

28. Deutsche Arbeitsbesprechung über Fragen der Unkrautbiologie und -bekämpfung, 27.02. – 01.03.2018 in Braunschweig

Räumlich hochauflösende Unkrauterkennerung mittels Flugroboter und merkmalsextrahierender Bildverarbeitung

Drone based weed monitoring with an image feature classifier

Michael Pflanz^{1*}, Michael Schirrmann², 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., Max-Eyth-Allee 100, 14469 Potsdam-Bornim

*Korrespondierender Autor, michael.pflanz@julius-kuehn.de

DOI 10.5073/jka.2018.458.056



Zusammenfassung

Für ein teilflächenspezifisches Unkrautmanagement sind Informationen über die Anzahl und die Verteilung verschiedener Unkrautarten auf einer Flächeneinheit erforderlich. Ist diese Voraussetzung erfüllt, kann die Applikation von Herbiziden hinsichtlich Aufwandmenge und Herbizidwahl an räumlich variable Unkrautsituationen landwirtschaftlicher Flächen angepasst werden. Neben einer online-Erfassung am Traktor oder Feldspritze werden künftig autonom fliegende Sensorplattformen eingesetzt, deren hochauflösende Luftbildaufnahmen Basis sind für die Generierung von artspezifischen Unkrautkarten. Damit würden ausreichend Informationen zur Verfügung stehen, um Aufwandmengen für Pflanzenschutzmittel bereits vor der Applikation exakt zu ermitteln und Restmengen zu reduzieren.

Für die Unkrauterkennerung selbst werden zunehmend Methoden des maschinellen Lernens adaptiert, die eine objektbasierte Klassifikation anhand eindeutiger Merkmale vieler Unkrautarten weiter voranbringt. Während spektral-optische Klassifikatoren bereits intensiv genutzt werden, um variable Nährstoff- und Wasserdefizite räumlich auflösen, hat die objektbasierte Klassifikation für eine artspezifische Unterscheidung von Leitunkräutern ihr volles Potential bisher noch nicht erreicht.

In der vorliegenden Studie wurde ein neuer Ansatz objekt-basierter Unkrauterkennerung getestet. Die Klassifikation unterschiedlicher Pflanzenarten erfolgte mit dem Bag-of-visual-Word (BoVW) Ansatz auf der Basis hochauflösender Luftbildaufnahmen von autonomen Luftfahrzeugen (UAV). BoVW ist ein objektbasierter Klassifizierer der bereits seit einiger Zeit in der landwirtschaftlichen Forschung diskutiert wird.

Die Ergebnisse zeigen, dass der BoVW-Ansatz eine artspezifische Unterscheidung zwischen *Matricaria recutita* L. und *Papaver rhoeas* L. mit guter Erkennungsleistung ermöglicht, wenn parallel eine objekt-basierte Klassifizierung der Kulturpflanzen (*Triticum aestivum* L.) und Boden erfolgt. Für die Erstellung praxisrelevanter Unkrautkarten als Basis für eine künftige teilflächenspezifische Herbizidapplikation müssen noch weitere Unkrautarten in den Klassifikator integriert werden. Hierzu erfolgen derzeit weitere Untersuchungen.

Stichwörter: Bilderkennung, Bildklassifikation, maschinelles Lernen, Präzisionslandwirtschaft, teilflächenspezifischer Pflanzenschutz, UAV, Unkrautarten, Unkrautverteilung

Abstract

Site specific weed management needs detailed weed information down to the species level. Then herbicides can be used more specifically according to weed occurrence and their spatial distribution. The accurate identification of weeds is one of the major prerequisites to generate weed maps. Next to predominant implementations of online monitoring approaches on agricultural machinery, unmanned aerial vehicles (UAV) platforms will be used in future to generate weed maps of different species by using high-resolution imagery. While colour-based indices are already applied for mapping nutritional deficits or water deficiency, they have failed to identify different weed species. In contrast, object-based image analysis looks much more promising to separate plant characteristics by means of form and morphology yet are much more complex.

This study proposes a new computer vision approach to discriminate weed species based on a bag-of-visual-word (BoVW) framework using high resolution aerial images. BoVW is an object-based image classifier that has recently gained interest in agricultural research. In our trials this technology has been applied in laboratory tests and field trials for automatic weed sampling with digital cameras.

The results showed that the BoVW model allows the discrimination between *Matricaria recutita* L., *Triticum aestivum* L., *Papaver rhoeas* L. and soil with good accuracy. For providing consistent weed maps in terms of precise herbicide applications in the future, the robustness of the classifier must be evaluated with more crops and weed species acknowledging the natural plant variability observed in the fields.

