

Monitoring von Winden (*Convolvulus* sp.) mit Drohnen

Low-cost monitoring of Convolvulus sp. with drones

Maike Krauss*, Jeremias Niggli, Hansueli Dierauer

Forschungsinstitut für biologischen Landbau FiBL, Departement für Bodenwissenschaften, Frick, Schweiz

*maike.krauss@fibl.org

DOI: 10.5073/20220125-060651

Zusammenfassung

Wurzelunkräuter vermehren sich weitgehend vegetativ über ihr Wurzelsystem und treten inhomogen in Nestern auf. Diese sind auf Feldebene visuell schwer zu erfassen. Drohnenflüge in Verbindung mit einer Segmentierung des Beikrauts eröffnen die Möglichkeit zur Langzeitkartierung und Erfolgskontrolle von Regulierungsmaßnahmen. Für Winden (*Convolvulus* sp.) wurde in einem ersten Ansatz eine spektrale Segmentierung vor dem Hintergrund von abreifendem Getreide (grün versus gelb) auf Basis eines random forest Algorithmus erarbeitet. Trainings- und Testdaten wurden über georeferenzierte und visuell kartierte 1x1 m Subplots in einem Bodenbearbeitungsexaktversuch mit Orthofotos verknüpft. Diese wurden mit einer RGB Kamera der Drohne DJI Phantom 4Pro in 40 m Flughöhe erfasst. Der Algorithmus erzielte eine Präzision von 91% mit einer Falschklassifikation von 12-14%. Angewendet auf neuen Testdaten des gleichen Aufnahmezeitpunktes und –feldes, erzielte eine mit $R^2 = 0.7$ signifikante Korrelation. Der Bodenbearbeitungsexaktversuch konnte damit erfolgreich ausgewertet werden. Die Evaluierung an zusätzlichen Orthofotos von Praxisschlägen zeigte jedoch, dass eine allgemeine Verunkrautung und Lagerstellen im Getreide stören. Ein Deep Learning Algorithmus, der neben spektralen Informationen auch Muster erkennen kann, wird zur Weiterentwicklung vorgeschlagen.

Stichwörter: *Convolvulus* sp., Drohne, Kartierung, Segmentierung, Wurzelunkraut

Abstract

Perennial weeds mainly spread through their rooting system resulting in an inhomogeneous distribution. This is hard to monitor visually and offers the opportunity for drone monitoring. Segmentation of weeds in contrast to crops can provide maps for long-term observation and success monitoring. Bindweed (*Convolvulus* sp.) in senescencing cereals was visually scored in 1x1 m subplots in a tillage trial and intersect with the respective orthofoto. The RGB information of the drone images taken with a DJI Phantom 4Pro in 40m flight height was taken for spectral segmentation (green versus yellow) with a random forest algorithm. Precision was 90% with 12-14% incorrect classifications. Applied to new subplot data of the same field and date resulted in a significant correlation of visually scores with segmented bindweed pixels ($R^2 = 0.7$). The tillage trial was therefore successfully evaluated by drone imaging. Yet, tested with orthofotos of real life on-farm fields, general weed infestation and lodging of cereals have shown to be problematic. Further development of a deep learning algorithm including spectral and pattern information is envisaged.

Keywords: *Convolvulus* sp., drone monitoring, perennial weeds, segmentation

Einleitung

Winden (*Convolvulus* sp.) sind Beikräuter im Ackerbau, die sich vorwiegend vegetativ über ihr Wurzelsystem verbreiten. Im Biolandbau wird auf synthetische Herbizide verzichtet. Die Regulierung von Wurzelunkräutern ist dadurch schwierig. Metastudien zeigen, dass eine Kombination intensiver Bodenbearbeitung mit zusätzlicher Konkurrenz durch Kulturpflanzen bisher das erfolgsversprechende Vorgehen ist (DAVIS et al., 2018; ORLOFF et al., 2018). Erfahrungen aus der Praxis zeigen jedoch, dass dies

