auf dem ökologisch bewirtschafteten Versuchsbetrieb der Universität Kassel in Neu-Eichenberg durchgeführt. Der Versuch wurde im Herbst 2016 mit den Varianten Klee- (KG) und Luzernegras (LG) sowie der jeweiligen Leguminosen- (L) und Gras-Reinsaat (G) der Mischungen in vierfacher

Wiederholung angelegt. Im darauffolgenden Jahr wurden alle zwei Wochen und zu insgesamt vier Ernte (17.05.17, 26.06.17, 08.08.17, 09.10.17) Biomasseproben für die Trockensubstanzbestimmung (105°C) entnommen. Parallel dazu erfolgten manuelle Höhenmessungen mit einem Zollstock (50 Messungen pro Parzelle).

RGB-Aufnahmen wurden jeweils zeitnah vor der destruktiven Probenahme mit einer Drohne (DJI Phantom 3 Professional, Shenzhen, Guangdong, China) und der integrierten Kamera (12 Megapixel) durchgeführt. Für jeden Flug wurden die Aufnahmen mit 80 % Überlappung in Form eines Gittermusters und in einer Höhe von 20 m aufgenommen. Alle Befliegungen wurden an Tagen ohne Regen und mit geringem Wind durchgeführt, um Probleme bei der Erstellung der Punktwolken zu minimieren.

Mit Hilfe einer SfM-basierten Bildverarbeitungssoftware (PhotoScan, AgiSoft, Russland) wurden aus den RGB-Aufnahmen 3D-Punktwolken für ein digitales Oberflächenmodell (DSM) generiert. In einem weiteren Schritt wurde die Software Quantum Geographical Information System (QGIS) verwendet um über die Interpolation zwischen Punkten in den Wegen ein digitales Höhenmodell (DEM) des Bodens zu erstellen. Durch Subtraktion von DSM und DEM wurde die Bestandeshöhe (CSH) berechnet. Die Bestandeshöhe der manuellen Höhenmessung (CH_Z) und der drohnen-gestützten RGB-Aufnahmen (CH_D) wurden als Schätzmaß für den Trockenmasseertrag (TME) herangezogen. TME wurde auf Normalverteilung und Varianzhomogenität geprüft und durch das Fehlen dieser Bedingungen wurzel-transformiert. Für die Vorhersagegenauigkeit der Ertragsmodelle wurde eine einfache Kreuz-Validierung durchgeführt.

3 Ergebnisse

In einem Zeitraum zwischen Mai und Oktober 2017 konnten je 10 Datensätze an TME, CH_Z und CH_D für jede Variante in vierfacher Wiederholung generiert werden. Auf Grund von unrealistischen negativen Höhenwerten, wurden sieben Werte aus der Analyse ausgeschlossen. Da die Klee- und Luzernegrasbestände in verschiedenen Wachstumsphasen während der Vegetationszeit untersucht wurden, variierte der TME, CH_Z und CH_D stark. Insbesondere der Aufwuchs des 2. Schnittes war durch eine Frühjahrs-trockenheit und folglich durch eine verfrühte generative Phase der Gräser geprägt.

Insgesamt befanden sich die Höhenwerte von CH_Z zwischen 9,42 und 89,54 cm und CH_D zwischen 1,01 und 71,06 cm (**Abbildung 1a**). Im Durchschnitt über alle Daten ist CH_D mehr als 4 cm niedriger als CH_Z . Bei einem Vergleich der beiden Messmethoden zeigte die Korrelation ein R^2 von 0,56 mit einem RMSE von 13,39 cm. Auffällig waren die einzelnen überschätzten Werte seitens CH_Z . Nach Ausschluss der Gräser-Daten des 2. Schnittes (acht Werte) zeigte sich eine Verbesserung des R^2 mit 0,70 ($p < 0,05$) und einem RMSE mit 10,32 cm (**Abbildung 1b**). Um das breite Spektrum des Leguminosenanteils abzudecken (d. h. 0-100%) wurden die Modelle mit der Mischung und der jeweiligen Reinsaat an Leguminosen und Gras mit CH_D als Schätzmaß für TME (**Abbildung 2**) erstellt. Dabei konnte der TME für Klee gras (**Abbildung 2a**) besser modelliert

werden mit einem R^2_{cal} von 0,75 ($r\text{RMSE}_{\text{val}} = 17\%$) als Luzernegras (**Abbildung 2b**) mit einem R^2_{cal} von 0,64 ($r\text{RMSE}_{\text{val}} = 17\%$).




Abbildung 1: Korrelation zwischen den Bestandeshöhen ermittelt mittels manueller Höhenmessung (CH_Z) und drohnengestützter RGB-Aufnahmen (CH_D) während der Vegetationsperiode, unterschieden zwischen Zwischenschnitten (\circ), 1. Schnitt (\blacksquare), 2. Schnitt (\blacklozenge), 3. Schnitt (\blacktriangle) und 4. Schnitt (\blacktriangledown) mit dem vollständigen Datensatz (a) und dem Datensatz ohne die Daten der Gras-Reinsaat des 2. Schnittes

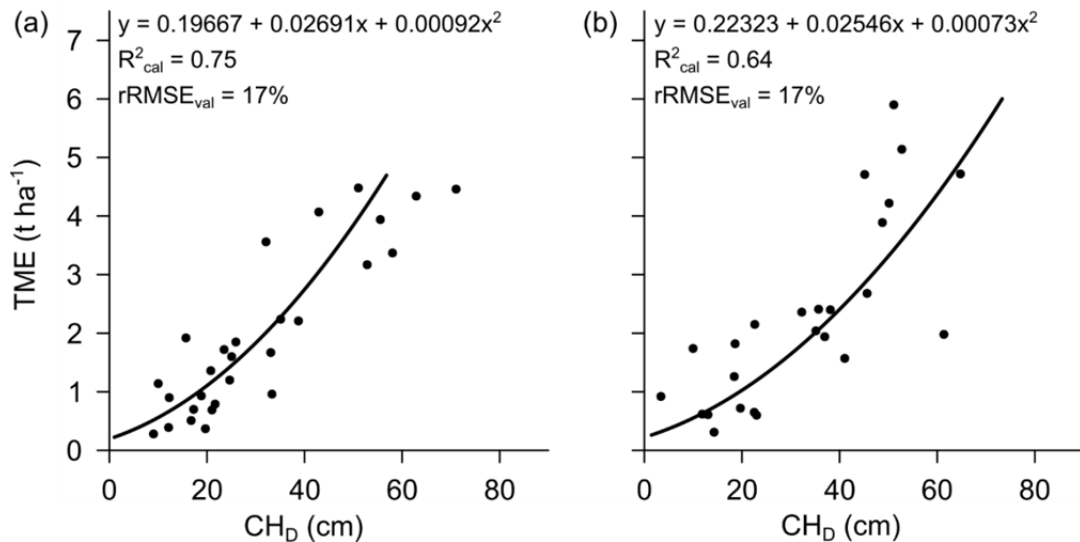


Abbildung 2: Leguminosen-spezifische Regressionsmodelle des Kalibrierungsdatensatzes mit dem Validierungsdatensatz (\bullet) für den TME ermittelt aus der Bestandeshöhe mittels drohnen-basierter RGB-Aufnahmen. Zum besseren Verständnis wurde TME auf die ursprüngliche Skala rücktransformiert. Modelle für Klee-(a) und Luzernegras (b) umfassen sowohl die jeweilige Mischung als auch die entsprechende Leguminosen- und Gras-Reinsaat. R^2_{cal} = Bestimmungskoeffizient der Kalibrierung; $r\text{RMSE}_{\text{val}}$ = relativer Root Mean Square Error der Validierung (berechnet mit wurzel-transformierten Daten)

4 Diskussion

Ziel dieses Versuchs war die Untersuchung und Bewertung der Beziehung zwischen Biomasseertrag und Höheninformation aus RGB-Aufnahmen in einem heterogenen Futterbaubestand. Das Wachstum der Klee- und Luzernebestände wurde im Sommer stark von Trockenheit geprägt. Dies führte bei den Gräsern zu einer verfrühten generativen Phase und folglich zu vielen länglichen Trieben mit sichtbaren Ähren sowie wenigen schmalen Blättern. MALAMBO *et al.* (2018) zeigten in einem Feldversuch mit Mais und Sorghum, dass das Wachstumsstadium der Pflanze die Vorhersagegenauigkeit der SfM-basierten Bestandeshöhe beeinflusst. Wurden bei der Regressionsanalyse in der vorliegenden Studie die Gräser-Daten des 2. Schnittes ausgeschlossen, zeigte sich eine Verbesserung der Vorhersagegenauigkeit. Da manuelle Höhenmessungen nur für eine begrenzte Anzahl von Punkten im Bestand durchgeführt werden, ist diese Methode empfindlicher gegenüber einzelnen hervorstehenden Trieben (GRÜNER *et al.* 2019). Zudem deuten die Ergebnisse dieser Studie darauf hin, dass drohnengestützte RGB-Aufnahmen aufgrund des Flächenbezugs und der Position der Kamera auch für Extremwerte in der Reinsaat des Grases geeignet waren.

Literaturverzeichnis

- BENDIG J, BOLTEN A, BENNERTZ S, BROSCHEIT J, EICHFUSS S und BARETH G (2014):** Estimating Biomass of Barley Using Crop Surface Models (CSMs) Derived from UAV-Based RGB Imaging. *Remote Sensing* 6 (11), pp. 10395–10412.
- FRICKE, T.; WACHENDORF, M. (2013):** Combining ultrasonic sward height and spectral signatures to assess the biomass of legume-grass swards. *Comput. Electron. Agric.*, 99, pp. 236–247.
- GRÜNER E., ASTOR T., WACHENDORF, M. (2019):** Biomass Prediction of Heterogeneous Temperate Grasslands Using an SfM Approach Based on UAV Imaging. *Agronomy* 9 (54), pp. 1–16.
- MALAMBO L., POPESCU S.C., MURRAY S., PUTMAN E., PUGH N.A., HORNE D.W., RICHARDSON G., SHREIDAN R., ROONEY W.L., AVANT R., VIDRINE M., MCCUTCHEN B., BALTENSPERGER D. und BISHOP M. (2018):** Multitemporal field-based plant height estimation using 3D point clouds generated from small unmanned aerial systems high-resolution imagery. *Int J Appl Earth Obs Geoinformation* 64, pp. 31–42.
- SCHIRRMANN M., GIEBEL A., GLEINIGER F., PFLANZ M., LENTSCHKE J. und DAMMER K.H. (2016):** Monitoring Agronomic Parameters of Winter Wheat Crops with Low-Cost UAV Imagery. *Remote Sensing* 8 (9), pp. 1–19.

