

Kartierung des Bedeckungsgrads von *Cirsium arvense* im Mais (*Zea mays* L.) mithilfe Neuronaler Netze in UAV-Daten

Maren Pöttker ¹, David Hagemann ², Simon Pukop ³, Thomas Jarmer ¹ und Dieter Trautz²

Abstract: Die Ackerkratzdistel (*Cirsium arvense* (L.) Scop.) verbreitet sich hauptsächlich über Wurzelausläufer, sodass sie gehäuft in Distelnestern auftritt. Diese können pro Jahr um bis zu 10 m im Durchmesser wachsen, sodass eine frühzeitige Erkennung neuer Nester und eine effektive Regulierung von hoher Relevanz ist. In dieser Arbeit wird *C. arvense* mithilfe hochaufgelöster Bilddaten aus UAV-Befliegungen, die in einem Zeitraum von vier Wochen erhoben wurden, durch ein Ensemble aus Convolutional Neural Networks (CNNs) kartiert und der Bedeckungsgrad abgeleitet. Die Ergebnisse zeigen, dass die Genauigkeit der Kartierung von Einzelpflanzen mit dem phänologischen Stadium der Pflanzen zusammenhängt, und bestätigen die Eignung von CNNs für eine artspezifische Erkennung von *C. arvense*.

Keywords: UAV-Daten, Neuronale Netze, teilflächenspezifische Beikrautregulierung, *Cirsium arvense*

1 Einleitung

Die Ackerkratzdistel (*Cirsium arvense* (L.) Scop.) ist ein perennierendes Wurzel- und Samenunkraut. Sie besitzt eine tiefe Pfahlwurzel und verbreitet sich primär vegetativ über Wurzelausläufer oder abgetrennte Wurzelausläuferteile, aber auch über im Frühjahr keimende Samen. Durch die Verbreitung über Wurzelausläufer tritt *C. arvense* gehäuft in Form von Distelnestern auf [Sö10]. Das Wurzelsystem eines solchen Distelnestes kann pro Jahr um bis zu 10 m im Durchmesser wachsen. Begünstigt wird ihr Wachstum unter anderem durch eine pfluglose Bodenbearbeitung und in zu frühen Wachstumsstadien stattfindende Herbizidapplikationen [Ba22]. Der optimale Behandlungszeitpunkt ist im 3- bis 4-Blattstadium, bei einer Blattfläche von etwa 200 cm² und einer Wuchshöhe von 13 cm [TVL19]. Zu diesem Zeitpunkt ist der Kompensationspunkt zwischen

¹ Universität Osnabrück, Institut für Informatik, Arbeitsgruppe Fernerkundung und Digitale Bildverarbeitung, Wachsbleiche 27, 49090 Osnabrück, maren.poettker@uni-osnabrueck.de,  <https://orcid.org/0000-0002-0711-732X>, thomas.jarmer@uni-osnabrueck.de,  <https://orcid.org/0000-0002-4652-1640>

² Hochschule Osnabrück, Fakultät Agrarwissenschaften und Landschaftsarchitektur, Arbeitsgruppe Agrarökologie und Umweltschonende Landbewirtschaftung, Am Krümpel 31, 49090 Osnabrück,

david.hagemann@hs-osnabrueck.de,  <https://orcid.org/0000-0003-3896-2064>, d.trautz@hs-osnabrueck.de

³ Universität Paderborn, Heinz Nixdorf Institut, Fachgruppe Algorithmen und Komplexität, Fürstenallee 11, 33102 Paderborn, simonjp@hni.uni-paderborn.de,  <https://orcid.org/0000-0002-4473-5215>