30. Deutsche Arbeitsbesprechung über Fragen der Unkrautbiologie und -bekämpfung, 22. – 24. Februar 2022 online

nicht reicht und gezielte Regulierungsmaßnahmen notwendig sind. Die Entwicklung in der konventionellen Landwirtschaft hin zu einer Pestizidreduktion lässt darüber hinaus vermuten, dass Wurzelunkräuter in den nächsten Jahren allgemein zu einem Problem werden. Die Erarbeitung von Regulierungsmaßnahmen ist dabei die eine Herausforderung, das Monitoring die Andere. Die Verbreitung von Wurzelunkräutern und im spezifischen von *Convolvulus* sp. im Feld ist nicht homogen. Sie kommen in Form von Nestern vor, von denen ausgehend die Verbreitung stattfindet. Eine Erfolgskontrolle von Regulierungsmaßnahmen erfordert daher eine genaue Kartierung. Dies ist auf Feldebene mit einem hohen Aufwand verbunden. Drohnen versprechen nicht nur eine Vereinfachung der Kartierung, sondern auch eine Weiterverwendung der Karten für ortsspezifische Interventionen, wie z.B. die Studie von RASMUSSEN et al. (2019) an Disteln zeigt. Damit nicht nur in der Forschung, sondern auch in der Praxis Drohnen zu einer Langzeitbeobachtung herangezogen werden können, stellt sich die Frage, ob der Einsatz günstiger Drohnen mit RGB Kameras für eine Kartierung ausreicht. Als vielversprechender Zeitpunkt für die Detektion von Winden hat sich abreifendes Getreide (BBCH 80-90) erwiesen. Im braun-gelben Getreidebestand ist die in vollem Wachstum befindende und daher grüne Winde spektral gut voneinander zu trennen.

Material und Methoden

Auf Basis eines einjährigen Exaktversuches zur Regulierung von Winden durch verschiedene Bodenbearbeitungsmaßnahmen, wurden Orthofotos vor dem Beginn des Versuches in der Vorkultur Dinkel (Juli 2019) und vor der Ernte der Versuchskultur Weizen (Juli 2020) per Drohne (DJI Phantom 4Pro, RGB Kamera, 4864 x 3648 Pixel Auflösung) erstellt, um den Erfolg der Bearbeitungsmaßnahmen abzuschätzen. Ein Flugplan (Litchi App, VC Technology Ltd) in 40 m Höhe, die Ausführung der Flüge am späten Vormittag bei vollem Sonnenschein und die Georeferenzierung über Ground control points garantierten die Vergleichbarkeit. Eine visuelle Bonitur mit einer Skala (0 = keine Winde, 4 = mit Winden überwachsen) wurde 2020 zusätzlich in Subplots von 1x1 m Grösse durchgeführt, um den Segmentierungsalgorithmus zu erarbeiten und zu testen. Darüber hinaus wurden im Juli 2020 verschiedene Weizenfelder von Praxisbetrieben im Einverständnis der Landwirte überflogen, um den Klassifikationserfolg auf seine Tauglichkeit für die Praxis zu prüfen. Die Drohnenbilder wurden mit der Software Metashape (Agisoft LLC, Russia) zu Orthofotos pro Schlag vereint und in QGIS (QGIS.ORG, 2021) georeferenziert.

Die Erarbeitung der Segmentierung erfolgte an Hand der Subplots mit dem Score 0 (=Getreide) und 4 (=Winde). Sie wurden mit dem Orthofoto in R (R CORE TEAM, 2021) unter Verwendung der packages „raster“ (HIJMANS and VAN ETTEN, 2012) und „rgdal“ (BIVAND et al., 2021) verschnitten. Die ausgeschnittenen Rasterdaten wurden als csv-Datei extrahiert. Diese enthielt pro extrahiertem Pixel die spektrale Information der Kamera (Rot, Grün, Blau) und den visuell erhobenen Winden-Score (0, 4). Der Datensatz wurde in einen Trainings- (80 %) und Testdatensatz (20 %) unterteilt und ersterer mit einem random forest Ansatz aus dem package „caret“ (KUHN, 2008) modelliert. Der resultierende Algorithmus wurde mit dem Testdatensatz validiert. Anschliessend wurden alle vorhandenen Orthofotos mit dem Algorithmus segmentiert, um i) den Exaktversuch quantitativ im Vergleich zu den restlichen Subplots auszuwerten und ii) die Praxistauglichkeit qualitativ zu testen.

Ergebnisse und Diskussion

Das Segmentierungsergebnis an Hand des Testdatensatzes mit der binären Einteilung in «Winde» und «Getreide» lag bei einer Präzision von 91 % (Tab. 1). Es wurden 12-14 % der Pixel falsch zugeordnet.

Tabelle 1 Ergebnis der Segmentierung durch einen random forest Algorithmus.