Kombinierbares Routensystem für UAS

Combinable Route System for UAS

Mirko Bothe, Ludwig Schrenk

CiS GmbH, Hansestraße 21, 18182 Bentwisch

E-Mail: mbothe@cis-rostock.de; lschrenk@cis-rostock.de

Zusammenfassung: Für Befliegungen mit unbemannten Flugsystemen ist es sinnvoll einen Autopiloten einzusetzen, um die Bildaufnahme möglichst strukturiert durchzuführen. In diesem Beitrag werden die Planungsmöglichkeiten für Flugrouten in der Software UAV Mobile der CiS GmbH vorgestellt.

Deskriptoren: UAS, Flugplanung, Flugroutenerstellung

Abstract: *For aerial surveys with unmanned aerial systems it makes sense to use an autopilot, so that image acquisition is done as structured as possible. This text will introduce the options for flight route creation in the software UAV Mobile by CiS GmbH.*

Keywords: *UAS, flight planning, creation of flight routes*

1 Einleitung

Unbemannte Flugsysteme (UAS) werden heutzutage für die verschiedensten Zwecke eingesetzt. Neben einfachen Luftbildflügen spielen auch hochgenaue Vermessungsaufgaben mit Photogrammetrie und Inspektionsaufgaben eine Rolle. Für gute Ergebnisse müssen die Bilder dabei strukturiert aufgenommen werden, wobei der Einsatz eines Autopiloten mit entsprechenden an die Aufgabe angepassten Flugrouten hilft. Im Folgenden sollen die kombinierbaren Flugplanungsvarianten der Software UAV Mobile der CiS GmbH vorgestellt werden.

2 Flugplanungsarten

UAV Mobile bietet verschiedene Planungsmethoden, die zu unterschiedlichen Zwecken eingesetzt werden und im Folgenden näher beschrieben werden sollen. Die bei der Planung entstehenden Flugrouten können im Anschluss detaillierter angepasst werden (**Abschnitt 3**), auch wenn Sie für die meisten Anwendungen ausreichen sollten.

Bei jeder Planung müssen vom Nutzer bestimmte Parameter festgelegt werden, die teilweise auch von der Planungsart abhängig sind. In jedem Fall wird die Flughöhe, die Geschwindigkeit, die Kameraneigung und das Bildintervall (= Anzahl der Sekunden

zwischen zwei Auslösungen der Kamera) abgefragt. Abweichende oder zusätzliche Parameter werden bei der jeweiligen Planungsart genannt und beschrieben. Geplante Routen lassen sich einerseits direkt im Programm mit den CiS-Multikoptern „Oktopus“ verwenden. Andererseits bietet das Programm die Möglichkeit eine Flugroute in eine Textdatei zu exportieren. So lassen sich die geplanten Routen über die Schnittstelle *Litchi* (VC Technology Ltd, London) auch mit Fluggeräten der Firma DJI (DJI, Guangdong) verwenden.

Polygonplanung bzw. Wegpunktplanung

Die einfachste Art eine Flugroute zu planen besteht darin, eine bestimmte Flugroute festzulegen. Bei der Polygonplanung wird sich das Fluggerät standardmäßig immer in Flugrichtung drehen und nach vorne in Flugrichtung schauen. UAV Mobile bietet dabei verschiedene Möglichkeiten (**Abbildung 1**):

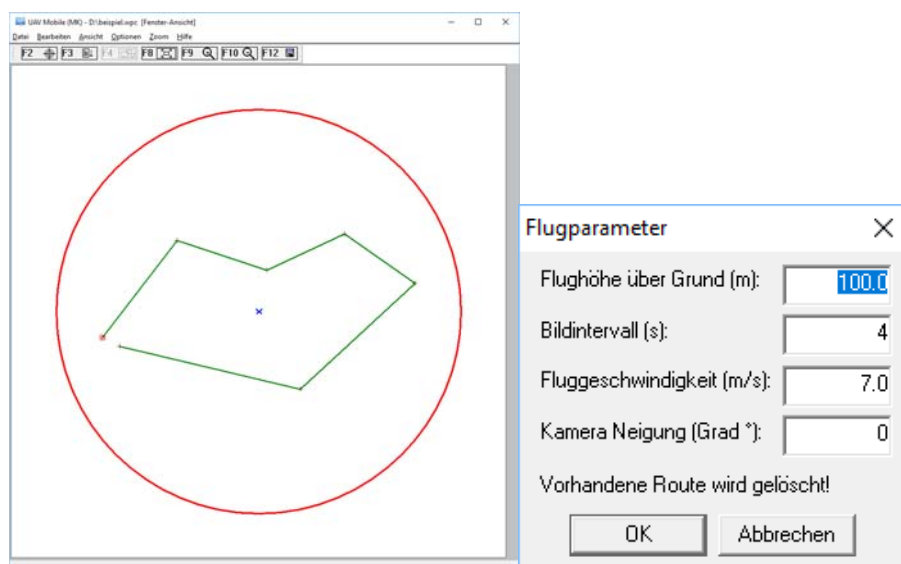


Abbildung 1: Screenshots der Flugplanungssoftware UAV-Mobile mit einer Übersicht der Flugroute und einer graphischen Eingabemöglichkeit weiterer Flugparameter

1. Flugstreckeneingabe mit der Maus
Nach dem Festlegen der Parameter kann mit Mausklicks im Kartenfenster eine Flugstrecke definiert werden.
2. Flugstreckeneingabe über Wegpunktauswahl
Wenn schon Wegpunkte vorhanden sind (können separat angelegt werden), können diese beliebig miteinander verknüpft werden. Die Auswahl wird mit der Maus in der Karte ausgeführt. Da die Wegpunkte schon über eine festgelegte Höhe verfügen, muss die Höhe in diesem Fall nicht eingegeben werden. Auch die Drehung in Flugrichtung wird nicht automatisch festgelegt (da dies über Programme der Wegpunkte definiert wird, siehe unten).

3. Flugstreckeneingabe über Polygonauswahl
Wenn eine fertige Strecke als Polygon importiert wurde (z.B. aus einer Shape- oder KML-Datei), kann auch ein solches Polygon ausgewählt und in eine Flugroute umgewandelt werden.
4. Flugstreckenimport aus einer Textdatei
Eine Datei, die eine Liste von Koordinaten enthält, kann eingelesen werden, um eine Flugroute zu erstellen. Die Höhe wird dabei aus der Datei eingelesen.

Flächenplanung

In vielen Fällen soll eine Befliegung einer Fläche durchgeführt werden, um z.B. daraus eine Karte oder ein Orthofoto zu erstellen. Um eine flächendeckende Abbildung des Gebietes mit ausreichender Überlappung der Einzelfotos herzustellen, enthält UAV Mobile eine entsprechende Funktion zur Generierung von Flugrouten. Als zusätzliche Parameter sind hier die gewünschte Überlappung und der Öffnungswinkel der Kamera (abhängig vom Objektiv) einzustellen, sowie eine Flugrichtung einzugeben (**Abbildung 2**). Außerdem muss die Umrandung der Fläche in Form eines Polygons vorhanden sein (kann im Programm gezeichnet oder importiert werden). Das Programm berechnet anschließend aus den Parametern eine Flugbahn, die die gesamte Fläche abbildet.

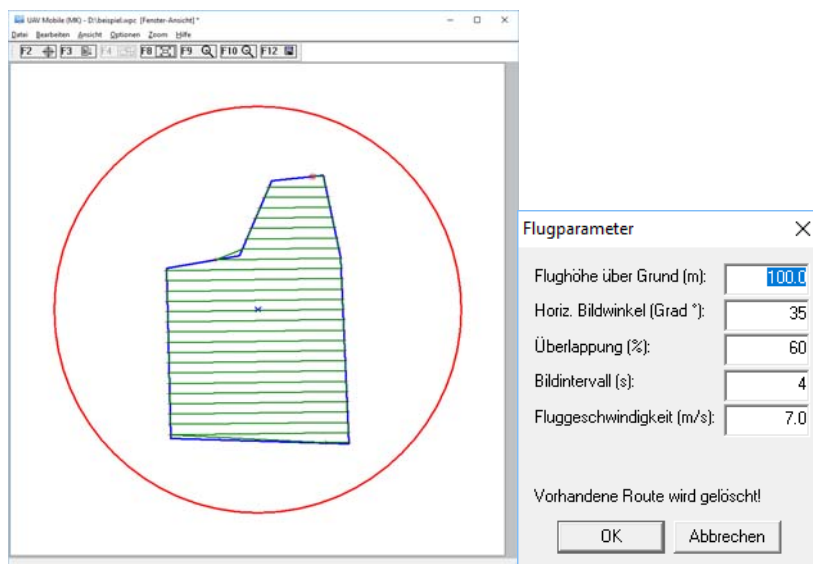


Abbildung 2: Screenshots der Flugplanungssoftware UAV-Mobile mit erfolgter Flugrouten- und Flächenplanung

Konturplanung

Eine weitere Möglichkeit besteht darin, eine gegebene Fläche zu umfliegen und mit einer geneigten Kamera in die Fläche zu blicken. Wenn die Fläche den Grundriss eines Gebäudes darstellt, lassen sich so z.B. Fotos der Fassade aufnehmen. Zusätzlich zu den Standardparametern lassen sich hier noch die Umrundungsrichtung, der Abstand

zur Kontur und der Blickwinkel relativ zur Flugrichtung festlegen. Auch ein Startpunkt auf der Kontur kann bestimmt werden. Es gibt außerdem eine Vorschaufunktion zur Visualisierung der Flug- und Blickrichtung (**Abbildung 3**). Eine Einschränkung ist bei dieser Funktion allerdings, dass nur konvexe Flächen befliegen werden können. Für nichtkonvexe Flächen bietet das Programm jedoch die konvexe Hülle als Option an.