Photosyntheseleistung und Bedarf für Wachstum und Respiration erreicht, sodass die Distel empfindlich auf die Behandlung reagiert [NS11]. Eine frühzeitige Erkennung neuer Nester und effektive Regulierung zum passenden Zeitpunkt ist daher von hoher Relevanz. Zur Steigerung der Resilienz von landwirtschaftlichen Räumen und im Sinne einer nachhaltigen Landwirtschaft möchte die EU-Kommission im Rahmen der *Farm-to-Fork*-Strategie bis 2030 den Pestizideinsatz ihrer Mitgliedsländer um 50 % senken [EU20]. Um dies bei gleichbleibendem Ertragsniveau zu realisieren, sind Konzepte wie eine teilflächen- oder sogar einzelpflanzenspezifische Herbizidapplikation nötig. Je nach Kultur und Befallsstärke können bei einer teilflächenspezifisch durchgeführten Regulierung von *C. arvensis* so 54 % [DGK04] bis 88 % [Ry21] Herbizid eingespart werden. Für die Umsetzung einer teilflächenspezifischen Herbizidapplikation sind vier Schritte notwendig: (1) die exakte Erkennung von Beikräutern, (2) Entscheidungssysteme und die Festlegung von Schwellwerten, (3) die präzise Herbizidapplikation und (4) die Kontrolle des Regulierungserfolges [Ch21]. Für eine exakte Erkennung von Beikräutern sowie die Kontrolle des Regulierungserfolges eignen sich fernerkundliche Methoden, um große landwirtschaftliche Flächen effizient abdecken zu können. In der Erkennung von *C. arvensis* wurden beispielsweise hochauflösende Satellitenbilder genutzt, um den Bedeckungsgrad anhand des *Patchiness-Indices* zu schätzen [RAN21]. Als *ground truth* für diese Klassifikation dienten hochauflösende UAV-Bilder, in denen die Einzelpflanzen erkennbar waren. Ebenfalls wurden UAV-Bilder als Klassifikationsgrundlage für die artspezifische Erkennung von *C. arvensis* genutzt, um z. B. Applikationskarten für eine selektive Herbizidapplikation zu erstellen [Mi18] oder die Ertragsminderung zu schätzen [RN20]. Durch unterschiedliche Bedingungen während der UAV-Befliegungen, wie Wind oder wechselhafte Beleuchtung, ist die Qualität von UAV-Daten jedoch nicht gleichbleibend. Weiterhin können andere Beikräuter oder größer werdende Kulturpflanzen mit sich überlappenden Pflanzenteilen die Klassifikation von *C. arvensis* erschweren. In dieser Studie wird *C. arvensis* mithilfe von *Convolutional Neural Networks* (CNNs) in hochauflösenden UAV-Daten, welche unter wechselnden Bedingungen im Verlauf von vier Wochen erhoben wurden, detektiert. CNNs wurden in letzter Zeit vermehrt in der Analyse von fernerkundlichen Vegetationsdaten verwendet, da sie sich besonders für die Ableitung von räumlichen Merkmalen eignen [Ka21]. Architekturen unterschiedlicher Komplexität werden zurzeit für die Erkennung von Beikräutern verwendet. Neben reinen CNNs zur Bilderkennung werden beispielsweise *Region Proposed Networks* wie Yolo oder Mask RCNNs zur Objekterkennung bzw. Instanzsegmentierung oder *Fully Convolutional Networks* wie U-Net zur semantischen Segmentierung verwendet [Ha21]. Hohe Genauigkeiten in der Klassifikation von Beikräutern lassen sich vor allem mit komplexen, vortrainierten Architekturen sowie einer großen Menge Trainingsdaten erzielen [Ha21]. Da für diese Arbeit nur ein begrenzter Umfang an Trainingsdaten zur Verfügung steht, soll eine einfache Architektur verwendet werden. Um ein repräsentatives Ergebnis zu erzeugen, wird ein Ensemble aus 10 einfachen CNNs für die Klassifikation verwendet. Es sollen die Fragen beantwortet werden, (1) ob sich ein Ensemble aus CNNs mit einer einfachen Architektur für die Klassifikation von *C. arvensis* eignet und (2) ob aus dem Ergebnis dieser Klassifikation der Bedeckungsgrad von *C. arvensis* abgeleitet werden kann.

2 Material und Methoden

Auf der Versuchsfläche in Belm bei Osnabrück (52,321124°N, 8,153100°E) befinden sich mehrere Nester von *C. arvense* im Mais (*Zea mays* L.). Während des Untersuchungszeitraumes von Mitte Mai 2022 bis Mitte Juni 2022 wurden an fünf Terminen während unterschiedlicher Belichtungsverhältnisse Befliegungen (s. Tab. 1) mit einer DJI Matrice 210 V2 durchgeführt und multispektrale Bilddaten mit einer MicaSense Altum erhoben. Mithilfe dieses Kamerasystems wurden spektrale Informationen in den fünf Wellenlängenbereichen: Blau (459-491 nm), Grün (547-573 nm), Rot (661-675 nm), Red Edge (711-723 nm) und Nahes Infrarot (814-865 nm) in einer Flughöhe von 10 m und einer daraus resultierenden räumlichen Auflösung von rund 3,5 mm erhoben. Die Bilddaten wurden unter Verwendung der Software Agisoft Metashape (Version 1.7.2) prozessiert und mithilfe von in der Versuchsfläche ausgebrachten und mit einem differentiellen GNSS-Gerät (Stonex S9 III) eingemessenen Targets georeferenziert. Eine radiometrische Kalibrierung der Bilddaten wurde anhand eines im Gelände eingemessenen Reflexionspanels in Agisoft Metashape vorgenommen. Aus den Orthophotos wurden zu jedem der fünf Zeitpunkte zwei Bereiche mit Distelnestern extrahiert: Eine 110 m² große Trainingsfläche sowie eine 9 m² große Testfläche. Die Datensätze für beide Flächen wurden jeweils co-registriert und mittels des *nearest-neighbour*-Verfahrens auf eine einheitliche Pixelgröße von exakt 3,5 mm resampelt. Bedingt durch unterschiedliche Belichtungsverhältnisse während der Datenakquise weisen die Datensätze Differenzen in den Reflektanzen auf (s. Tab. 1). Für eine unabhängige Validierung wurden auf der Testfläche manuell Polygone für die Pflanzen der Klassen Mais, Distel und sonstiges Beikraut erstellt. Um die Daten (x) zu normalisieren, wurde mithilfe des arithmetischen Mittels (μ) und der Standardabweichung (σ) der Z-Score gebildet: $x_{norm} = \frac{x-\mu}{\sigma}$. Aus den fünf Datensätzen der Trainingsfläche wurden jeweils 200 Trainingsdaten in Form von 64×64 Pixel großen Samples für die beiden Klassen (Distel und Nicht-Distel) extrahiert (s. Abb. 1) und wie folgt augmentiert: Drehung um 90°, 180° und 270°, Spiegelung sowie die gelegentliche Verwendung eines Median-Filters, um Bildunschärfe hinzuzufügen [Pa17]. Für jede der beiden Klassen konnten so 13.000 Samples erzeugt werden, wovon randomisierte 75 % für das Training und 25 % für die Validierung des Modells während des Trainingsprozesses verwendet wurden.