Keywords: Image classification, image recognition, machine learning, precision farming, site-specific weed control, UAV, weed distribution, weed species

Einleitung

Teilflächenspezifische Ertragsunterschiede können neben variierenden Bodeneigenschaften im Wesentlichen auf eine starke Konkurrenzwirkung von Unkräutern bezüglich Licht-, Wasser- und Nährstoffaufnahme zurückgeführt werden (MILBERG, 2004). Ertragsverluste und Unkrautdichte verhalten sich zwar annähernd proportional, werden aber im Rahmen des Schadschwellenkonzeptes nur ungenügend räumlich aufgelöst. Für eine teilflächenspezifische Anwendung von Herbiziden sind Schadschwellenwerte von großer Bedeutung (SAN MARTIN et al., 2016).

Für eine Optimierung der Aufwandmenge und die Auswahl von Herbiziden ist daher sowohl die Identifikation als auch die Lokalisierung verschiedener Unkrautarten erforderlich. Dazu gehören die Dichte und die räumliche Verteilung auf einer Fläche (HÄUSLER et al., 1999; CHRISTENSEN, 2003; NORDMEYER, 2006; LOPEZ-GRANADOS, 2011). Während manuelle und zufällige Stichproben oder Rasterbonituren sehr aufwendig und teuer sind (WILES und SCHWEIZER, 1999), kann der Einsatz autonom fliegender Sensorplattformen (UAV) dazu beitragen, Einzelpflanzen mit Hilfe bildgebender Sensorik und photogrammetrischer Analyse zu erfassen (PFLANZ und NORDMEYER, 2014). Dabei konnte gezeigt werden, dass derzeit verfügbare UAV-Systeme in der Lage sind, in sehr geringer Flughöhe über dem Boden zu navigieren (PFLANZ und NORDMEYER, 2016), was es erlaubt den Detailgrad von Luftbildaufnahmen zu erhöhen, um somit die Identifikation verschiedener Unkrautarten zu ermöglichen. Unter der Voraussetzung hoher Bodenauflösungen wurden bereits Texturmodelle entwickelt, die mit wenigen eindeutigen Merkmalen für eine Reihe von Unkrautarten Gültigkeit haben (SOGAARD, 2005). In ähnlicher Weise separierte MANH et al. (2001) individuelle Unkräuter auf der Basis von parametrisierbarer Formvektoren einzelner Laubblätter.

Neuere Ansätze in der Bildanalyse berücksichtigen lokale invariante Formenmerkmale in hochauflösenden Bildaufnahmen, um Unkräuter, Kulturpflanzen und Boden voneinander zu unterscheiden. Im Bag-of-Word (BoVW) Framework werden diese Merkmale mit Hilfe von Clusterverfahren um eine große Anzahl ähnlich optischer Merkmale gruppiert, um so eine Datenbank eindeutiger Basismerkmale (Wörterbuch) zu erstellen. Über direkte Bezüge zum Wörterbuch können für Bildaufnahmen Signaturen erstellt werden, die sich leicht in maschinelle Lernverfahren integrieren lassen, um einen Klassifikator für Pflanzenarten zu erlernen. In der vorliegenden Studie wurde der BoVW Ansatz kombiniert mit einer Mustererkennung auf der Basis von Support Vector Machines, um zwei verschiedene Unkrautarten unter Feldbedingungen zu identifizieren und zu kartieren.

Material und Methoden

UAV-Befliegung und photometrische Aufnahmen

Für die Segmentierung verschiedener Unkrautsituationen wurde der BoVW Klassifizierer mit Luftbildaufnahmen unter realen Feldbedingungen von Echter Kamille (*Matricaria recutita* L., MATCH), Klatschmohn (*Papaver rhoeas* L., PAPRH) sowie von Winterweizen (*Triticum aestivum* L., TRZAX) und von Boden trainiert. Hierfür wurden Versuchsflächen des Julius Kühn-Instituts (Standort Sickte, 52°12'54.6"N 10°37'25.7"E) mit einem Multirotorsystem (Hexakopter, Hexa XL, HiSystems GmbH Moormerland, Deutschland) und modifizierter Flugsteuerung auf der Basis von Paparazzi (BRISSET et al., 2006; CiS GmbH, Rostock-Bentwisch, Deutschland) befliegen. Die photometrischen Aufnahmen erfolgten an insgesamt 52 Wegpunkten in einer Flughöhe von 5 m. 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. Verwendet

wurde weiterhin ein Objektiv mit einer Festbrennweite von 60 mm (Sigma 2.8 DN, Sigma Corp., Japan), wodurch eine mittlere Bodenauflösung von 2,5 Pixel/mm erreicht wurde (Abb. 1).




