

Fusion von Bilddaten und IoT-Funksensordaten im pflanzenbaulichen Feldversuchswesen

Andreas Heckmann¹ und Stefan Paulus²

Abstract: Ein Hemmnis beim Einsatz der digitalen Technologien stellt die mangelnde Zuverlässigkeit bzw. die Ungenauigkeit von Entscheidungshilfesystemen, insbesondere zur teilflächenspezifischen Vorhersage von Biomassewachstum, Krankheiten oder Nährstoffstress, dar. Mit dem Feldversuch „Fieldloop“ werden unterschiedliche Sensortechniken im Feldversuchswesen eingesetzt, um eine standpunktgenaue und fortlaufende Messung des Pflanzenwachstums und der mikroklimatischen Umweltfaktoren zu untersuchen. Im vorliegenden Beitrag wird die Untersuchung der Einsatzmöglichkeiten digitaler Werkzeuge im Feldversuchswesen evaluiert. Es zeigt sich, dass die Etablierung von drahtlosen Sensornetzwerken eine wertvolle Ergänzung zur Bildanalyse, zu Geo- und Boniturdaten gerade im Feldversuchswesen darstellt. Auf der Basis der gewonnenen Erkenntnisse können Validierungsversuche von Prognosemodellen für Biomasse und Vitalität präziser durchgeführt werden. Eine Quantifizierung und Beschreibung heterogener Einflussgrößen wird ermöglicht. Eine Weiterentwicklung des Ansatzes für Großflächenversuche wird in aufbauenden Projekten vorangetrieben.

Keywords: Remote Services, Machine Learning, Modellierung, Sensorsysteme, Sensor- und Datenfusion, Internet der Dinge und mobile Vernetzung, Lora, IoT, Remote Sensing, Mikroklima

1 Einleitung

Bei der klassischen manuellen Feldbonitur und Beobachtungen können Ergebnis-Effekte durch die subjektive Wahrnehmung des Menschen auftreten. Müdigkeit, Sonnenstand und Wolkenbedeckungen führen dazu, dass menschliche Boniturnoten für gleiche Orte variieren. Neue Technologien im Bereich der Sensorik und der Datenanalyse sind sinnvolle Werkzeuge, um die präzise und objektive Erhebung und die Beschreibung pflanzenbaulicher Exaktversuche zu gewährleisten [Th10]. Oftmals kommen jedoch manuelle Beprobungs sonden oder sogenannten „Handheld“-Geräte zum Einsatz, womit an einzelnen Zeit- und Ortsmarken Datenpunkte aufgenommen werden. Da für ein durchgängiges Monitoring der Beprobungsaufwand enorm ansteigen würde, kann ein permanentes Sensor-Monitoring auf Versuchsflächen oft nicht realisiert werden. Neben einem mangelnden Stichprobenumfang steigt das Risiko des Auftretens von Messfehlern oder der fehlenden Datengrundlage zur Erklärung von Phänomenen. Durch Innovationen im Bereich der Messelektronik und der Funktechnik können Sensormesswerte über weite

¹ Georg-August Universität Göttingen, DNPW Abteilung Agrartechnik, Gutenbergstraße 33, 37075 Göttingen, andreas.heckmann@uni-goettingen.de

² Institut für Zuckerrübenforschung, Abteilung Sensorik, Holtenser Landstraße 77, 37079 Göttingen, paulus@ifz-goettingen.de

Distanzen direkt in lokalen Datenbanken oder Cloudservern gespeichert werden [OMR15]. Vor diesem Hintergrund wurde in einem regulären Parzellenversuch mittels drahtloser Funksensorknoten das Mikroklima gemessen. Anschließend wurden Spektralbild- und Boniturdaten mit den Mikroklimadaten zur Beschreibung des Biomassewachstums pro Parzelle verschmolzen. Durch die Nutzung unterschiedlicher Sensoren soll die Frage beantwortet werden, ob Funksensordaten in Verbindung mit neuartigen Analysemethoden als Ergänzung zur manuellen Bonitur von Biomassewachstum und Vitalität im Feldversuchswesen genutzt werden können.