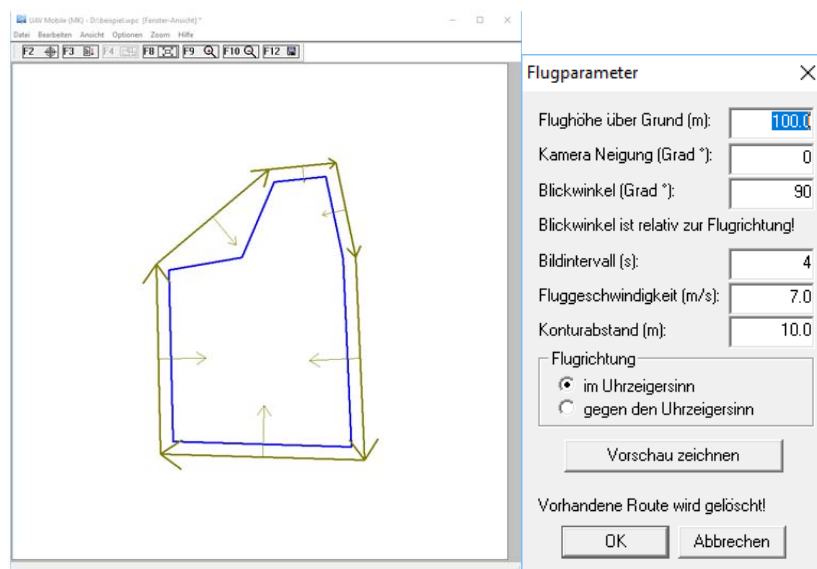


Abbildung 3: Screenshots der Flugplanungssoftware UAV-Mobile mit erfolgter Flugrouten- und Kontourplanung

Fassadenplanung (Einzelfassade)

Eine systematischere Befliegung einer Fassade (vergleichbar mit einer vertikalen Flächenplanung) lässt sich in UAV Mobile ebenfalls planen. Bei der Planungsmethode „Einzelfassade“ wird eine Kante einer Gebäudeumrandung ausgewählt und dann anhand der Parameter eine Flugbahn berechnet. In diesem Fall müssen zwei Höhen eingegeben werden: eine obere und eine untere Flughöhe. Außerdem muss der Abstand der einzelnen Flugbahnen und der Abstand zur Fassade gewählt werden, sowie die Hauptflugrichtung (horizontal oder vertikal) und ein Startpunkt (z.B. links-oben) festgelegt werden.

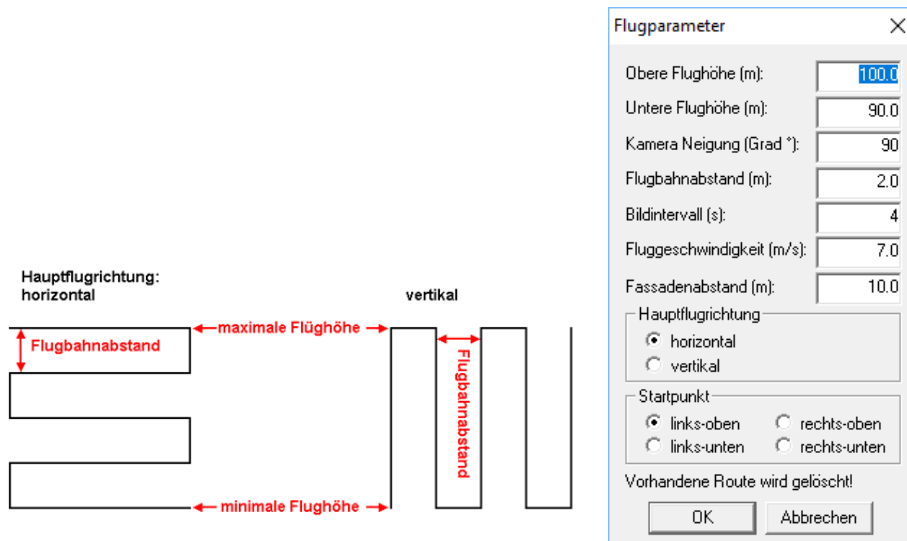


Abbildung 4: Screenshots der Flugplanungssoftware UAV-Mobile mit erfolgter Fassadenplanung

Fassadenplanung (Gebäude)

Eine Fassadenplanung für das gesamte Gebäude (mit derselben Einschränkung bezüglich nichtkonvexer Flächen wie bei der Konturplanung) besteht ebenfalls (**Abbildung 4**). Die Einstellungsmöglichkeiten sind dabei ähnlich wie bei der Einzelfassade. Die Hauptflugrichtung ist jedoch festgelegt (vertikal). Stattdessen kann man wie bei der Konturbelegung wählen, ob das Gebäude im oder gegen den Uhrzeigersinn umrundet werden soll. Der Startpunkt auf der Kontur wird ebenfalls gewählt, und man hat die Wahl, ob der Startpunkt unten oder oben liegen soll.

3 Anpassung von Flugplanungen

Wie oben beschrieben gibt es weitere Optionen, eine vorgeplante Route weiter anzupassen. Es ist möglich, verschiedene Planungen zu verbinden, einzelne Punkte zu manipulieren, Aktionen an Punkten ausführen zu lassen, die Flughöhe an das Gelände anpassen zu lassen oder stichprobenartig auf eine niedrigere Flughöhe zu gehen, um Detailaufnahmen zu erstellen.

Verbindung verschiedener Planungsarten

Normalerweise wird bei einer neuen Planung die bestehende Route gelöscht. Es gibt aber auch die Möglichkeit, eine Route um eine weitere Planungsart zu erweitern. Die neugeplanten Wegpunkte werden dabei ans Ende der bestehenden Route angehängt. Es lassen sich alle Planungsarten in beliebiger Reihenfolge miteinander verknüpfen. Auch eine bereits erweiterte Route lässt sich wieder erweitern, so dass z.B. flächenhafte Befliegungen benachbarter Flächen inkl. Konturflug in einer einzigen Planung gespeichert werden können.

Editieren von Wegpunkten

Wegpunkte können gelöscht, verschoben oder eingefügt werden. Für jeden Wegpunkt können einzelne Aktionen (siehe nächster Abschnitt) oder eine andere Flughöhe festgelegt werden (**Abbildung 5**).

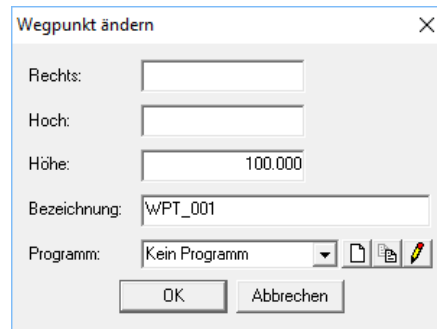


Abbildung 5: Eingabefenster in der Planungssoftware UAV-Mobile zum Ändern von Wegpunkten

Ausführung von Aktionen an Wegpunkten

An jedem Wegpunkt lassen sich kleine Programme aus bestimmten vordefinierten Befehlen anhängen, die einerseits Aktionen an diesem Punkt ausführen (z.B. Aufnahme von Bildern, warten, drehen), andererseits aber auch das Verhalten auf den folgenden Flugstrecken festlegen (z.B. andere Geschwindigkeit oder Blickrichtung). Programme können dabei in einer programminternen Datenbank gespeichert und somit in anderen Planungen wiederverwendet werden.

Anpassung an Geländemodelle

Falls für das zu befliegende Gelände ein digitales Geländemodell vorliegt, lässt sich die Flugplanung so anpassen, dass die Flughöhe (in gewissen einstellbaren Toleranzgrenzen) über der Geländeoberfläche konstant bleibt. Ohne eine solche Anpassung beziehen sich die Flughöhen grundsätzlich auf den Startpunkt. Zu diesem Zweck werden an Punkten, wo die Abweichung zwischen idealer Flughöhe laut Geländemodell und der tatsächlichen Flughöhe zu groß wird, neue Wegpunkte mit der idealen Flughöhe eingefügt.

Stichprobenartiges Absenken der Flughöhe

Es gibt Fälle, in denen es interessant sein kann, einerseits einen groben Überblick über eine Fläche aus größerer Höhe zu erhalten, aber auch stichprobenartige Detailaufnahmen eines Teilgebiets in geringer Flughöhe zu haben. Zu diesem Zweck kann für eine Fläche eine Stichprobennahme geplant werden. Man definiert einen Abstand und eine Höhe und wählt eine Fläche aus, in der dann mit dem eingegebenen Abstand entlang der bestehenden Flugroute Punkte angelegt werden, an denen die Flughöhe entspre-

chend reduziert und ein Bild aufgenommen wird. Anschließend kehrt das Fluggerät wieder auf die alte Höhe zurück und fliegt zum nächsten Punkt.

Flugunterbrechungen und Rückflughöhe

Bei einem Flug mit einem CiS-Multikopter („Oktopus“) kann ein Flug entweder manuell oder bei niedrigem Akkustand automatisch unterbrochen werden. UAV Mobile wird dann beim nächsten Startversuch anbieten, die Flugroute am Punkt der Unterbrechung fortzusetzen. Somit ist es möglich, auch längere Flüge sinnvoll durchzuführen, ohne nach einer Unterbrechung eine neue Planung durchführen zu müssen. Außerdem lässt sich eine Rückflughöhe definieren. Das Fluggerät steigt dann am Ende der Route auf die gewünschte Höhe und kann somit problemlos mögliche Hindernisse auf dem Rückweg überfliegen.

4 Zusammenfassung

Durch die Kombinierbarkeit verschiedener Flugplanungsarten und die späteren Anpassungsmöglichkeiten bietet UAV Mobile die Möglichkeit, für verschiedenste Flugaufgaben und Umgebungen eine angepasste Flugroute zu planen. Durch die Exportfunktion kann eine Flugplanung für verschiedene Systeme verwendet werden.

Unsupervised clustering of remote sensing data from kiwifruit (*A. deliciosa* var. *Hayward*) orchards affected by kiwifruit decline

Unüberwachtes Clustering von Fernerkundungsdaten aus Obstplantagen von Kiwifrüchten (*A. deliciosa* var. *Hayward*), die von Kiwifruit decline betroffen sind

Francesco Savian^{1*}, Marta Martini¹, Paolo Ermacora¹, Luca Zuliani², Stefan Paulus³
and Anne-Katrin Mahlein³

¹*Department of food, environmental agricultural and animal sciences,
University of Udine, Udine, Italy*

²*Adron technology srl, Udine, Italy*

³*Institute of Sugar Beet Research (IfZ), Göttingen
E-Mail: *Francesco.savian@uniud.it*

Zusammenfassung: Seit 2012 bedroht eine neue Krankheit mit dem Namen „Kiwifruit-Divide“ die Kiwifrucltplantagen in den nördlichen Regionen Italiens. Kranke Pflanzen weisen ein stark befallenes Wurzelsystem auf, das nach den ersten Hitzewellen zu einem plötzlichen und irreversiblen Welken des Blattapparates der Pflanzen führt. RGB-, Multispektral- und Wärmedaten wurden in zwei aufeinander folgenden Jahren (2017–2018) gleichzeitig von einem Feld mit erkrankten Pflanzen unter Verwendung einer UAV-Plattform erfasst. Die Einzelbilder wurden für jeden Sensor einzeln und separat für jedes Jahr zusammengefügt. Nach der Extrapolation der Koordinaten der Pflanzreihenenden wurde die Bilddaten durch iterative Reduzierung auf eine nicht überlappende *Region of Interest* (ROI) entlang der Pflanzreihen segmentiert. Der *K-means Clustering* Algorithmus wurde auf die reduzierten Daten angewendet, um multispektrale und thermische Daten der Erhebung aus dem Jahre 2017 zu analysieren. Für jede ROI wurden die Vigorklassen und -änderungen des Gesundheitszustandes zwischen den Jahren 2017 und 2018 durch Experten geschätzt und als *Ground Truth* für die Interpretation des *Clustering* verwendet. Die multispektralen Daten zeigten eine hohe Korrelation mit der Vitalität der Pflanze, während Temperaturdaten ein hohes Potenzial für Prognosen zur Gesundheitsverschiebung zu bieten scheinen. Dies gilt insbesondere für Pflanzen, die 2017 eine starke Vitalität aufwiesen und 2018 abstarben.