Datum	Uhrzeit	BBCH	Belichtungsverhältnisse
12.05.2022	11:30	11-12	Sonne und Wolken im Wechsel
18.05.2022	12:00	14	wolkenlos
02.06.2022	11:30	15	Sonne und Wolken im Wechsel
07.06.2022	12:00	16-17	Sonne und Wolken im Wechsel
13.06.2022	15:30	18	geschlossene Wolkendecke

Tab. 1: Übersicht über die Datengrundlage. Die BBCH-Stadien beziehen sich auf den Mais

Als Modell für die Klassifikation wurde ein Ensemble aus 10 identischen CNNs gebildet [Ka21]. Der Trainingsprozess der CNNs unterschied sich dabei in der Verteilung von

Trainings- und Validierungsdaten; diese wurden bei jedem Modell neu randomisiert. Auf diese Weise konnte sowohl die gesamte Menge der Trainingsdaten genutzt, aber auch jedes Modell ausreichend validiert werden. Mithilfe eines *Moving-Window*-Ansatzes wurde die Testfläche von dem Ensemble aus CNNs klassifiziert. Für das Ergebnis der Klassifikation wurde der Median der 10 Klassifikationswahrscheinlichkeiten für die Klasse Distel genutzt. Weiterhin wurde die Standardabweichung der Klassifikationsergebnisse berechnet. Mithilfe der unabhängigen Validierungsdaten wurden die Klassifikationsergebnisse bei einem wechselnden Schwellwert für die Klassen Boden, Mais, Distel und Beikraut mithilfe einer Konfusionsmatrix validiert. Genutzte Metriken waren hierbei die Gesamtgenauigkeit und die Präzision der Klasse Distel sowie der Anteil der falsch klassifizierten Pixel der Klassen Boden, Mais und Beikraut [SL09]. Anhand der Betrachtung der sich veränderten Klassifikationsgüte bei wechselnden Schwellwerten wurde ein Schwellwert für die Ableitung des Bedeckungsgrads festgelegt. Der Bedeckungsgrad pro $0,25 \text{ m}^2$ wurde durch Zählen der Pixel der Klasse Distel sowohl im Klassifikationsergebnis als auch in den unabhängigen Validierungsdaten ermittelt und so der aus der Klassifikation abgeleitete Bedeckungsgrad dem tatsächlichen Bedeckungsgrad gegenübergestellt. Der Ablauf der vorgestellten Methodik ist in Abbildung 2 dargestellt.

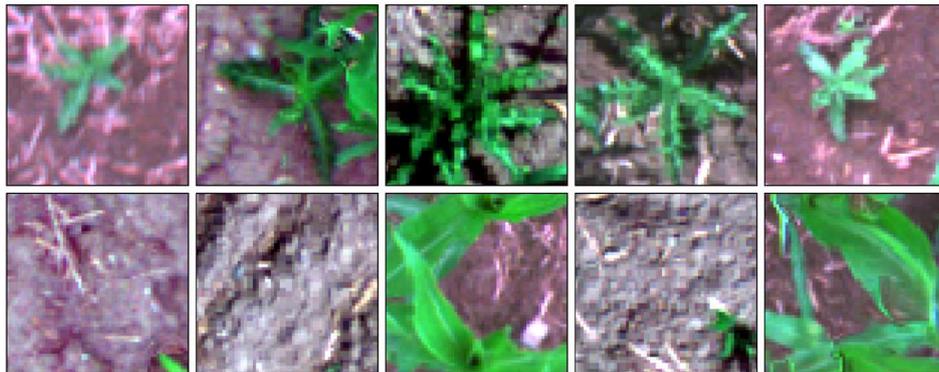


Abb. 1: Trainingssamples der Größe 64×64 Pixel nach der Z-Score Normalisierung, dargestellt in RGB. Obere Zeile: Klasse Distel, Untere Zeile: Klasse Nicht-Distel