2 Material und Methoden

2.1 Versuchsbeschreibung

Von April bis Juni 2018 wurde an einem Standort (sandiger Lehm) in Niedersachsen ein Doppel-Parzellenversuch in der Kultur Winterweizen (*Triticum aestivum*, Sorte JB Asano) durchgeführt. Zum Zeitpunkt der Vollblüte des Weizens wurde Biomasse invasiv am 28.05.2018 geerntet. Zuvor wurden die Erntestellen randomisiert festgelegt und neben der Krankheits- und Stressbonitur die Pflanzenlänge, Triebe pro Pflanze, Anzahl der Ähren bestimmt. Ferner wurde der SPAD (single-photon avalanche diode) mit dem *Yara N-Tester* (Yara International, Hanninghof 35, 48249 Dülmen, Germany) erhoben. Vor und nach der Ernte fand ein Drohnenüberflug (ebee, senseFly SA, Route de Genève 38, 1033 Cheseaux-sur-Lausanne, Switzerland) mit einer RGB-Kamera (Lumix DMC-TZ70, Panasonic, Osaka, Japan.) mit 30-fachen optischen Zoom und 12,1 Megapixel Auflösung statt. In einem zweiten Überflug mit einem Multispektralsensor (SEQUOIA+, Parrot) wurden die Wellenbereiche Grün (530-570 nm), Rot (640-680 nm), Red Edge (730-740 nm) und Nahinfrarot (770-810 nm) mit jeweils 1,2 Megapixel Auflösung und gleichzeitiger RGB-Aufnahme mit 16 Megapixel gemessen. Die anschließende Bildprozessierung und Errechnung des NDVI wurde in Agisoft Metashape (Professional Edition, Version 1.5, Agisoft LLC 11 Degtyarniy per., St. Petersburg, Russia, 191144) durchgeführt. Georeferenzierte Daten wurden in QGIS-OSGeo4W-3.6.3-1 Girona analysiert.

Maschinelle Lernmethoden generieren aus einem Trainingsdatensatz von Bilddaten mit zugehöriger Frischmasse bzw. Grünheitswert der oberen Blatttage ein Modell, um aus neuen Bilddaten (Testdaten) einen passenden Frischmasse- bzw. Grünheitswert vorherzusagen. Je heterogener dabei der Trainingsdatensatz desto besser die Voraussage beim Testdatensatz. Zur Modellgenerierung wurden dabei vier verschiedene Modelle sowie ein Ensemble bestehend aus allen fünf Modellen gemeinsam evaluiert. Mit folgenden Varianten wurden verschiedene Typen aus der Familie der Machine Learning Regressionsmodelle getestet.

SVM: Die Familie der Support Vector Machines nutzt Stützvektoren, um die Distanz zwischen Klassen bzw. zu einer Modellfunktion zu optimieren. Dabei kommen lineare oder auch radiale Basisfunktionen zum Einsatz.

PSL: Partial Least Square Regression, gehört zu den Strukturvergleichsmodellen und nutzt die Varianz innerhalb der Daten, um Werte vorherzusagen.

RF/ xgbTree: gehören zur Familie der Entscheidungsbäume. Beide Implementierungen unterscheiden sich in der Art und Weise, wie der Baum aufgebaut und an die Daten angepasst wird.

Ensemble: Hierbei werden sämtliche Modelle zur Vorhersage genutzt. Ein weiteres Machine Learning Modell entscheidet dabei, wann welches Modell genutzt wird.