Deskriptoren: Fernerkundung, multispektrale Bildgebung, Wärmebildgebung, UAV, Kiwi Früchte

Abstract: Since 2012, a new disease called “kiwifruit decline” is threatening kiwifruit orchards in the northern regions of Italy. Diseased plants show a heavily compromised root system, which lead the plants to a sudden and irreversible wilting of the canopy after the first heat waves. RGB, Multispectral and Thermal data were acquired simultaneously over one field with diseased plants for two consecutive years (2017–2018) using a UAV platform. Single images were stitched together independently for each sensor and for each year. After the extrapolation of the coordinates of the planting line endings, data reduction was applied by iterative cropping small areas along the planting lines. K-mean algorithm was used on the reduced data to cluster multispectral and thermal data of 2017 survey. For each cropped area, vigour class and health shifting between 2017 and 2018 were estimated via expert assessment and used as ground truth for the interpretation of the clustering. Multispectral data showed high correlation with plant vigour, while temperature data seems to have good potential for health shift predictions especially for plants that had high vigor in 2017 and died in 2018.

Keywords: Remote sensing, multispectral imaging, thermal imaging, kiwifruit decline, UAV

1 Introduction

Since 2012, a new major treat to kiwifruit growing has been added to the renowned *Pseudomonas syringae* pv. *artinidiae* (PSA) bacterial cancer. Up to now, this disease known as kiwifruit decline caused consistent losses in the north of Italy (Veneto, Piedmont and Friuli Venezia Giulia regions) and first report are now coming even from Lazio and Calabria (SORRENTI *et al.* 2019, *in press*). To our knowledge, this disease is limited to Italy but several articles report vine decline like disease from other countries: Turkey (AKILLI *et al.* 2011; KURBETLI & OZAN 2013), Japan (HUANG & QI 1998), and New Zealand (REID *et al.* 1992). However, a direct connection with these reports is difficult mostly because not all the symptoms coincide. Furthermore, the description of the evolution of the symptoms for more than one years is usually missing. Overall, it seems kiwifruit decline in Italy has a higher intensity, faster spreading and last even after replanting.

The symptoms are visible in July and August when the first heat waves arrive, the canopy is fully expanded and the fruit are in the middle of their ripening phase. No symptoms in the canopy are clearly visible before the first heat waves arrive. Within few weeks the canopy pass from a green and healthy state to a fast and irreversible wilting process that usually bring the plant to death. The following years, the plants that manage to survive shows a consistent reduction of the canopy and if some fruits are produced they will never reach full ripening. Above ground symptoms are the result of a highly compromised root system with no or very few feed roots. The coarse roots show a reddish discoloration under the cortex and the external cylinder is easily detachable from the central one creating a specific symptom called “rat tail” (TACCONI *et al.* 2014, 2015; SORRENTI *et al.* 2016). The cause of the disease is still unknown but it seems that waterlogged condition do play a significant role in the induction of the symptoms. Still

submersion conditions alone are not enough and the involvement of some biotic factor is more than probable.

When studying unknown biotic factors in decline-like disease, one of major problem is the timing and the positioning of the sampling. For kiwifruit decline, this aspect is critical since when the symptoms are visible in the canopy, almost all the root tissue are rotten and therefore not informative for diagnosis purposes. Remote sensing can support open field surveys highlighting differences between healthy and diseased plants through the analysis of the canopy temperature and reflectance in the bands between 400–1000 nm (MAES & STEPPE 2012; CALDERÓN *et al.* 2013; MAHLEIN 2015; ZARCO-TEJADA *et al.* 2018). These differences can be used to identify homogenous areas within the field, where samples should be collected for laboratories analyses. Free satellite images usually do not have the spatial resolution for disease detection, while ground surveys in kiwifruit orchards are usually time consuming especially due to the wide canopy that limits the movement and reduces the field of view. UAV surveys can be a good compromise between resolution and acquisition time. The outputs of these surveys are a high spatial resolution orthomosaic map derived by the stitching of many frames.

This study presents an approach to apply clustering procedures to UAV orthomosaic photos acquired over fields affected by kiwifruit decline. RGB, multispectral and thermal images were acquired using a multi-copter drone and images were stitched together to create one orthomosaic for each sensor. Data reduction was applied by iterative cropping small areas along the planting lines and saving the statistics of each cropped area in a matrix. The K-mean algorithm was used to cluster multispectral and thermal data. Interpretation of the clusters was finally made by comparing the clusters with two references: plant vigor of and plant health shifting.

2 Material and methods

UAV based surveys were performed over one hectare of kiwifruit (*A. deliciosa* var *Hayward*) in San Giorgio della Richinvelda (Italy). First symptoms of kiwifruit decline were spotted in 2015 after an irrigation pipe broke in the central rows. Later in 2016, the disease rapidly spread towards the border compromising almost the whole field. From 2017, the field was regularly inspected to check the disease spreading patterns. In 2017, the disease compromised almost all the orchard and in 2018 only few plants in the eastern border were still showing high canopy vigor.

An overall picture of the processing workflow is reported in **Figure 1**. In August 2017 and 2018, UAV flights were performed using a SAPR six-rotor with a maximum payload of 4kg using RTK-GPS and a gimbal system on two axis (Adorn-technologies srl. – Italy). Thermal-Multispectral-RGB datasets were acquired simultaneously 35 m over the canopy. In 2017, the acquisition combined the three sensor reported in **Table 1**, while in 2018 the RGB and multispectral sensor were changed on behalf of Sequoia+ sensors (Parrot s.a. – France). For this study, only data from 2017 and RGB data of 2018 has been used. Snapshots of each sensor were stitched together to create three georefer-

enced orthomosaic with the software Pix4D (Pix4D s.a. – Switzerland). Temperature values (°C) were derived from the FIR wavelength using the software FLIR-studio (FLIR System Inc. – USA) before the stitching. Acquisition, stitching and ortho correction were performed by Adorn technology srl. (Italy). RGB data was used to evaluate the reference for plant vigor the plant health shifting between 2017 and 2018, while 2017 multi-spectral and thermal data were used for clustering analysis.

The alignment between orthomosaic pictures and the coordinates of the northernmost and southernmost points were checked/extrapolated for each planting line using Qgis software (TEAM 2016). After that, all the processing work has been performed in R (TEAM 2013).

Single band orthomosaic pictures were extracted from the multispectral maps and reflectance values were scaled in a range from 0 to 1. Green and red bands were decorrelated from the NIR band using the formula $R_{adj} = R_{ini} - RNIR * 0.8$, where R_{adj} is the corrected wavelength value, R_{ini} is the initial band value and RNIR is the wavelength value in the NIR spectrum. This correction reduced the R2 correlation to 0.64 between red and NIR band and from to 0.81 between green and NIR band. Temperature values were not modified after the stitching.

Table 1. Sensor characteristics of 2017 survey

Sensor type	Sensor name	Wavelength*			Spatial res.*	Use
RGB	GoPro 4 (GoPro Inc.- USA)	RED	0.66	0.40-0.70	1	Vigor and health shifts assessment
		GREE	0.55	0.40-0.70		
		N				
		BLUE	0.47	0.40-0.70		
Multisp.	Tetracam ADC snap (Tetracam Inc.USA.)	NIR	0.79	0.52-0.90	4	Clustering
		RED	0.66	0.52-0.90		
		GREE	0.55	0.52-0.90		
		N				
Thermal	Thermal Capture 2.0 640 (FLIR system Inc.–USA)	FIR	10.00	7.5-13.5	7	Clustering

* wavelength central band and ranges in μm ; spatial resolution in cm/pixels of the stitched images at 35m over the canopy

A rough segmentation algorithm was applied to each single band and thermal orthomosaic. As first attempt, the segmentation has been made using a mask that moves along each planting line. The mask moves from the north to south and from east to west cutting a circle of 1 m radius from the center of the planting line to avoid interference from background pixels of the inter row grass.

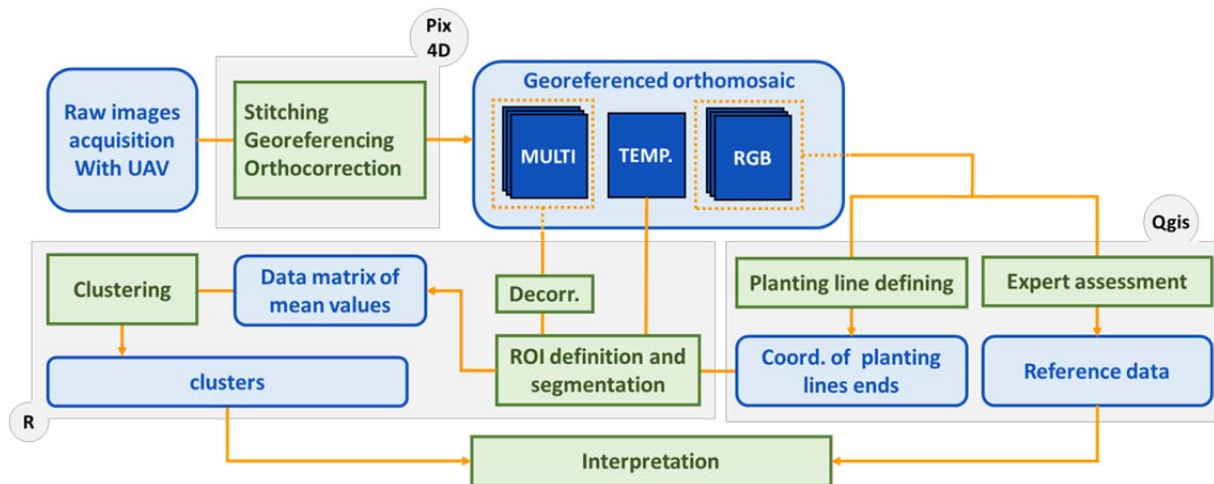


Figure 1. Work flow chart showing dataflow in the algorithm. Blue boxes represent data, green boxes activities and in grey the different software packages used in this study.