Table 1 Segmentation result by the random forest algorithm

Konfusionsmatrix	Winde	Getreide
Winde	46176	3167 (12 %)
Getreide	3614 (14 %)	22217
Statistik		
Accuracy : 0.9098	95% CI : (0.9077, 0.9118)	P-Wert: < 0.001
Sensitivity : 0.9274	Specificity : 0.8752	Detection Rate : 0.6143

Bei der Korrelation des Segmentierungsergebnisses mit der visuellen Bonitur von 2020 an Hand der restlichen im Feld erhobenen Subplots war die Präzision mit rund 70 % tiefer, aber dennoch signifikant (Abb. 1). Dies kann zum einen daran liegen, dass die Segmentierung auf Pixelbasis im Vergleich zu dem übergeordneten visuellen Scoring der 1x1 m großen Subplotflächen Unschärfe mit sich bringt. Zum anderen waren Kleebestände zum gleichen Zeitpunkt grün und daher potentiell als Winde falsch klassifiziert (Rot unterlegt in Abb. 1). Da in diesen Subplots jedoch auch Winden vorhanden waren, lag die Falschklassifikation des Klees innerhalb der Streuung.




Abbildung 1 Korrelation der visuellen Windenbonitur durch Subplots (Skala 1-4) mit der als Winde klassifizierten Pixel (%) berechnet durch die Segmentierung. Daten aus dem Weizen Exaktversuch 2020. Rote Punkte kennzeichnen die potentielle Falschklassifikation von Kleebeständen.

Figure 1 Correlation of the visual field assessment of *Convolvulus* sp. (Scoring 1-4) with the number of pixels classified as *Convolvulus* sp. (%) extracted and classified from the respective Orthofoto. Data were collected in the wheat field trial in 2020. Red dots mark the potential misclassification of clover.

Der Segmentierungsalgorithmus wurde zur Auswertung des Bodenbearbeitungsversuches herangezogen. Kernparzellen von 3x30 m wurden aus den Orthofotos von 2019 und 2020 herausgeschnitten, mit dem Algorithmus segmentiert und der Anteil an Winden klassifizierten Pixel statistisch mit einer Varianzanalyse ausgewertet (Tab. 2). Im Bodenbearbeitungsversuch wurde der Einfluss der Bewirtschaftung zwischen der Dinkelernte Ende Juli 2019 bis zur Herbstsaat von Weizen im Oktober 2019 auf die Entwicklung der Winden und den Weizenertrag im Folgejahr verglichen. Die Referenz (Pflug und mehrmaliges Eggen,

Schwarzbrache) entspricht der aktuellen Empfehlung zur Sanierung von Winden mit maximaler Bodenbearbeitungsintensität.

Während das mittlere Windenvorkommen 2019 zu Beginn des Versuches bei rund 25 % lag und durch die beabsichtigte gleichmäßige Verteilung der Parzellen zwischen den Verfahren keinen statistischen Unterschied zeigte, nahm der Windenbesatz im Schnitt aller Verfahren um 14 % auf 39 % in 2020 zu. Die Kombination von Pflügen mit der sofortigen Saat einer Gründüngung (UFA Lepha) zeigte die geringste Zunahme von Winden bei einem marginal kleineren Weizenertrag im Vergleich zur Referenz. Das Verfahren Flächenrotte mit der sofortigen Direktsaat der Gründüngung und anschließendem Einfräsen ergab nicht nur ein schlechtes Auflaufen sowohl der Gründüngung als auch des Weizens, sondern auch eine Zunahme der Winden um 24 % und eine Reduktion des Weizenertrages um 45 %. Die Tatsache, dass der Windenbesatz allgemein zunahm und manche Bewirtschaftungsmaßnahmen zusätzlich Winden förderten zeigt, dass Bewirtschaftungsfehler problematisch sein können, die Windenregulierung jedoch eine übergeordnete längerfristige Strategie erfordert.

Tabelle 2 Mittelwerte (Standardabweichung) des Anteils als Winden klassifizierte Pixel (%) innerhalb der Kernparzellen im Vergleich der Jahre 2019 und 2020 und des Weizenkornenertrages von 2020 (t TS ha⁻¹) zwischen vier Bodenbearbeitungsverfahren. Kleinbuchstaben kennzeichnen signifikante Unterschiede ($p < 0.05$, Tukey Test) zwischen den Verfahren pro Spalte

Table 2 Means (standard deviation) of the share of pixels classified as *Convolvulus* sp. (%) within core plots in 2019 and 2020 and the winter wheat grain yield in 2020 (t TS ha⁻¹) distinguished by four different tillage treatments. Letters indicate significant differences ($p < 0.05$, Tukey Test) between treatments per column