Als prototypischer Aufbau zum Monitoring von Temperaturen und Feuchten im Boden und im Pflanzenbestand wurde ein Feldsensor auf Basis der STM32 B-L072Z-LRWAN1 LoRa® Entwicklungsplatine aufgebaut. Auf 80 cm und 25 cm Höhe über dem Boden wurden die Feuchtigkeit und Temperatur der Umgebungsluft gemessen (Bosch BME280, Bosch Sensortec GmbH, Gerhard-Kindler-Straße 9, 72770 Reutlingen). Weiterhin wurde auf 70 cm Höhe in einem Winkel von 45 Grad ein Infrarotsensor zur gezielten Messung der Pflanzentemperatur installiert (MLX90614-BCF Melexis, Ypres, Belgium). Im Boden wurde ein kapazitiver Bodenfeuchtesensor mit integriertem Temperaturfühler (Miceuz i2c-moisture-sensor) eingesetzt. Die Sensordaten wurden als LoRaWAN™- Datenpakete an eine 1,2 Km entfernte Datensenke im Intervall von 10 Minuten versandt. Das lokale Netzwerk besaß eine Stern-Architektur, bei der ein in Verbindung mit einem Raspberry Pi Model 3b (Raspberry Pi Foundation, 37 Hills Road, Cambridge, CB2 1NT) als Gateway konfiguriert wurde. Die Daten wurden lokal gesichert und per MQTT Protokoll an einen Server weitergeleitet. Fehlerhafte Messwerte wurden händisch im Datensatz pro Messzeitpunkt entfernt. Es wurde der Zeitraum vom 17.05.2018 bis 03.06.2018 betrachtet. Als Referenz wurde eine Wetterstation (Pessl iMETOS® 3.3 IMT280, Pessl Instruments GmbH, WERKSWEG 107, 8160 Weiz) in 100 m Entfernung zum Versuch genutzt.

3 Ergebnisse

3.1 Mikroklimamessung über Funksensornetzwerk

Durch die Installation des Sensornetzwerkes konnten die mikroklimatischen Bedingungen im Pflanzenbestand während des Beobachtungszeitraumes aufgezeichnet werden. Die Temperaturmessung der prototypischen Funksensoren erreichten eine vergleichbare Messgenauigkeit wie die der Wetterstation. Es konnte zwischen den beiden Messhöhen (0,15-0,2 m und 0,8-1,0 m) Temperaturdifferenzen von bis zu 3 °C gemessen werden. Im täglichen Mittel lag die Differenz beim Funksensornetzwerk bei 0,46 °C und bei der Wetterstation bei 0,62 °C. Es gilt zu beachten, dass als Referenz nur eine Wetterstation zur Verfügung stand, während 4 Funksensoreräte im Versuch platziert wurden.

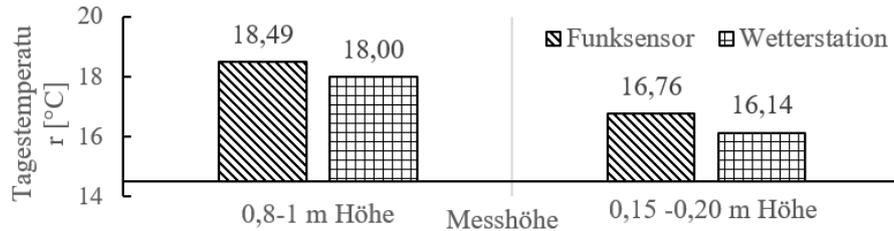


Abb. 1: Mittelwertvergleich der Tagesdurchschnittstemperatur vom 16.05.2018 bis zum 28.05.2018 zwischen Temperatur-Funkensensoren (n = 4) und einer kalibrierten Referenz-Wetterstation im Messbereich 80 cm bis 100 cm (links) und 15 cm bis 20 cm Höhe über dem Boden

3.2 Biomasseprognose

Biomasse	RGB		RGB+MS		RGB+MS +TEMP		RGB+MS +TEMP+SPAD	
	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²
svmLinear	55,64	0,02	44,5324	0,28	59,83	0,02	60,76	0,05
svmRadial	55,5	0,03	36,49	0,48	54,04	0,01	53,33	0,06
rf	57,74	0,11	31,5	0,68	58,41	0,09	47,57	0,15
pls	50,38	0,11	29,87	0,76	52,4	0,01	50,76	0,05
xgbTree	57,65	0,08	23,87	0,81	60,08	0,02	49,4	0,15
Ensemble	53,6	0,22	21,27	0,845	47,53	0,4	53,61827	0,21