The distance between two consecutive cropping was based on the assumption to have balance between computational time (less than 1.5 h) and resolution (at least three clip-pings per plant). For each clip the mean value was evaluated and stored in a matrix together with the coordinates of the center of the mask. This matrix was used as input for the clustering analysis. Clustering was performed separately for a number of clusters between two and four for multispectral (NIR and red bands) and thermal data. Results were compared with the reference value of plant vigor in 2017 and plant health shifting between 2017 and 2018.

The reference value for each clipped area was evaluated via expert assessment looking at the RGB data. A value from one to four, with one is high vigor and four is a dead plant, has been assigned to each clipped area for the year 2017 and 2018. Plant health shifts were then extracted associating a ranking from minus five to one based on the difference between the plant vigor classes in 2017 and 2018 (**Table 2**). This ranking is based on the assumption that the bigger is the difference between health state between 2017 and 2018, the lower value of the class will be. Plants that show no changes in the vigor class were instead classified as zero for plants always dead or with weak vigor and one for always high or medium vigor plants. Positive shifting of vigor class (from lower to higher) was observed only between V2 classes in 2017 that became V1 in 2018. Those shifting were treated as unchanged healthy plants assigning.

Table 2. Assignment of vigor classes and rankings of plant health shifts.

Plant vigor classes							
Vigor Class	High		Medium		Low		dead
	V1		V2		V3		V4
Plant health shift							
Vigor class in 2017	V1	V1	V2	V2	V3	V3-V4	V1 or V2
Vigor class in 2018	V4	V3	V4	V3	V4	V3-V4	V1 or V2
Ranking	-5	-4	-3	-2	-1	0	1
Class	P1	P2	P3	P4	P5	P6	P7

3 Results and discussion

Thermal data seems not to be good indicator for predicting canopy vigor, but seems to have the potential for predicting disease outbreaks (**Figure 2** and **Table 4**). In fact, regardless of the number of cluster, temperature clusters never follow the distribution of vigor classes. Instead, it is interesting the correlation between temperatures the plant health shifting occurred to plant classified with higher vigor class in 2017. With two clusters, plants with high vigor in 2017 that died in 2018 were clearly split from the plants that instead remain healthy. This could allow the prediction of the disease outbreaks one year in advance for those plants that were undistinguishable using only human eye detection. The differences in the temperature of these two clusters were around 1.5°C, enough to consider this result reliable. Therefore, Canopy temperature could be a good indicator to focus monitoring and sampling in the field. As the number of clusters increase, there is no clear splitting within the middle classes but the number of misclassified plants (hot=healthy with no shift, cold=dead but with higher vigor class in 2017) decrease. Even if the overall prediction of future outbreaks based on temperature alone is not high for each cluster class x tested so far, sampling plant based on canopy temperature could lead to a breakthrough in the quality of the sample for laboratory analysis and in the understanding the etiology of kiwifruit decline.

Multispectral data provides good results for the evaluation of dead plants and for the estimation of the canopy vigor (**Figure 2** and **Table 3**). With two clusters, it was possible to discriminate between dead and alive plants with an accuracy of 83%. With the increasing of cluster numbers, the overall accuracy of the clustering also increases. Using tree clusters, almost all the clips with dead plants (V4) were classified in one cluster and healthy plant (V1 and V2) grouped in cluster C1. With four clusters, there is a clear distribution of the class according to the vigor index, with each cluster characterized by a dominant class. Regarding the plant health shift, there is no clear association between clusters and disease spread. It seems that multispectral bands can picture the phytosanitary states of plants with healthy or already compromised root system, but failed when predicting future outbreaks.

Several improvements need to be done to this processing pipeline (**Figure 1**) starting from a more refined segmentation process that should take into account dead plants and holes within the canopy. For this purpose, multispectral bands do have good potential to develop indices for masking the canopy. Thermal imaging has proven to be a resourceful information for kiwifruit decline detection especially in those plants that are not showing symptoms.

4 Conclusion

To conclude, the method we propose rapidly explores and analyzes data from UAV surveys, allowing its use in open field scouting activities. Unsupervised clustering could indeed be a useful technique to support the studying of unknown soil-borne pathosystems. Finally, the validity of thermal images for the prediction of kiwifruit decline outbreaks and of multispectral data for vigor classification has been shown.

Table 3. Interpretation of multispectral data clustering vs plant vigor and health shift.

Clustering	Vigour				Plant health shift							
	N of cluster	High	Med	low	dead	High to dead	High to weak	Med to dead	Med to week	Weak to dead	no shift dead	no shift Healthy
2	C1	99	92	49	2	100	97	87	92	36	22	96
	C2	1	8	51	98	0	3	13	8	64	78	4
3	C1	81	45	8	0	50	77	37	46	7	3	68
	C2	19	53	68	7	50	23	59	52	57	32	30
	C3	0	2	24	92	0	0	4	2	37	64	1
4	C1	60	14	2	0	42	54	13	13	2	0	45
	C2	37	67	20	1	50	42	61	65	18	8	45
	C3	3	19	69	13	8	3	22	21	66	35	10
	C4	0	1	9	86	0	0	4	1	15	57	0

Table 4. Interpretation of thermal data clustering vs plant vigor and health shift.

Clustering	Vigour				Plant health shift							
	N of cluster	High	Med	low	dead	High to dead	High to weak	Med to dead	Med to week	Weak to dead	no shift dead	no shift Healthy
2	C1	60	59	50	62	17	47	41	54	44	59	73
	C2	40	41	50	38	83	53	59	46	56	41	27
3	C1	36	29	24	38	0	22	11	26	18	34	47
	C2	46	51	45	42	42	55	54	54	41	44	42
	C3	18	20	30	20	58	23	35	20	41	22	11
4	C1	17	13	13	19	0	7	4	11	8	17	24
	C2	39	39	32	37	8	37	33	34	31	35	45
	C3	36	34	36	28	58	50	35	41	33	32	25
	C4	9	14	19	16	33	7	28	15	28	15	6