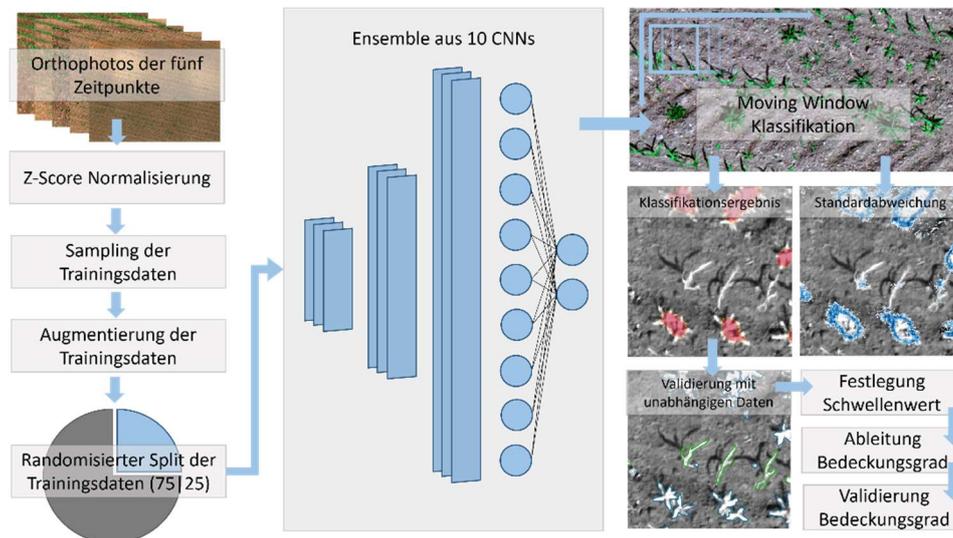


Abb. 2: Ablauf des vorgestellten Ansatzes mit einer schematischen Abbildung der Architektur des CNNs

3 Ergebnisse

Mithilfe des vorgestellten Ensembles aus CNNs wurden die fünf Testdatensätze klassifiziert, durch manuell extrahierte Validierungsdaten unabhängig validiert und für die Ableitung des Bedeckungsgrads verwendet. In Abbildung 3 sind die Klassifikationsergebnisse in einem Teilausschnitt des Testgebietes abgebildet. Es ist erkennbar, dass mit der fortschreitenden phänologischen Entwicklung und dem Wachstum der Pflanzen die als *C. arvense* klassifizierten Bereiche zunehmen. Auch ist zu erkennen, dass die Klassifikationswahrscheinlichkeit in den mittleren Bereichen um die Distelpflanze herum nahe 100 % liegt, während sie zu den Randbereichen abnimmt. Hier sind weiterhin Fehlklassifikationen zu erkennen: Die äußeren Bereiche der Blätter werden nicht erkannt, während der Boden nahe dem Zentrum der Distel mit klassifiziert wird. Ebenfalls sind Fehlklassifikationen punktuell in Bereichen einzelner Maispflanzen zu erkennen. Aufwachsendes Beikraut, erkennbar beispielsweise im Teilausschnitt des 18.05., wird nicht als Distel klassifiziert. In Abbildung 4 lässt sich anhand der Standardabweichung das Verhalten des CNN-Ensembles in den Randbereichen der Disteln erkennen. Im Gegensatz zu Bodenflächen und den Bereichen im Zentrum der Disteln weisen die Randbereiche eine hohe Standardabweichung auf, unabhängig der Größe der Distelpflanze. Durch die Verwendung des Medians der Klassifikationsergebnisse im Ensemble wird diese Über- bzw. Unterschätzung des zu klassifizierenden Bereiches teilweise ausgeglichen. Es wird deutlich, dass sich die Gesamtgenauigkeit je nach Zeitpunkt der Aufnahme unterscheidet und zu den späteren Terminen kontinuierlich geringer wird.

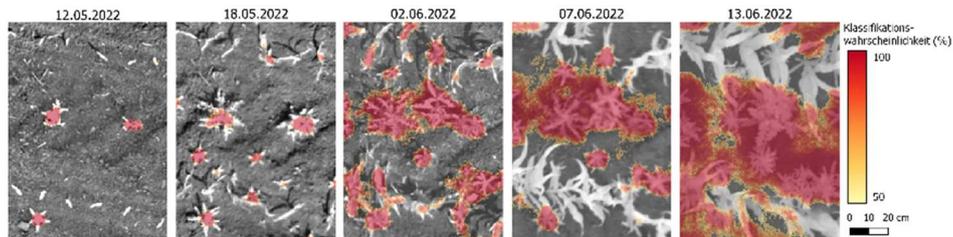


Abb. 3: Klassifikationsergebnisse von Teilausschnitten des Testgebiets an den fünf Aufnahmetermen mit einer Klassifikationswahrscheinlichkeit von 50-100 %