Tab. 1: Auflistung der statistischen Kenngrößen Wurzel der mittleren Fehlerquadratsumme (Root Mean Square Error, RMSE) und dem Bestimmtheitsmaß (R-squared, R²) der geschätzten Biomasse für die Beprobungspunkte pro m² und nach Training mit vier kombinierten Datenlayern auf Basis der Drohnensbilder vom 28.05.2018 (RGB = Rot Gelb Blau, MS = Multispektral), der Temperaturmessung der Mikroklimasensoren zum 28.05.2018 (TEMP) und der manuellen Messung der Pflanzengrünheit zum 28.05.2018 mit dem N-tester (SPAD)

Alle verwandten maschinellen Lernverfahren lieferten die beste Vorhersage der Biomasse für die Beprobungspunkte durch Kombination der RGB und Multispektralbilddaten. Das Ensemble und xgbTree zeigten dabei die beste Modelanpassung mit hohem R²-Werten und geringeren RMSE-Fehlerwerten. Die Hinzugabe der Temperaturtagesmittelwerte zeigte keine Verbesserung, sondern führte zu einer Verschlechterung der Vorhersagegenauigkeit der getesteten Verfahren. Die zusätzliche Nutzung der SPAD-Handmessung zur RGB, MS und TEMP wies im Vergleich zur reinen RGB Luftbildmessung keine Vorteile auf.

3.3 Grünheit der oberen Blätter (F, F-1)

Die Schätzung der Grünheit der oberen Blätter konnte durch alle verwandten Methoden mit Ausnahme der svmRadial mit einem geringen RMSE-Fehler gezeigt

werden. Es konnte eine leichte Verbesserung der Vorhersagegenauigkeit durch Kombination der RGB, MS, TEMP und SPAD Eingangswerte beobachtet werden. In allen geprüften Varianten wiesen das Ensemble und xgbTree die beste Modelanpassung aus.

Grünheit obere Blatttage	RGB		RGB+MS		RGB+MS +TEMP		RGB+MS +TEMP+SPAD	
	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²
svmLinear	18,29	0,43	21,11	0,39	17,14	0,53	15,27	0,66
svmRadial	22,34	0,21	14,75	0,64	25,41	0,05	24,28	0,28
rf	15,18	0,63	15,94	0,59	15,75	0,56	15,19	0,65
pls	18,54	0,43	19,07	0,5	17,28	0,48	16,27	0,61
xgbTree	14,13	0,67	16,2	0,57	13,38	0,68	13,6	0,7
Ensemble	13,95	0,69	15,07	0,63	13,9	0,65	13,75	0,71

Tab. 2: Auflistung der statistischen Kenngrößen Wurzel der mittleren Fehlerquadratsumme (Root Mean Square Error, RMSE) und dem Bestimmtheitsmaß (R-squared, R²) der Grünheit der oberen Blatttage (F. F-1) für die Beprobungspunkte pro m² und nach Training mit vier kombinierten Datenlayern auf Basis der Drohnenbilder vom 28.05.2018 (RGB = Rot Gelb Blau, MS = Multispektral), der Temperaturmessung der Mikroklimasensoren zum 28.05.2018 (TEMP) und der manuellen Messung der Pflanzengrünheit zum 28.05.2018 mit dem N-Tester (SPAD)