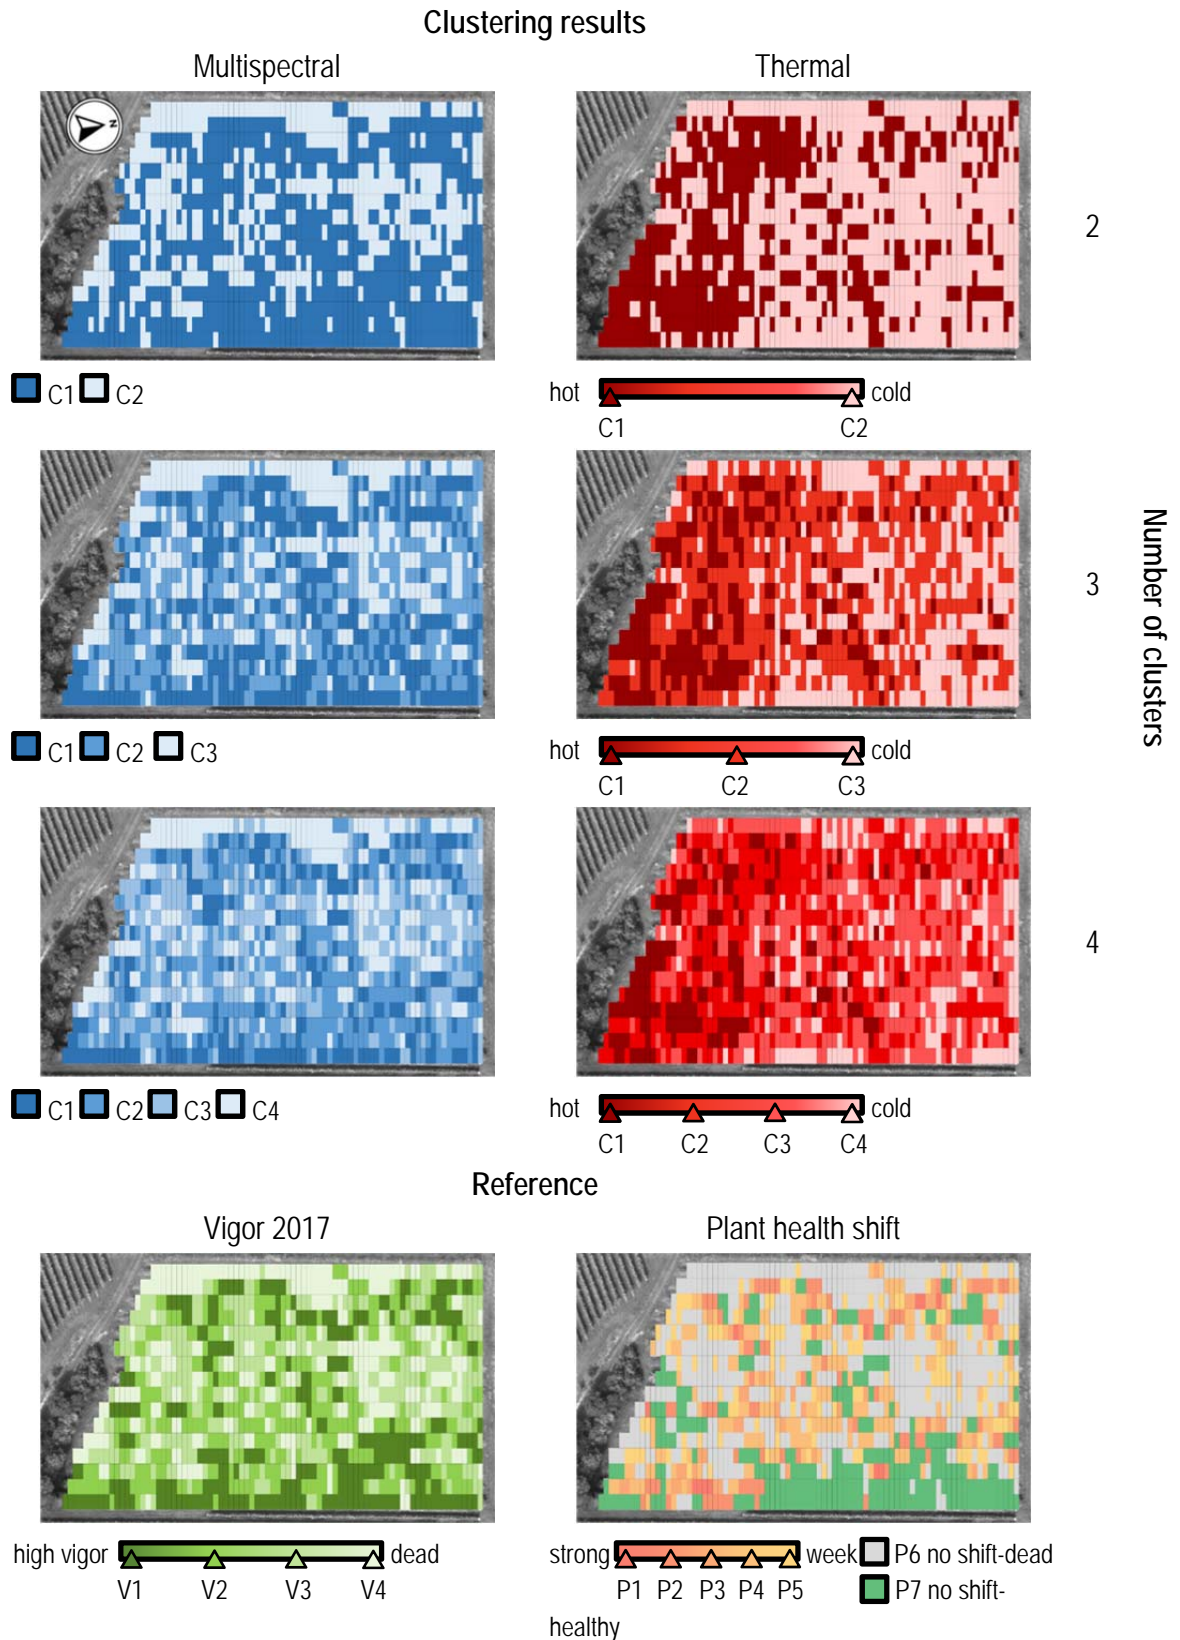


Figure 2. Results obtained after clustering and reference used for the interpretation. Blue scale is used for clustering derived by multispectral bands; Red scale is used for temperature, Green scale for the assessment of the vigor class (V1 high, V2 medium, V3 week, V4 dead). Mixed color composition is use to represent the plant health shift between 2017 and 2018, orange scale is used for plant that get diseased in 2018 (from P1 high shift to P5 small shift), while gray and green was respectively used of always dead plants and always healthy plants.

References

- AKILLI S., SERÇE ÇI.U., ZEKAİ KATIRCIOĞLU Y., KARAKAYA A. & MADEN S. (2011):** Involvement of *Phytophthora citrophthora* in Kiwifruit Decline in Turkey. – *Journal of Phytopathology*, 159 (7–8): 579–581.
- CALDERÓN R., NAVAS-CORTÉS J.A., LUCENA C. & ZARCO-TEJADA P.J. (2013):** High-resolution airborne hyperspectral and thermal imagery for early detection of *Verticillium* wilt of olive using fluorescence, temperature and narrow-band spectral indices. – *Remote Sensing of Environment*, 139: 231–245.
- HUANG Y. & QI P. (1998):** Studies on the cause of root rot of kiwifruit in Guangdong Province. – *Journal of South China Agricultural University*, 19 (4): 19–22.
- KURBETLI İ. & OZAN S. (2013):** Occurrence of *Phytophthora* Root and Stem Rot of Kiwifruit in Turkey. – *Journal of Phytopathology*, 161 (11–12): 887–889.
- MAES W.H. & STEPPE K. (2012):** Estimating evapotranspiration and drought stress with ground-based thermal remote sensing in agriculture: a review. – *Journal of Experimental Botany*, 63 (13).
- MAHLEIN A.-K. (2015):** Plant Disease Detection by Imaging Sensors – Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping. – *Plant Disease*, 100 (2): 241–251.
- REID J.B., TATE K.G. & BROWN N.S. (1992):** Effects of flooding and alluvium deposition on kiwifruit (*Actinidia deliciosa*). – *New Zealand Journal of Crop and Horticultural Science*, 20 (3): 283–288.
- SORRENTI G., TOSELLI M., REGGIDORI G., SPINELLI F., TOSI L., GIACOPINI A. & TACCONI G. (2016):** Implicazioni della gestione idrica nella “Moria del kiwi” del veronese. – *Frutticoltura*, 3.
- SORRENTI G., TACCONI G., TOSI L., VITTONI G., NARI L., SAVIAN F., SARO S., ERMACORA P., GRAZIANI S., TOSELLI M. (2019):** Avanza la “Moria del kiwi”, evoluzione e primi riscontri della ricerca. *Frutticoltura*, 1.
- TACCONI G., GIACOPINI A. & TOSI L. (2014):** La Moria Del Kiwi Nel Veronese. – *Kiwi informa*, Aprile/Giugno: 5–23.
- TACCONI G., PALTRINIERI S., MEJIA J.F., FUENTEALBA S.P., BERTACCINI A., TOSI L., GIACOPINI A., MAZZUCCHI U., FAVARON F., SELLA L. & BERTAIOLA F. (2015):** Vine decline in kiwifruit: climate change and effect on waterlogging and *phytophthora* in north italy. – *Acta Horticulturae* (1096): 93–97.
- TEAM Q.D. (2016):** QGIS geographic information system. – Open Source Geospatial Foundation Project.
- TEAM R.C. (2013):** R: A language and environment for statistical computing. – .
- ZARCO-TEJADA P.J., CAMINO C., BECK P.S.A., CALDERON R., HORNERO A., HERNÁNDEZ-CLEMENTE R., KATTENBORN T., MONTES-BORREGO M., SUSCA L. & MORELLI M. (2018):** Pre-visual symptoms of *Xylella fastidiosa* infection revealed in spectral plant-trait alterations. – *Nature Plants*, 4 (7): 432.

Berechnung des *Morisita-Index of dispersion* in digitalisierten Feldaufnahmen

Calculation of the Morisita index of dispersion in digital field images

Michael Pflanz¹ und Hannes Hegewald²

¹Leibniz-Institut für Agrartechnik und Bioökonomie e.V. (ATB),
Max-Eyth-Allee 100, 14469 Potsdam

²Julius Kühn-Institut, Institut für Anwendungstechnik im Pflanzenschutz,
Messeweg 11–12, 38104 Braunschweig
E-Mail: mpflanz@atb-potsdam.de

Zusammenfassung: Der *Morisita-Index of dispersion* beschreibt die räumliche Verteilung von Individuen innerhalb einer Population bzw. Flächeneinheit. Er kann dazu verwendet werden, die Applikationsgenauigkeit von Präzisionsanwendungen in der Landwirtschaft (z.B. Gleichstandssaat) zu bewerten. Die Markierung von Individuen erfolgt bisher weitgehend manuell innerhalb einer fest eingestellten Rastergröße. Durch die photometrische Aufnahme des zu untersuchenden Flächensegments, kann die Auszählung am PC erfolgen. Hierzu wurde eine Methode entwickelt, mit dessen Hilfe Einzelpflanzen reproduzierbar markiert und damit verortet werden können. Die Berechnung des *Morisita-Index* erfolgt an Hand der Distanzen zwischen den im Bild gesetzten Marker und kann auf verschiedene Rastergrößen angewendet werden. Eine systematische Optimierung der Rastergröße ist auf diese Weise möglich.

Deskriptoren: *Morosita Index*, digitale Feldaufnahmen, PC Bonitur

Abstract: *The Morisita index of dispersion describes the spatial distribution of individuals within a population or an area unit. It can be used to evaluate the application accuracy of precision applications in agriculture (e.g. uniform seed pattern). Up to now, the labeling of individuals has mostly been done manually within a fixed grid size. By using a photometric acquisition of area segments the counting can be done later on the office computer. For this purpose a method was developed, which supports a reproducibly localization of individual plants. The calculation of the Morisita index is based on the distances between the markers set in the image and can be applied to different grid sizes. A systematic optimization of the grid size is possible in this way.*

Keywords: *Morosita Index of dispersion, digital field images, PC sampling*

1 Einleitung

Bei der Bewertung der Applikationsgenauigkeit von Präzisionsanwendungen in der Landwirtschaft (Gleichstandssaat oder Pflanzenschutzanwendungen) ist es erforderlich, die räumliche Aggregation von Pflanzen (Nutzpflanzen oder Unkräuter) auf einer bestimmten Flächeneinheit zu bestimmen.

Allgemein ist die Analyse der räumlichen Verteilung von Individuen ein wichtiges Instrument der Pflanzenforschung (TILMAN & KAREIVA 1997; DIECKMANN *et al.* 2000). In der Agrarforschung sind räumlich hochauflösende Informationen über die Verteilung von Pflanzen im Feld und geeignete Analysemethoden notwendig, um die Auswirkungen der räumlichen Aggregationen auf die pflanzenbauliche Effizienz (z.B. Ertrag) quantifizieren und bewerten zu können. Um die Aggregation von Einzelpflanzen auf einer Fläche zu bestimmen, kann der *Morisita-Index of Dispersion* herangezogen werden (MORISITA 1959, 1962; TSUJI & TSUJI 1998; TSUJI & KASUYA 2001; CRESSIE 2015). Dieser Index basiert auf einer Auszählung von Treffern in zufälligen oder regelmäßigen Rastern (Quadraten) und ist vergleichbar mit Messungen räumlicher Muster zur Bestimmung von Varianz-Mittelwert-Verhältnissen (KREBS 1989; DALE *et al.* 2002). Da der Morisita-Index für verschiedene Rastergrößen berechnet werden kann, ist die Skala der Analyse nicht inhärent.

Für die Berechnung des Morisitas Index sollte das Rastermaß des Flächenausschnitts (Stichprobeneinheit) im Verhältnis zur Zielfläche klein sein (CRESSIE 2015). Dies vorausgesetzt nimmt der Index dann valide Werte zwischen 0 (einheitlich) über 1 (zufällig) bis hin zum Wert Q (aggregierte Anordnung, alle Pflanzen befinden sich in einem Rasterquadrat) an. Allerdings können bei Verwendung des Index von Morisita kleinräumige Informationen verloren gehen, wenn positionsbezogene Daten (x-, y-Koordinaten) innerhalb eines Quadrates in Zählraten konvertiert werden (CRESSIE 2015). Durch ein genügend kleines Raster, könnte die räumliche Information folglich besser aufgelöst werden. Dies ist bei einer Feldbeprobung jedoch nicht praxistauglich. Berechnet wird der *Morisita-Index of dispersion* nach der Formel:

$$I = Q \frac{\sum_{i=1}^Q n_i (n_i - 1)}{N(N - 1)}$$

Hierbei sind:

Q = Anzahl der Quadrate auf dem untersuchten Flächenausschnitt

n = Anzahl der Pflanzen im Quadrat I

N = Gesamtanzahl an Pflanzen im untersuchten Flächenausschnitt.