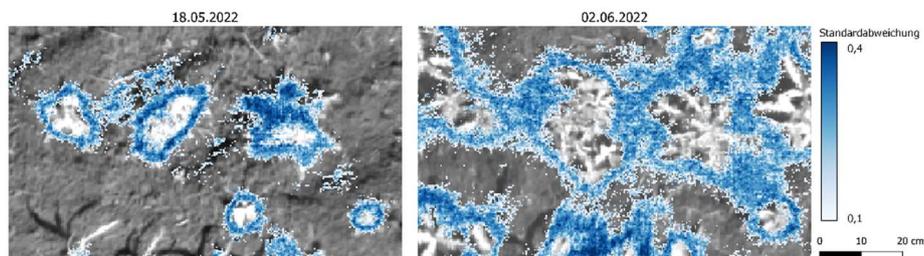


Abb. 4: Standardabweichung der Klassifikationsergebnisse innerhalb des CNN-Ensembles an zwei exemplarischen Teilausschnitten des Testgebiets. Bereiche mit einer Standardabweichung $< 0,1$ sind transparent dargestellt

Besonders auffällig ist die Gesamtgenauigkeit der Klassifikation am 13.06.2022, bei einem Schwellwert von 50 % liegt diese lediglich bei 48,53 %. Ebenfalls ist zu erkennen, dass mit einem steigenden Schwellenwert die Gesamtgenauigkeit an den ersten beiden Aufnahmetermen nahezu konstant bis leicht verringert ist, während sie an den drei späteren Aufnahmetermen in Folge eines steigenden Schwellenwerts steigt. Bei einem Schwellwert von 99 % liegt die Gesamtgenauigkeit aller Klassifikationen bei über 80 %. Die Güte der Klassifikation der Klasse Distel nimmt jedoch bei einem steigenden Schwellwert ab, besonders deutlich im Bereich zwischen 95 % und 100 %. Der Anteil der falsch als Distel klassifizierten Pixel der Klassen Boden, Mais und Beikraut ist in Tabelle 2 bei einem Schwellenwert von 50 % und 99 % dargestellt. Es ist zu erkennen, dass der Anteil der falsch klassifizierten Pixel bei einem höheren Schwellwert abnimmt. Der Anteil der falsch klassifizierten Beikraut Pixel liegt sowohl bei einem Schwellenwert von 50 % als auch von 99 % nahe Null bzw. bei Null. Die Ergebnisse der Schätzung des Bedeckungsgrads sind in Abbildung 6 A abgebildet. Es wird jeweils der aus dem Klassifikationsergebnis bei einem Schwellwert von 95 % berechnete Bedeckungsgrad pro $0,25 \text{ m}^2$ dem aus unabhängigen Validierungsdaten berechneten Bedeckungsgrad gegenübergestellt. Anhand der eingezeichneten 1:1-Linie lässt sich erkennen, dass die Werte bei sehr geringen Bedeckungsgraden unterschätzt, und bei höheren Bedeckungsgraden, insbesondere am 13.06., überschätzt werden. Dieses Verhalten zeigt sich auch in der Gegenüberstellung des tatsächlichen und abgeleiteten durchschnittlichen Bedeckungsgrads (s. Abb. 6 B). An den ersten vier Befliegungsterminen wird der Bedeckungsgrad um

3-5 % unterschätzt, am 13.06. jedoch um 15 % überschätzt. Der Korrelationskoeffizient nach *Pearson* ergibt für den Bedeckungsgrad des 12.05. 0,84, für den 18.05. 0,85, für den 02.06. 0,95, für den 07.06. 0,91 und für den 13.06. 0,84. Für die gesamte Datenreihe ergibt sich ein Korrelationskoeffizient von 0,91.

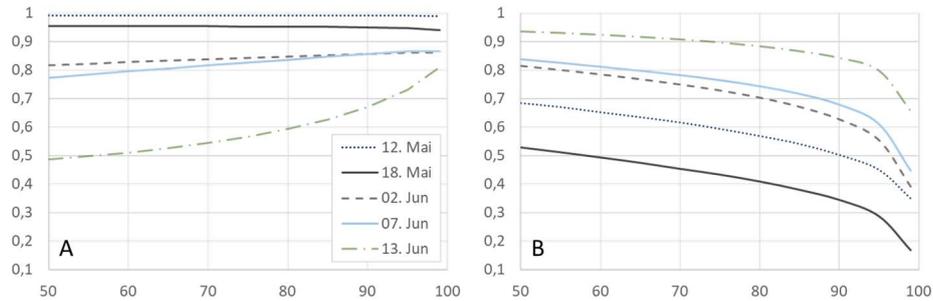


Abb. 5: A: Gesamtgenauigkeit der Klassifikationen der fünf Aufnahmetermine bei steigendem Schwellwert. B: Präzision für die Klasse Distel bei steigendem Schwellwert