Abb.1 Aus der Brennweite von 60 mm und der geringen Flughöhe von 5 m ergibt sich eine Bodenauflösung von etwa 2,5 Pixel / mm.

Fig. 1 The focal length of 60 mm and the low altitude of 5 m results in a ground sample distance of 2.5 pixel / mm.

Bildanalyse

Die über dem Versuchsfeld aufgenommenen Luftbilder wurden später manuell am PC bonitiert. Hierzu wurde eine selbst entwickelte graphische Oberfläche (HerbCount GUI Ver. 0.2) entwickelt. Durch Auswahl und Setzen von Markierungen können in den Luftbildern Einzelpflanzen artspezifisch identifiziert und verortet werden. Eine Segmentierung 200 x 200 Pixel großer Ausschnitte erfolgt im Anschluss auf Basis der Position der Einzelpflanzen. Alle Einzelbilder ergeben den Basisdatensatz für das Training des BoVW-Klassifizierers (Abb. 2a). Insgesamt wurden auf diese Weise n=3968 für MATCH, n=548 für PAPRH, n=1401 für TRZRX und n=2469 Einzelbilder für Boden mit Hilfe der UAV-Befliegung innerhalb eines Tages aufgezeichnet.

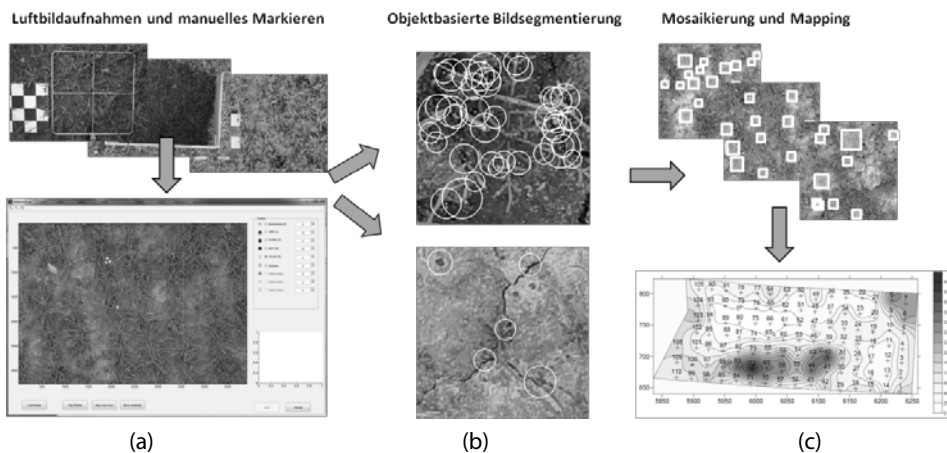


Abb. 2 Schematischer Ablauf der objekt-basierten Unkrauterkennerung. (a) Verschiedene Verunkrautungs-situationen, aufgenommen aus einer Flughöhe von 5 m und artspezifisch annotiert mit Hilfe eines grafischen Benutzerinterfaces zur manuellen Unkrautbonitur am PC (b) Aufbau einer Bilddatenbank auf Basis von Einzelpflanzen (am Beispiel von *Matricaria chamomilla* L.) (c) Erstellung von Unkrautverteilungs- bzw. Herbizidapplikationskarten nach Mosaikierung der analysierten Luftbildaufnahmen.

Fig. 2 Diagram of object based weed detection. (a) Different spatial weed distributions captured from an altitude of 5m above ground and counted by species on PC, (b) Object-based image segmentation and composition of an image database (*Matricaria chamomilla* L.), (c) Generated application map from analysed aerial photographs.

Für das Training des BoVW-Klassifizierers wurden anschließend lokale Bildmerkmale (image key points) aus den Luftbildaufnahmen mit Hilfe der Extraktoren SURF and MSER ermittelt (BAY et al., 2006; MATAS et al., 2004). Zuvor wurden die Ausgangsbilder durch Graustufen- (gray) bzw. vegetationsbetonte Konvertierungen (VEG) umgewandelt. Die Graustufenumwandlung erfolgte mit Hilfe des in Matlab implementierten `rgb2gray` Scriptes. Die vegetationsbetonte Graustufenumwandlung erfolgte mit einem angepassten Skript nach HAMUDA et al. (2016), welche im Wesentlichen die Relation zwischen grünem zu rotem und blauem Kanal berechnet. Das BoVW-Wörterbuch wurde auf Basis von k-means Clusterverfahren erstellt und schließlich trainiert mit Support Vektor Machines (SVM).