4 Diskussion

Die gemessenen Lufttemperaturwerte der Funksensoren im Pflanzenbestand und oberhalb der Bestandeskante lagen im nahezu gleichen Wertebereich im Vergleich zur Referenz-Wetterstation. Durch den prototypischen Aufbau konnte das Mikroklima im Versuch für den Testzeitraum überwacht werden. Für die abschließende Bewertung hinsichtlich Zuverlässigkeit der prototypischen Funksensoren ist eine Testphase über einen längeren Zeitraum mit einer höheren Geräteanzahl notwendig, um beispielsweise unterschiedliche Witterungsverhältnisse zu prüfen. Durch die Nutzung der Funksensoren ergeben sich vielfältige Anwendungsmöglichkeiten im Versuchswesen, um das Pflanzenwachstum, das Auftreten von Stresssituationen oder von Anomalien quantitativ und qualitativ zu beschreiben [CAS17]. Die in diesem Versuch durchgeführten georeferenzierte Bonitur und invasive Biomassernten sollten zunächst in zukünftigen Versuchsanstellungen angewandt werden, um eine valide Referenzgröße sicherzustellen. Die Möglichkeit, eine hohe Anzahl von Sensoren durch Funkmodule automatisiert und permanent in einer Datenbank zu speichern, kann zu einer effizienteren und genaueren Versuchsanstellung beitragen. Ein Nachteil des getesteten Funksensornetzwerkes liegt im hohen Erstaufwand der prototypischen Umsetzung. Hier sind kommerzielle Systeme von Vorteil. Zum Zeitpunkt des Versuches konnten jedoch keine kommerziellen Lösungen in einem vergleichbaren Preisrahmen von unter 150 Euro pro Funksensor gefunden werden. Auf Basis spektraler Daten des Drohnenüberfluges konnte die Biomasse und die Grünheit der oberen Blatttagen pro Beprobungspunkt mit hoher Genauigkeit vorhergesagt werden. Dabei zeigte ein Ensemble aus fünf maschinellen Lernmethoden einen geeigneten Ansatz

mit der höchsten Vorhersagegenauigkeit. Mit der Fusion der Temperaturmessdaten der Funksensoren konnte keine Verbesserung der Vorhersagegenauigkeit von Biomasse erzielt werden, jedoch konnte in der Vorhersage der Grünheit der oberen Blättertagen ein leicht positiver Effekt auf das Vorhersageergebnis gezeigt werden. Eine Verbesserung des Ansatzes kann durch eine Erhöhung der Datenheterogenität herbeigeführt werden. Die Drohnenbilddaten lassen sich weiter auswerten und um Geländemodelle und weitere spektrale Wellenbereiche ergänzen, um die Vorhersagegenauigkeit zu verbessern [Be15]. Gerade bei Großparzellen- /On-Farm-Versuchen oder bei hoher Heterogenität der Bodenart, des Bodentypes oder der Standorteigenschaften sollten in zukünftigen wissenschaftlichen Arbeiten der Nutzen von Funksensornetzwerken und insbesondere des permanenten Mikroklima-Monitorings untersucht werden, um die Effekte der Klima- und Umweltfaktoren in der Pflanzenwachstumsmodellierung und Prognosesystemen zu berücksichtigen [Se17]. Durch den beschriebenen Versuch konnten wertvolle Erkenntnisse über den Einsatz drahtloser Funksensornetzwerke und deren Verknüpfung mit spektralen Daten gewonnen werden. Es konnte ein Proof-of-Concept erreicht werden, der die Potenziale der Technologie aufzeigt.

Literaturverzeichnis

- [Be15] Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., Gnyp, M. L., Bareth, G.: „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 (1. Januar 2015): 79–87. <https://doi.org/10.1016/j.jag.2015.02.012>.
- [CAS16] Capalbo, S. M., Antle, J. M., Seavert, C.: „Next generation data systems and knowledge products to support agricultural producers and science-based policy decision making“. *Agricultural Systems* 155 (1. Januar 2017): 191-99. <https://doi.org/10.1016/j.agsy.2016.10.009>.
- [OMR15] Ojha, T., Misra, S., Raghuwansi, N. S.: „Wireless Sensor Networks for Agriculture: The State-of-the-Art in Practice and Future Challenges“. *Computers and Electronics in Agriculture* 118 (Oktober 2015): 66-84. <https://doi.org/10.1016/j.compag.2015.08.011>.
- [Se17] Seidel, P.: „Eingriff von Schaderregern in den Ertragsbildungsprozess als Grundlage für eine Abbildung in Kulturpflanzenwachstumsmodellen: Neue Herausforderungen - alte Probleme!: Impacts of plant pests on the yield forming process taken as a basis for simulation with crop growth models: New challenges - old problems!“, 1. Januar 2017. <https://doi.org/10.5073/jka.2017.456.000>.
- [Th10] Thöle, H.: „Ansätze zur statistischen Auswertung von On-Farm-Experimenten mit georeferenzierten Daten“, 25. November 2010. <https://doi.org/10.18452/16232>.