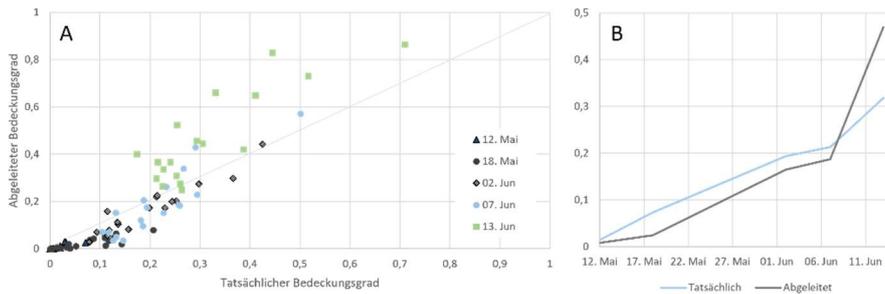


Abb. 6: A: Verhältnis von tatsächlichem zu abgeleitetem Bedeckungsgrad pro 0,25 m² der Testfläche sowie eingezeichnete 1:1-Linie. B: Tatsächlicher und abgeleiteter durchschnittlicher Bedeckungsgrad der Testfläche an den fünf Aufnahmetermine.

	Schwellwert = 50 %					Schwellwert = 99 %				
	Gesamt (A)	Distel (B)	Boden	Mais	Beikraut	Gesamt (A)	Distel (B)	Boden	Mais	Beikraut
12.05.2022	99,05	68,52	34,34	1,41	0	98,99	34,85	20,98	0	0
18.05.2022	96,63	52,28	18,24	4,69	0,03	93,95	16,9	7,75	1,19	0
02.06.2022	81,67	81,40	27,01	22,58	0,01	86,08	39,31	8,62	1,79	0
07.06.2022	77,29	83,75	43,87	9,05	0,03	86,54	44,79	14,56	4,03	0
13.06.2022	48,53	93,51	48,31	14,96	0	80,98	65,67	20,55	9,04	0

Tab. 2: Validierung der Klassifikation bei Schwellwerten von 50 % und 99 %. Dargestellt sind Gesamtgenauigkeit der Klassifikation (*Gesamt*), Präzision für Distel (*Distel*), Anteil der fälschlicherweise als Distel klassifizierten Pixel der Klassen *Boden*, *Mais*, und *Beikraut*

4 Diskussion

4.1 Klassifikation von *C. arvensis* durch ein CNN-Ensemble

Wie die Ergebnisse zeigen, ist eine Klassifikation von *C. arvensis* in verschiedenen Wachstumsstadien und bei unterschiedlichen Belichtungsverhältnissen durch ein Ensemble von CNNs möglich. Anhand der dargestellten Standardabweichung (s. Abb. 4) und der Validierungsergebnisse (s. Tab. 2) wird jedoch deutlich, dass es insbesondere in den Randbereichen der Distelpflanzen zu Fehlklassifikationen kommt. Eine pixelweise Klassifikation von *C. arvensis* ist daher mit der vorgestellten Methodik so nicht möglich. Mit einer erweiterten Menge an Trainingsdaten und einer veränderten Architektur könnte jedoch auch eine pixelweise Klassifikation umgesetzt werden. Betrachtet man die Distelpflanzen als Objekt, werden diese zuverlässig klassifiziert, unabhängig von ihrem Wachstumsstadium. Neben den Fehlklassifikationen in den Randbereichen werden auch einzelne Maispflanzen als *C. arvensis* klassifiziert. Dies lässt sich durch ein Erhöhen des Schwellwerts der Klassifikationswahrscheinlichkeit in vielen Bereichen größtenteils beheben. Weiterhin lässt sich beobachten, dass der Anteil an fälschlicherweise klassifizierten Maispflanzen mit Fortschreiten des Pflanzenwachstums und sich stärker überlappenden Pflanzenteilen zunimmt. Beikräuter werden hingegen kaum als Distel erkannt und können über einen hohen Schwellenwert erfolgreich ausgeschlossen werden. Eine artspezifische Klassifikation von *C. arvensis* in den betrachteten Bereichen ist somit möglich.

Durch das Ensemble wird der Einfluss einzelner Netze, die Disteln in ihrer Größe über- oder unterschätzen, gemindert, und somit eine genauere und einheitlichere Klassifikation ermöglicht. Durch die 10-fache Klassifikation eines jeden Pixels ist dieser Ansatz jedoch sehr zeitintensiv. Gerade in Bereichen, in denen keine Disteln aufwachsen, ist eine wiederholte Klassifikation nicht notwendig. Durch den hohen Zeitaufwand ist eine großflächige Anwendung der vorgestellten Methodik ohne weitere Anpassung nicht möglich. Ein erster Ansatz für effizientere Algorithmen könnte hier eine dynamische Anpassung der Klassifikationsauflösung sein. Gestartet mit einer niedrigen Auflösung könnte so in der Umgebung von gefundenen Disteln die Auflösung erhöht werden, um die Pflanzen pixelgenau abzubilden, ohne viel Rechenzeit in Anspruch zu nehmen.