Die Präzision des BoVW-Modells wurde mit nicht trainierten Einzelbildern von Unkrautaufnahmen (der randomisierte Anteil von Testdaten am Gesamtdatensatz betrug 25 %) unterschiedlicher Pflanzendeckungsgrade evaluiert (Abb. 3). Hierfür wurde der Vegetationsindex I_G pixelbasiert mit der Formel $I_G = 2 * R - G - B$ nach Segmentierung der Farbbilder in seine Kanäle rot (R), grün (G) und blau (B) errechnet und das Bild anschließend binarisiert. Dieser Ansatz wird häufig genutzt, um die grüne Vegetation vom Hintergrund in Farbbildern zu trennen (WOEBECKE et al., 1995; SØGAARD and OLSEN, 2003). Alle Analysen wurden mit Hilfe von Matlab (Version 2016b, The Mathworks, USA) durchgeführt.




Abb. 3 Bilddatensatz (Auswahl) verschiedener Verunkrautungssituationen für die BoVW Klassifikation nach Bedeckungsgrad.

Fig. 3 Exemplary image subset of different plant coverage for BoVW category classification.

Ergebnisse und Diskussion

Die Erkennungsraten unterschiedlicher Trainingsdatensätze (Unkräuter, Kulturpflanze und Boden) wurden für verschiedene Merkmalsextraktoren und Graustufenkonvertierungen untersucht. Eine Übersicht der Ergebnisse zeigt Tabelle 1. Die höchste Erkennungsrate lag bei 97,03 % für Bildausschnitte, die das Trainingselement Boden bei geringem Pflanzendeckungsgrad enthalten. Die geringste Erkennungsrate von 16,07 % wurde bei MATCH für die Detektor/Graustufenkombination MSER-Gray errechnet. Hierbei zeigte sich eine deutliche Abhängigkeit zum Pflanzendeckungsgrad, denn die Rate stieg bis auf 65,35 % bei einem Pflanzendeckungsgrad von 80 %. Bei geringen Pflanzendeckungsgraden konnten bessere Ergebnisse erzielt werden, wenn für die Graustufenberechnung der Ausgangsbilder ein vegetationsbetonter Konvertierer benutzt wurde. Dagegen zeigte sich die einfache RGB2Gray Graustufenkonvertierung robuster gegenüber Ausgangsdatsätzen mit hohem Pflanzendeckungsgrad.

Insgesamt zeigten die errechneten BoVW-Modelle bezüglich ihrer Vorhersagegenauigkeit der Kategorien MATCH und PAPRH teilweise widersprüchliche Ergebnisse. Die höchste Erkennungsrate für MATCH lag bei 73,49 % bei einem Pflanzendeckungsgrad von 60 % für die Detektor/Graustufenkonvertierung SURF-veg. Eine ähnliche hohe Rate von 78,57 % wurde für PAPRH bei gleichem Pflanzendeckungsgrad für SURF-gray ermittelt. Die höchste Erkennungsrate für PAPRH lag bei 96,91% (100 % Pflanzendeckungsgrad, SURF-gray).

Tab. 1 Zusammenhang zwischen Erkennungsrate und Pflanzendeckungsgrad unterschiedlicher Trainingsdatensätze (Unkräuter, Kulturpflanze und Boden) auf Basis von Einzelpflanzenausschnitten aus Luftbildern. Gezeigt werden die Ergebnisse für verschiedene Merkmalsextraktoren und Graustufenkonvertierungen.

Tab. 1 *The accuracy of object detection (weeds, cultivated plants and soil) based on images separated from aerial images as a function of plant coverage shown for different detector and preprocessing combinations.*

Bedeckungsgrad (%)	20	40	60	80	100
MATCH	41,07	68,37	73,49	69,55	51,30
TRZR	-	58,97	76,92	76,73	72,56
PAPRH	-	25,00	53,57	62,15	66,02
Boden	97,03	85,77	75,30	72,54	47,06
SURF-Gray Genauigkeit (%)					
Bedeckungsgrad (%)	20	40	60	80	100
MATCH	23,21	49,18	56,67	61,39	48,86
TRZR	-	43,59	76,07	91,04	89,84
PAPRH	-	25,00	78,57	91,59	96,91
Boden	79,79	69,53	69,05	67,61	61,76
MSER-veg Genauigkeit (%)					
Bedeckungsgrad (%)	20	40	60	80	100
MATCH	37,50	55,51	64,21	61,82	38,64
TRZR	-	76,92	76,07	67,14	40,04
PAPRH	-	43,75	53,57	50,00	36,29
Boden	92,08	77,85	71,13	68,31	70,59
SURF-Gray Genauigkeit (%)					
Bedeckungsgrad (%)	20	40	60	80	100
MATCH	16,07	47,76	58,99	65,35	46,59
TRZR	-	28,21	67,52	85,69	87,80
PAPRH	-	25,00	55,36	79,91	91,12
Boden	79,29	69,26	71,43	78,17	70,59