2 Material und Methoden

Für die halbmanuelle Umsetzung der Morisita-Berechnung am PC wurde ein Matlab-Skript (Matlab Version 2016b, The Mathworks, USA) und eine grafische Benutzeroberfläche entwickelt. Voraussetzung für die Berechnung sind digitale Feldaufnahmen, die äquidistant über der Bodenoberfläche aufgenommen werden. Hierzu wurde ein Zählrahmen konstruiert, der ein Quadrat mit festgelegten Abmessungen (50 x 50 cm) am Boden aufspannt und die Kamera in einer ebenfalls festen Höhe hält (**Abbildung 1**). Die reale Größe des Rahmens kann innerhalb der Morisita-GUI eingestellt werden. Mittels `imcrop` wird der Ausschnitt in Rahmengröße innerhalb der GUI freigestellt und abgespeichert. Morisita-GUI speichert die manuell verorteten Pflanzenpositionen in einer Textdatei ab, welche nachträglich geladen werden kann und die zuvor durchgeführte Verortung erneut in das Bild überträgt.



Abbildung 1: Kamerahalterung und 50 x 50 cm Rahmen für die Feldbonitierung

Für eine erste Abschätzung der Funktionsweise und Plausibilität der Ergebnisse wurden Feldaufnahmen mit einer handelsüblichen RGB-Kamera (Alpha 6000, Sony, Japan) gemacht. Die Aufnahmen, die mit dieser Kamera bei einer Sensorgröße von 23,7 x 15,8 mm (APS-C Sensor), einer Brennweite von 16 mm und einem Abstand zum Boden von etwa 70 cm gemacht wurden, erreichten eine *ground sample distance* (GSD) von 0,4 mm.



Abbildung 1: (a) Originalbild der Teilfläche zur Bestimmung der Pflanzenverteilung mittels *Morisita-Index of dispersion* (MORISITA 1959). (b) Screenshot der Morisita-GUI, der einen quadratischen Ausschnitt der zu bonitierenden Teilfläche zeigt. Der Ausschnitt entspricht exakt der Fläche innerhalb des Boniturrahmens. Grüne Marker zeigen die manuell gesetzten Positionen der Pflanzen, deren räumliche Verteilung berechnet werden soll.

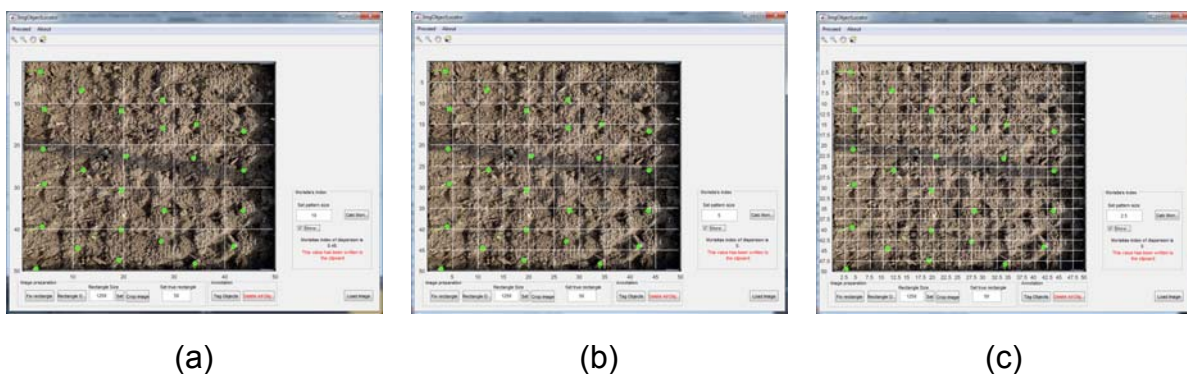


Abbildung 1: Verschiedene Rastermaße für die Berechnung des *Morisita-Index of Dispersion*: (a) 10 cm, (b) 5 cm und (c) 2,5 cm. Bei (a) ist das Ergebnis der Berechnung $I=0.48$, während der Wert für kleinere Raster bei 0 liegt.

3 Ergebnisse

Es wurde eine grafische Benutzerschnittstelle geschaffen, die es ermöglicht, die Position von Pflanzen in einer digitalisierten Feldaufnahme zu verorten. Aus den relativen Pflanzenpositionen im Bild kann anschließend der *Morisita-Index of Dispersion* in Abhängigkeit zum Rastermaß errechnet werden. Die manuell gesetzten Positionen werden gespeichert und können nachträglich korrigiert werden. Auf diese Weise bleibt die vorgenommene Bonitur reproduzierbar. In ersten Tests der Methodik konnte gezeigt werden, dass die halbmanuelle Herangehensweise mit der manuellen Bonitur auf dem Feld übereinstimmt. Darüber hinaus kann mit Hilfe der Methode das Rastermaß variiert und dessen Einfluss auf den *Morisita-Index of dispersion* untersucht werden.

4 Diskussion

Da es für die Berechnung des Morisitas Index ggf. erforderlich ist, das Rastermaß des Flächenausschnitts an die Größe der Zielfläche anzupassen (CRESSIE 2015), sind Bonitierungen auf dem Feld unter Verwendung festgelegter Raster wenig flexibel. Mit der hier vorgestellten softwarebasierten Methode zur Berechnung des *Morisita-index of Dispersion* werden dagegen systematische Untersuchungen zur Anwendbarkeit des *Morisita-Index of Dispersion* für verschiedene Skalierungen (Rastermaß) und Flächengrößen ermöglicht. Neben der gezeigten Anwendung zur Berechnung der Verteilung von Einzelpflanzen in Pflanzenbauversuchen (z.B. Gleichstandssaat) können künftig differenziertere Klassifizierungen vorgenommen werden, die es erlauben, weitere Indizes räumlicher Verteilung zu berechnen (z.B. zur Ermittlung der Biodiversität auf einer Zielfläche). Bisher wurden erst sehr wenige Aufnahmen ausgewertet. Daher muss die Praxistauglichkeit der hier vorgestellten Software weiter getestet werden.

Das Programm kann unter www.atb-potsdam.de heruntergeladen werden.

Literaturverzeichnis

- CRESSIE N.A.C. (2015):** Statistics for Spatial Data. – In: Statistics for Spatial Data. – pp. 1–26 (John Wiley & Sons, Inc.) Hoboken, NJ, USA <https://doi.org/10.1002/9781119115151.ch1>.
- DALE M.R.T., DIXON P., FORTIN M.-J., LEGENDRE P., MYERS D.E. & ROSENBERG M.S. (2002):** Conceptual and mathematical relationships among methods for spatial analysis. – *Ecography*, 25 (5): 558–577 <https://doi.org/10.1034/j.1600-0587.2002.250506.x>.
- DIECKMANN U., LAW R. & METZ J.A.J. (eds) (2000):** The Geometry of Ecological Interactions: Simplifying Spatial Complexity. – (Cambridge University Press) Cambridge <https://doi.org/10.1017/CBO9780511525537>.
- KREBS C.J. (1989):** Ecological methodology. – (Harper & Row New York).
- MORISITA M. (1959):** Measuring of the dispersion of individuals and analysis of the distributional patterns. – *Mem. Fac. Sci. Kyushu Univ. Ser. E*, 2 (21): 5–23.
- MORISITA M. (1962):** $I\sigma$ -Index, a measure of dispersion of individuals. – *Researches on Population Ecology*, 4 (1): 1–7 <https://doi.org/10.1007/BF02533903>.
- TILMAN D. & KAREIVA P. (1997):** Spatial Ecology. – (Princeton University Press) <https://doi.org/10.2307/j.ctv36zpzpm>.
- TSUJI K. & KASUYA E. (2001):** What Do the Indices of Reproductive Skew Measure? – *The American Naturalist*, 158 (2): 155–165 <https://doi.org/10.1086/321310>.
- TSUJI K. & TSUJI N. (1998):** Indices of reproductive skew depend on average reproductive success. – *Evolutionary Ecology*, 12 (2): 141–152 <https://doi.org/10.1023/A:1006575411224>.

In der Reihe**Bornimer Agrartechnische Berichte**

sind bisher erschienen:

Heft 1	Technik und Verfahren der Landschaftspflege	1992
Heft 2	Beiträge zur Lagerung und Verarbeitung pflanzenbaulicher Produkte	1993
Heft 3	Technik und Verfahren in der Tierhaltung	1993
Heft 4	Technik und Verfahren der Landschaftspflege und für die Verwendung der anfallenden Materialien	1994
Heft 5	Verfahrenstechnik der Aufbereitung, Lagerung und Qualitätserhaltung pflanzlicher Produkte	1994
Heft 6	Biokonversion nachwachsender Rohstoffe und Verfahren für Reststoffbehandlung	1994
Heft 7	Preußische Versuchs- und Forschungsanstalt für Landarbeit und Schlepperprüffeld in Bornim 1927 bis 1945	1995
Heft 8	Qualitätssicherung und Direktvermarktung	1996
Heft 9	Konservierende Bodenbearbeitung auf Sandböden	1996
Heft 10	Anwendung wärme- und strömungstechnischer Grundlagen in der Landwirtschaft	1996
Heft 11	Computer-Bildanalyse in der Landwirtschaft Workshop 1996	1996
Heft 12	Aufbereitung und Verwertung organischer Reststoffe im ländlichen Raum	1996
Heft 13	Wege zur Verbesserung der Kartoffelqualität durch Verminderung der mechanischen Beanspruchung	1997
Heft 14	Computer-Bildanalyse in der Landwirtschaft Workshop 1997	1997
Heft 15	Technische und ökonomische Aspekte der Nutztierhaltung in großen Beständen	1997
Heft 16	11. Arbeitswissenschaftliches Seminar	1997
Heft 17	Nachwachsende Rohstoffe im Land Brandenburg Stand Aktivitäten und Perspektiven einer zukunftsfähigen und umweltgerechten Entwicklung	1998
Heft 18	Qualität von Agrarprodukten	1998
Heft 19	Computer-Bildanalyse in der Landwirtschaft Workshop 1998	1998
Heft 20	Beiträge zur teilflächenspezifischen Bewirtschaftung	1998