4.2 Schätzung des Bedeckungsgrads

Wie in Abbildung 6 A erkennbar ist, wird der Bedeckungsgrad pro 0,25 m² zu den ersten vier Terminen überwiegend unterschätzt, am 13.06 jedoch deutlich überschätzt. Der durchschnittliche Bedeckungsgrad der gesamten 9 m² großen Testfläche wird an den ersten vier Terminen konstant um 3-5 % unterschätzt (s. Abb. 6 B). Es lässt sich daher vermuten, dass der Bedeckungsgrad der ersten vier Termine mit einem konstanten Faktor korrigiert werden könnte. Die deutliche Überschätzung des Bedeckungsgrads am 13.06. lässt sich mit der schlechten Klassifikationsgenauigkeit an diesem Termin erklären (s. Tab. 2). Bei dem verwendeten Schwellwert von 95 % für die Ableitung des Bedeckungsgrades

liegt diese bei 73,03 % (s. Abb. 5) und damit mehr als 10 % geringer als die Klassifikationsgenauigkeit vom 07.06. (86,65 %). Im Gegensatz zu den vorherigen Terminen gibt es am 13.06. sich deutlich überlappende Pflanzenbereiche, sodass einzelne *C. arvense*-Pflanzen nicht mehr gut voneinander oder von Maispflanzen abgrenzbar sind. Wie in Abbildung 3 erkennbar, werden so größere zusammenhängende Bereiche von Boden oder hereinragenden Pflanzenteilen mit klassifiziert. Der ausgleichend wirkende Effekt von Fehlklassifikationen an den äußeren Blättern der Distelpflanzen kommt so vermutlich nicht mehr zur Geltung, woraus die Überschätzung des Bedeckungsgrads resultiert. In der Arbeit von Mink et al. [Mi18] wurde der Bedeckungsgrad von *C. arvense*, bei einer Mindesthöhe von 6 cm, mithilfe eines indexbasierten Ansatzes auf 9×9 m großen Testflächen sowohl aus spektralen Informationen als auch Informationen über die Pflanzenhöhe geschätzt. Auch hier wurde der tatsächliche Bedeckungsgrad um 1-10 % unterschätzt. Der in dieser Arbeit vorgestellte Ansatz auf Basis von Neuronalen Netzen ist somit mit einem indexbasierten Ansatz vergleichbar. Für eine präzise Schätzung des Bedeckungsgrads von *C. arvense* eignet sich der vorgestellte Ansatz durch die auftretende Unterschätzung jedoch nur bedingt. Mit einer pixelbasierten, segmentierenden Klassifikation anstelle des vorgestellten patchbasierten Ansatzes könnten bessere Ergebnisse in Bezug auf die Schätzung des Bedeckungsgrads erzielt werden und auch genauere Aussagen in Bezug auf die Pflanzengröße getroffen werden. Mithilfe dieser Informationen könnten weiterhin einzelpflanzenspezifische Aussagen über den idealen Behandlungszeitpunkt abgeleitet werden.

5 Fazit und Ausblick

Durch den schnellen Wiederaustrieb des perennierenden Beikrauts ist eine frühzeitige Erkennung und Abpassung des optimalen Behandlungszeitpunktes für einen hohen Regulierungserfolg mit geringem Herbizidaufwand unerlässlich. Eine frühzeitige Erkennung ist mit dem in dieser Arbeit vorgestellten System möglich und kann damit zu einem resilienten Umgang mit dem Auftreten von *C. arvense* in Ackerkulturen beitragen. Durch das Ensemble aus CNNs kann *C. arvense* zuverlässig auch in frühen Wachstumsstadien detektiert und von anderen aufwachsenden Beikräutern differenziert werden. Diese Klassifikation kann genutzt werden, um den Bedeckungsgrad mit einem Toleranzbereich von etwa 5 % zu detektieren. Mit fortschreitendem Wachstum und sich überlappenden Pflanzenteilen wird die Klassifikation von *C. arvense* jedoch erschwert und der Bedeckungsgrad deutlich überschätzt. Es ist zu vermuten, dass die Klassifikationsgenauigkeit und auch die Schätzung des Bedeckungsgrads durch einen segmentierenden, pixelbasierten Ansatz verbessert werden kann. Diese Segmente könnten zusätzlich genutzt werden, um die Größe einzelner *C. arvense*-Pflanzen abzuleiten und den optimalen Behandlungszeitpunkt zu bestimmen. Ein regelmäßiges Monitoring ausgewählter Distelnester könnte so realisiert werden. Die Effizienz der in dieser Arbeit behandelten Methodik könnte durch die Konzipierung spezialisierter Algorithmen deutlich verbessert werden. Speziell die Nutzung der räumlichen Kohärenz der Pflanzen bietet hier Potential. Um den vorgestellten Ansatz auf andere Kulturen und Beikrautarten zu übertragen, müsste

eine entsprechende Menge an Trainingsdaten bereitgestellt werden. Die Ergebnisse zeigen, dass mit einer entsprechenden Normalisierung Daten mehrerer Aufnahmetermine zu unterschiedlichen phänologischen Phasen und wechselnder Wetterbedingungen in einer gemeinsamen Klassifikation verwendet werden können, wodurch die Erstellung einer solchen Datenbasis für Trainingsdaten erleichtert wird.