Verfahren (Dauer 2,5 Monate zwischen Dinkelernte Ende Juli und Weizensaat Mitte Oktober 2019)	Anteil Winden klassifizierte Pixel (%)			Weizenertrag 2020 (t TS ha ⁻¹)
	2019	2020	Delta 2020-2019	
Referenz: Pflügen (25 cm) und 3-maliges eggen (Schwarzbrache)	25.0 (9.76) a	36.0 (14.1) ab	11.0 (11.3) b	3.79 (0.60) a
Pflügen (25 cm) und sofortige Saat einer Gründüngung	26.2 (7.59) a	33.2 (15.5) b	6.93 (12.0) b	3.19 (0.30) a
Stoppelbearbeitung mit Flachgrubber (2 Durchgänge, 6-10 cm) mit Saat einer Gründüngung ca. 1.5 Monate vor Weizensaat	22.7 (8.26) a	36.1 (14.3) ab	13.4 (12.0) ab	2.02 (0.49) b
Sofortige Direktsaat einer Gründüngung, Flächenrotte: Einfräsen mit Einspritzen von Milchsäurebakterien (Rottelenker) 14 Tage vor Weizensaat	25.5 (10.6) a	49.0 (17.9) a	23.5 (11.3) a	1.72 (0.25) b




Abbildung 2 Klassifizierte Orthofotos (grün = Winde, gelb = Weizen) von Praxis schlägen A) eines konventionellen Betriebes ohne weiteres Beikraut, B) eines Biobetriebs mit viel Beikraut und C) eines Biobetriebs mit lagerndem Weizen.

Figure 2 Classified orthofotos (green = bindweed, yellow = wheat) of farmers fields of A) a conventional farm with no other weeds than bindweed, B) an organic farm with high weed pressure and C) an organic farm with lodged wheat.

Die qualitative Evaluierung von segmentierten Orthofotos verschiedener Praxis schläge zeigte, dass der Segmentierungsalgorithmus gute Karten hervorbringt solange die Schläge nur mit Winden verunkrautet sind (Abb. 2A). Sobald Felder eine allgemein hohe Verunkrautung (Abb. 2B) oder Lagerstellen im Getreide mit langsamerer Abreife (Abb. 2C) aufweisen, ist die Differenzierung zwischen Winde und Hintergrund mit dem vorliegenden Algorithmus auf alleiniger Basis spektraler Information nicht ausreichend. Deep Learning Algorithmen wären vermutlich erfolgreicher. Sie können neben der spektralen Information auch die Muster der Verteilung von Winden im Feld berücksichtigen und daher die Segmentierung verbessern. Dies setzt allerdings eine große Datenbank an annotierten Orthofotos voraus.

Danksagung

Wir danken dem Coop Fonds für Nachhaltigkeit für die finanzielle Unterstützung des Projektes.

Literatur

- BIVAND, R., T. KEITT, B. ROWLINGSON, rgdal (1.5-25).<https://rgdal.r-forge.r-project.org/index.html>.
- DAVIS, S., J. MANGOLD, F. MENALLED, N. ORLOFF, Z. MILLER, E. LEHNHOFF, 2018: A Meta-Analysis of Filed Bindweed (*Convolvulus arvensis*) Management in Annual and Perennial Systems. *Weed Science* **66** (4), 540-547, DOI: 10.1017/wsc.2018.25.
- HIJMANS, R.J., J. VAN ETTEN, 2012: raster: Geographic analysis and modeling with raster data. R package version 2.0-12.<http://CRAN.R-project.org/package=raster>.
- KUHN, M., 2008: Caret package. *Journal of Statistical Software*, 28(5) <https://github.com/topepo/caret/>.
- ORLOFF, N., J. MANGOLD, Z. MILLER, F. MENALLED, 2018: A meta-analysis of field bindweed (*Convolvulus arvensis* L.) and Canada thistle (*Cirsium arvense* L.) management in organic agricultural systems. *Agriculture Ecosystems & Environment* **254**, 264-272, DOI: 10.1016/j.agee.2017.11.024.
- QGIS.ORG, 2021: QGIS Geographic Information System. ASSOCIATION., Q.<http://www.qgis.org>.
- R CORE TEAM, 2021: R (Version 4.0.3): A language and environment for statistical computing. R Foundation for Statistical Computing. Vienna, Austria, R Foundation for Statistical Computing.

30. Deutsche Arbeitsbesprechung über Fragen der Unkrautbiologie und -bekämpfung, 22. – 24. Februar 2022 online

RASMUSSEN, J., J. NIELSEN, J.C. STREIBIG, J.E. JENSEN, K.S. PEDERSEN, S.I. OLSEN, 2019: Pre-harvest weed mapping of *Cirsium arvense* in wheat and barley with off-the-shelf UAVs. *Precision Agriculture* **20** (5), 983-999, DOI: 10.1007/s11119-018-09625-7.