Heft 21	Landnutzung im Spiegel der Technikbewertung – Methoden, Indikatoren, Fallbeispiele	1998
Heft 22	Kriterien der Nachhaltigkeit in der Verfahrensentwicklung für die Nutztierhaltung	1999
Heft 23	Situation und Trends in der Landtechnik / Erneuerbare Energien in der Landwirtschaft	1999
Heft 24	Institut für Landtechnik der Deutschen Akademie der Landwirtschaftswissenschaften zu Berlin 1951 bis 1965	1999
Heft 25	Computer-Bildanalyse in der Landwirtschaft Workshop 1999 / 2000	2000
Heft 26	Computer-Bildanalyse in der Landwirtschaft Workshop 2001	2001
Heft 27	Approaching Agricultural technology and Economic Development of Central and Eastern Europe	2001
Heft 28	6 th International Symposium on Fruit, Nut, and Vegetable Production Engineering	2001
Heft 29	Measurement Systems for Animal Data and their Importance for Herd Management on Dairy Cow Farms	2002
Heft 30	Produktion, Verarbeitung und Anwendung von Naturfasern	2002
Heft 31	Computer-Bildanalyse in der Landwirtschaft Workshop 2002	2002
Heft 32	Biogas und Energielandwirtschaft – Potenzial, Nutzung, Grünes Gas TM , Ökologie und Ökonomie	2003
Heft 33	Sozioökonomische Aspekte zu Perspektiven des Offenlandmanagements	2003
Heft 34	Computer-Bildanalyse in der Landwirtschaft Workshop 2003	2003
Heft 35	Energieholzproduktion in der Landwirtschaft Potenzial, Anbau, Technologie, Ökologie und Ökonomie	2004
Heft 36	High-Tech Innovationen für Verfahrensketten der Agrarproduktion. Statusseminar 2003	2004
Heft 37	Computer-Bildanalyse in der Landwirtschaft Workshop 2004	2004
Heft 38	Die Landmaschinenprüfung in der DDR 1951–1991 und ihre Vorgeschichte	2004
Heft 39	Energieverlust und Schimmelpilzentwicklung bei der Lagerung von Feldholz-Hackgut	2005
Heft 40	Computer-Bildanalyse in der Landwirtschaft Workshop 2005	2005
Heft 41	Demonstration der Langzeitwirkung bedarfsorientierter Fungizidbehandlung mit dem CROP-Meter	2005

Heft 42	Biochemicals and Energy from Sustainable Utilization of herbaceous Biomass (BESUB)	2005
Heft 43	Ozontes Waschwasser zur Qualitätssicherung leichtverderblicher Produkte – Entwicklung einer <i>Fuzzy-Logic</i> -Steuerung des Waschprozesses	2005
Heft 44	Messsystem zur Bewertung des Unkrautvorkommens	2005
Heft 45	Anwendung der Thermographie zur Optimierung der Belüftungssteuerung bei der Lagerhaltung landwirtschaftlicher Produkte	2005
Heft 46	Membranbioreaktor zur Aufbereitung von Schlachthofabwässern Prozesssteuerung von Biogasanlagen mit Kofermentation	2005
Heft 47	Verschleißeinfluss auf das Förderverhalten von Drehkolbenpumpen	2005
Heft 48	Qualitätserhaltung und Qualitätssicherung von Bioobst und Biogemüse in der Nachernte	2005
Heft 49	Miniaturisiertes Datenerfassungs-System zum Implantieren in Früchte und zur Messung ihrer mechanischen Belastung durch Ernte- und Nachernteverfahren	2005
Heft 50	Prozesskontrolle der Qualität von frischem Obst und Gemüse mit Hilfe eines Multigas-Sensors	2005
Heft 51	Entwicklung eines Echtzeitsensors für die Stärkebestimmung bei Kartoffeln als funktionaler Bestandteil eines optoelektronischen Verleseautomaten	2005
Heft 52	Optimierte Steuerung von Getreide-Schachttrocknern	2005
Heft 53	Möglichkeiten und Grenzen der energetischen Nutzung von Rizinusöl	2005
Heft 54	Non-Destructive Methods for Detecting Health-Promoting Compounds COST Action 924 Working Group Meeting	2005
Heft 55	4 th IFAC / CIGR Workshop Control Applications in Post-Harvest and Processing Technology (CAPPT 2006) 26 th – 29 th March 2006, Potsdam	2006
Heft 56	Computer-Bildanalyse in der Landwirtschaft Workshop 2006	2006
Heft 57	Kontrolle der Frische in der Nacherntekette von Ökogemüse	2006
Heft 58	Entwicklung eines innovativen Dekontaminationsverfahrens als Technologieantwort auf zukünftiges Qualitätsmanagement im Nacherntebereich	2006
Heft 59	Experimental Studies and Mathematical Modelling of Solar Drying System for Production of High Quality Dried Tomato	2007

Heft 60	13. Workshop Computer-Bildanalyse in der Landwirtschaft & 4. Workshop Precision Farming	2007
Heft 61	Energiepflanzen im Aufwind Wissenschaftliche Ergebnisse und praktische Erfahrungen zur Produktion von Biogaspflanzen und Feldholz	2007
Heft 62	14. Workshop Computer-Bildanalyse in der Landwirtschaft	2008
Heft 63	Experten-Workshop Lagerung von Holzhackschnitzeln	2008
Heft 64	Postharvest unlimited 2008	2008
Heft 65	Vom Agrarrohstoff zu neuen Produkten – Verfahrens- technische Forschung im Nacherntebereich	2009
Heft 66	16. Arbeitswissenschaftliches Kolloquium des VDI-MEG Arbeitskreises Arbeitswissenschaften im Landbau	2009
Heft 67	Monitoring der methanbildenden Mikroflora in Praxis-Biogas- anlagen im ländlichen Raum: Analyse des Ist-Zustandes und Entwicklung eines quantitativen Nachweissystems	2009
Heft 68	Wieviel Biogas steckt in Pflanzen? Abschluss- Symposium des „Biogas-Crops-Network“ (BCN) 7. Mai 2009 Potsdam	2009
Heft 69	Image Analysis for Agricultural Products and Processes 27 th to 28 th August 2009, Potsdam	2009
Heft 70	5th International Technical Symposium on Food Processing, Monitoring Technology in Bioprocesses and Food Quality Management 31 st August to 2 nd September 2009, Potsdam	2009
Heft 71	Einsatz von Biogas in PEM-Brennstoffzellen	2009
Heft 72	Teilflächenspezifische Grunddüngung	2009
Heft 73	16. Workshop Computer-Bildanalyse in der Landwirtschaft 4. Mai 2010 Braunschweig	2010
Heft 74	Erschließung von Nachhaltigkeitspotenzialen durch Nutzung innovativer Sensortechnologien – <i>Prozesskette Getreide</i> –	2010
Heft 75	Erschließung von Nachhaltigkeitspotenzialen durch Nutzung innovativer Sensortechnologien – <i>Prozesskette pflanzliche Frischeprodukte</i> –	2010
Heft 76	International Workshop The future of the quarter individual milking 14.–15. September 2010 Potsdam	2010
Heft 77	A flow cytometric approach to monitor the effects of gentle preservation techniques in the postharvest chain	2011
Heft 78	17. und 18. Workshop Computer-Bildanalyse in der Landwirt- schaft 5. Mai 2011 Stuttgart und 9. Mai 2012 Osnabrück	2012

Heft 79	2. Öffentliches Symposium des „BCN“ BiogasPOTENZIALE Erkennen, Erforschen, Erwirtschaften	2012
Heft 80	Mechanisms of Bacillus spore germination and inactivation during high pressure processing	2013
Heft 81	19. Workshop Computer-Bildanalyse in der Landwirtschaft 2. Workshop Unbemannte autonom fliegende Systeme in der Landwirtschaft 6.–7. Mai 2013 Berlin	2013
Heft 82	3rd Global Workshop on Proximal Soil Sensing	2013
Heft 83	19. Arbeitswissenschaftliches Kolloquium des VDI-MEG Arbeitskreises Arbeitswissenschaften im Landbau 11.–12. März 2014 Dresden	2014
Heft 84	Prozessmikrobiologie in landwirtschaftlichen Biogasanlagen Schlussbericht zum Forschungsverbund BIOGAS-BIOCOENOSIS	2014
Heft 85	Sensoren. Modelle. Erntetechnik Kolloquium zur Verabschiedung von Dr. Ehlerlert 27. Mai 2014, Potsdam-Bornim	2014
Heft 86	Phosphor für die Landwirtschaft – Strategien für eine endliche Ressource 11. Juni 2014, Potsdam-Bornim	2014
Heft 87	Biofilme in Biogasanlagen - Struktur, Einfluss auf die Bio- gasausbeute und Optimierung technischer Systeme zur Rückhaltung der mikrobiellen Biomasse BIOGAS-BIOFILM	2015
Heft 88	20. und 21. Workshop Computer-Bildanalyse in der Landwirt- schaft 3. Workshop Unbemannte autonom fliegende Systeme (UAS) in der Landwirtschaft 26. Mai 2014, Osnabrück und 6.–7. Mai 2015, Braunschweig	2015
Heft 89	International Biochar Symposium: Biochar Contribution to Sustainable Agriculture 28 th – 29 th May 2015, Potsdam	2015
Heft 90	ISHS Symposium 2016 “Sensing Plant Water Status” Methods and Applications in Horticultural Science 05 th – 07 th October 2016 Potsdam	2016
Heft 91	10 th International FRUTIC Symposium Quality and Safety of Fresh Horticultural Commodities February 07, 2017	2017
Heft 92	Etablierung eines <i>core</i> -Mikrobioms für Biogasanlagen Genom-Sequenzierung von Isolaten aus Biogasanlagen und Mapping von Metagenom-Datensätzen BIOGAS-CORE	2017

Heft 93	22. Workshop Computer-Bildanalyse und Unbemannte autonom fliegende Systeme in der Landwirtschaft 23. Workshop Computer-Bildanalyse in der Landwirtschaft 21. April 2016, Wernigerode und 27. April 2017, Potsdam-Marquardt	2017
Heft 94	Leitfaden für die Trocknung von Arznei- und Gewürzpflanzen	2017
Heft 95	Entwicklung von molekularen Markern und Nachweisverfahren auf Basis der quantitativen (realtime) PCR zum Monitoring von prozessrelevanten Mikroorganismen als Frühwarnsysteme für Prozessstörungen	2017
Heft 96	Cold atmospheric pressure plasma treatment of food matrices: Tailored modification of product properties along value-added chains of plant and animal related products	2017
Heft 97	INSECTA Conference 2017 07 th – 08 th September 2017, Berlin, Germany	2017
Heft 98	Storability of broccoli – investigations of optical monitoring, chlorophyll degradation and predetermination in the field	2018
Heft 99	24. Workshop Computerbildanalyse in der Landwirtschaft 25. April 2018, Zürich	2018
Heft 100	INSECTAS 2018 05 th – 07 th September 2018, Giessen, Germany	2018
Heft 101	6th International Conference on Machine Control and Guidance 1 st – 2 nd October 2018, Berlin	2018
Heft 102	25. Workshop Computerbildanalyse in der Landwirtschaft 17 th 2019, Bonn	2019

Interessenten wenden sich an:

Leibniz-Institut für Agrartechnik und Bioökonomie e.V.
Max-Eyth-Allee 100
14469 Potsdam

Tel.: (0331) 5699-820
Fax.: (0331) 5699-849
E-Mail: atb@atb-potsdam.de

Schutzgebühr Print: 20,00 Euro

CD-Rom: 10,00 Euro