Anmerkung

Der verwendete UAV-Datensatz sowie die Parametrisierung des verwendeten CNN-Ensembles können auf begründete Anfrage zur Verfügung gestellt werden.

Förderhinweis und Danksagung: Das Projekt CognitiveWeeding wird durch die Mittel des Bundesministeriums für Umwelt, Naturschutz, nukleare Sicherheit und Verbraucherschutz (BMUV) aufgrund eines Beschlusses des Deutschen Bundestages gefördert. Ein besonderer Dank geht an den Studenten Lukas Grund, der durch die Erstellung von Polygonen auf der Testfläche wichtige Vorarbeiten für die Validierung der Klassifikationsergebnisse geleistet hat.

Literaturverzeichnis

- [Ba22] Bayrische Landesanstalt für Landwirtschaft: Acker-Katzdistel: Unkrautsteckbrief, 2022, url: https://www.lfl.bayern.de/ips/unkraut/u_steckbriefe/053954/index.php
- [CH21] Christensen, S.; Dyrmann, M.; Laursen, M.; Jørgensen, R.; Rasmussen, J.: Sensing for Weed Detection. In: Sensing Approaches for Precision Agriculture. Springer, S. 275-300, 2021.
- [DGK04] Dicke, D.; Gerhards, R.; Kühbauch, W.: Überprüfung bestehender Schadschwellen auf ihre Eignung für die teilschlagspezifische Unkrautkontrolle in Braugerste unter Verwendung eines Geoinformationssystems. Integration und Datensicherheit–Anforderungen, Konflikte und Perspektiven, Referate der 25. GIL Jahrestagung/, 2004, url: <https://dl.gi.de/bitstream/handle/20.500.12116/29083/GI.Proceedings.4982.pdf?sequence=1&isAllowed=y>, Stand: 19. 01. 2022.
- [EU20] The European Commission: Communication from the Commission to the European Parliament, the Council, the European economic and social committee and the Committee of the regions, A Farm to Fork Strategy for a fair, healthy and environmentally-friendly food system, 20. Mai 2020, url: https://eur-lex.europa.eu/resource.html?uri=cellar:ea0f9f73-9ab2-11ea-9d2d01aa75ed71a1.0001.02/DOC_1&format=PDF.
- [Ka21] Kattenborn, T.; Leitloff, J.; Schiefer, F.; Hinz, S.: Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. ISPRS Journal of Photogrammetry and Remote Sensing 173/, S. 24-49, 2021.

- [Ha21] Hasan, A. M.; Sohel, F.; Diepeveen, D.; Laga, H.; Jones, M. G.: A survey of deep learning techniques for weed detection from images. *Computers and Electronics in Agriculture* 184/, S. 106067, 2021.
- [NS11] Nkurunziza, L.; Streibig, J. C.: Carbohydrate dynamics in roots and rhizomes of *Cirsium arvense* and *Tussilago farfara*. *Weed Research* 51/5, S. 461-468, 2011.
- [Pa17] Pawara, P.; Okafor, E.; Schomaker, L.; Wiering, M.: Data augmentation for plant classification. In: International conference on advanced concepts for intelligent vision systems. Springer, S. 615-626, 2017.
- [RAN21] Rasmussen, J.; Azim, S.; Nielsen, J.: Pre-harvest weed mapping of *Cirsium arvense* L. based on free satellite imagery – The importance of weed aggregation and image resolution. *European Journal of Agronomy* 130/, S. 126373, 2021.
- [RN20] Rasmussen, J.; Nielsen, J.: A novel approach to estimating the competitive ability of *Cirsium arvense* in cereals using unmanned aerial vehicle imagery. *Weed research* 60/2, S. 150-160, 2020.
- [Ry21] Rydahl, P.; Bøjer, O.; Jensen, N. - P.; Nielsen, M.; Paz, L. -C.; Pedersen, K.; Jensen, K.; Rasmus, J.; Scovill, A.; Laursen, M.; Teimouri, N.; Hartmann, B.: Analysis of potential herbicide savings using experience and data from the RoboWeedMaPS project: Report prepared as a result of participation in project 2020-68795, under the Danish Environmental Protection Agency. "Precision Spraying Partnership". 2021
- [SL09] Sokolova, M.; Lapalme, G.: A systematic analysis of performance measures for classification tasks. *Information processing & management* 45/4, S. 427-437, 2009.
- [Sö10] Sökefeld, M.: Variable rate technology for herbicide application. In: Precision crop protection-the challenge and use of heterogeneity. Springer, S. 335-347, 2010.
- [TVL19] Tavaziva, V. J.; Verwijst, T.; Lundkvist, A.: Growth and development of *Cirsium arvense* in relation to herbicide dose, timing of herbicide application and crop presence. *Acta Agriculturae Scandinavica, Section B—Soil & Plant Science* 69/3, S. 189-198, 2019.