Fazit

Zusammenfassend deuten die Ergebnisse der vorliegenden Studien darauf hin, dass eine Segmentierung mit Hilfe des vorgestellten BoVW-Ansatzes die Unterscheidung von Unkrautarten ermöglicht, wenn weitere Bildbestandteile (Boden, Kulturpflanze) in das Training der Modelle einbezogen werden. Um eine praxisrelevante Unkrauterkenntnis auf der Basis verschiedener Leitunkräuter nach dem Schadschwellenprinzip umzusetzen, muss der Ansatz mit Hilfe von weiteren Luftbilddaufnahmen unter Feldbedingungen evaluiert werden, damit die natürliche Variabilität auf landwirtschaftlich genutzten Flächen besser abgebildet werden kann.

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 Versuchsdurchführungen. Besonderer Dank gilt hierbei Herrn Feistkorn und Herrn Littmann für die Befliegungen, sowie Frau Behme und Herrn Löhr für die manuelle Unkrautbonitur am PC.

Literatur

- BAY, H., A. ESS, T. TUYTELAARS und L. VAN GOOL, 2008: Speeded-Up Robust Features (SURF). *Comput. Vis. Image Underst.* **110**, 346–359.
- BRISSET, P., A. DROUIN, M. GORRAZ, P.-S. HUARD und J. TYLER, 2006: The paparazzi solution. In: *MAV 2006, 2nd US-European Competition and Workshop on Micro Air Vehicles*, pp. 1-15.
- CHRISTENSEN, S., T. HEISEL, A.M. WALTER und E. GRAGLIA, 2003: A decision algorithm for patch spraying. *Weed Research* **43**, 276–284.
- HÄUSLER, A. und H. NORDMEYER, 1999: Characterizing spatial and temporal dynamics of weed seedling populations. In: *Sheffield Academic Press*, 463–472.
- LOPEZ-GRANADOS, F., 2011: Weed detection for site-specific weed management: mapping and real-time approaches. *Weed Research* **51**, 1–11.
- MANH, A.G., G. RABATEL, L. ASSEMAT und M.J. ALDON, 2001: Weed leaf image segmentation by deformable templates. *Journal of Agricultural Engineering Research* **80**, 139–146.
- MATAS, J., O. CHUM, M. URBAN und T. PAJDLA, 2004: Robust wide-baseline stereo from maximally stable extremal regions. *Image and Vision Computing* **22**, 761–767.
- MILBERG, P. und E. HALLGREN, 2004: Yield loss due to weeds in cereals and its large-scale variability in Sweden. *Field Crops Research* **86**, 199–209.
- NORDMEYER, H., 2006: Patchy weed distribution and site-specific weed control in winter cereals. *Precision Agriculture* **7**, 219–231.
- PFLANZ, M., D. FEISTKORN und H. NORDMEYER, 2014: Unkrautererkennung mit Hilfe unbemannter Luftfahrzeuge. *Julius-Kühn-Archiv* **443**, 396-403.
- PFLANZ, M. und H. NORDMEYER, 2016: Automatisierte Unkrautererkennung auf dem Acker – Möglichkeiten und Grenzen. *Julius-Kühn-Archiv* **452**, 241-248.
- SAN MARTÍN, C., D. ANDÚJAR, J. BARROSO, C. FERNÁNDEZ-QUINTANILLA und J. DORADO, 2016: Weed Decision Threshold as a Key Factor for Herbicide Reductions in Site-Specific Weed Management. *Weed Technology* **30**, 888–897.
- SØGAARD, H.T., 2005: Weed classification by active shape models. *Biosystems Engineering* **91**, 271–281.
- WILES, L.J. und E.E. SCHWEIZER, 1999: The cost of counting and identifying weed seeds and seedlings. *Weed Science* **47**, 667–673.
- SØGAARD, H.T. und H.J. OLSEN, 2003: Determination of crop rows by image analysis without segmentation. *Computers and Electronics in Agriculture* **38**, 141–158.
- WOEBBECKE, D.M., G.E. MEYER, K. VON BARGEN und D.A. MORTENSEN, 1995: Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE* **38**, 259–269.