

KI-basierte Detektion von Feldhamsterbauen auf landwirtschaftlichen Nutzflächen mittels multi-sensoraler UAS-Daten

F. Thürkow,¹ C. Lorenz,² J. Ramstetter,² I. Hoppe³ und M. Haase³

Abstract: Der zunehmende Druck auf Landwirtschaftsbetriebe, vitale Feldhamsterpopulationen zu erhalten, steht dem regional variierenden Risiko von Ernteausfällen durch Feldmausfraßschäden gegenüber. Diese Herausforderung ist eng mit den Zielen des Sustainable Development Goals 2 der Vereinten Nationen verknüpft, die Ernährungssicherheit und eine nachhaltige Landwirtschaft anstreben. In dieser Studie wird die Erschließung einer Methode zur automatisierten Detektion von Feldhamsterbauen anhand von Drohnen-basierten RGB- und Thermaldaten untersucht. Zu diesem Zweck werden Faster / Mask R-CNN Objektdetektionsmodelle trainiert. Die Auswertung konzentriert sich auf die Güte dieser, welche anhand unterschiedlicher Flugparameter und einer Feinkartierung validiert werden. Für die RGB-Sensoren Weitwinkel (Brennweite = 4.5 mm) und Zoom (Brennweite = 21-75 mm) kann Faster R-CNN 56 % der Baue erfassen. Mask R-CNN erzielt auf Basis der RGB-Sensoren, sowie des Thermalsensors Trefferquoten von über 80 %. Mit Blick auf die aktuelle und zukünftige Rolle von Naturschutz und Landwirtschaft deuten die Ergebnisse dieser Studie auf einen signifikanten Mehrwert KI-basierter UAS-Ansätze hin.

Keywords: UAS, Künstliche Intelligenz, Objektdetektion, R-CNN, Landwirtschaft, Feldhamster

1 Einleitung

Die Ernährung einer wachsenden Weltbevölkerung bei gleichzeitigem Anspruch an eine umweltschonende und nachhaltige Landwirtschaft stellt Landwirtschaftsbetriebe vor zunehmende Herausforderungen. Die 2015 von den Vereinten Nationen beschlossenen *Sustainable Development Goals 2* (SDG2) beinhalten sowohl eine Null-Hunger-Strategie als auch die Förderung einer nachhaltigen Landwirtschaft [Gi19; Un]. Auf regionaler Ebene sind diese innerhalb der Europäischen Union in der *Gemeinsamen Agrarpolitik* (GAP) verankert und leiten politische Entscheidungen [Di]. Dem Ziel, eine ertragreiche und nachhaltige landwirtschaftliche Produktion zu gewährleisten, können insbesondere Tierfraß bedingte Schäden entgegenwirken. In dem landwirtschaftlich geprägten Flächenland Sachsen-Anhalt gehen diese vornehmlich auf die Feldmaus (*Microtus arvalis*) zurück. In Gradationsjahren belaufen sich diese Ernteverluste auf bis zu 80 % [EWR11; JT10; Lu13]. Eine Besonderheit des Bundeslandes ist, dass sich die Risikoregionen der Feldmausschäden nahezu vollständig

¹ Bern University of Applied Sciences, TI, Biel, Schweiz florian.thuerkow@bfh.ch

² Umwelt- und GeodatenManagement GbR, Halle (Saale), Deutschland info@umgeodat.de

³ Landschaftspflegeverband "Grüne Umwelt" e. V. info@lpv-gruene-umwelt.de



mit dem regionalen Vorkommensgebiet des Feldhamsters (*Cricetus cricetus*) decken [Bua; Wo]. Der Feldhamster ist weltweit vom Aussterben bedroht und gilt als streng geschützte Art, die gemäß § 44 BNatSchG weder gestört noch getötet werden darf [Ba19; Bub]. Dieser Schutzstatus des Feldhamsters macht es erforderlich, dass bei massiven Feldmausbefall nur dann gegen diese mit Rodentiziden vorgegangen werden kann, wenn das Vorkommen des Feldhamsters nachweislich ausgeschlossen ist [Ba19; Bua; Mia]. Zu den gängigsten Erfassungsmethoden gehören Feinkartierungen, die eine vollständige Begehung des betroffenen Schlages erfordern [KKW01]. Die Anwendung unbemannter Luftfahrtsysteme (UAS) in Kombination mit Künstlicher Intelligenz (KI) könnte als vielversprechende Technologien Abhilfe schaffen [E119; PR18]. Der Einsatz von UAS (Drohnen) erfolgt zunehmend auch in der Landwirtschaft [Ch18; Gr22; Ju21]. Aktuelle Anwendungsgebiete sind die Überwachung der Ernte, die Präzisionslandwirtschaft, die Schädlings- und Krankheitsbekämpfung, die Aussaat, sowie der Natur- und Artenschutz [Ch18; Ta20]. Darüber hinaus ermöglichen Thermalmessungen die Überwachung der Boden- und Pflanzentemperatur sowie des Pflanzenstresses [Pa17]. Die Integration solcher Ansätze in KI-Modelle ermöglicht eine präzise und zeitnahe Überwachung und Analyse landwirtschaftlicher Flächen. Dies trägt wiederum zu einer verbesserten Entscheidungsfindung und letztlich zu einer nachhaltigeren und produktiveren Landwirtschaft bei [BMEL]. Im Sinne der Feldhamsterdetektion existiert jedoch noch keine hinreichende Lösung. Eine automatisierte, KI-gestützte Erkennung von Feldhamsterbauen auf landwirtschaftlichen Nutzflächen unter Verwendung von UAS-RGB- und Thermaldaten könnte dazu einen wichtigen Beitrag leisten. Hier knüpft unsere Arbeit im Projekt CRIFORA an [CR].

In der hier vorgestellten Studie verwenden und vergleichen wir zwei Ansätze des maschinellen Lernens (ML): Faster R-CNN und Mask R-CNN, die für die KI-gesteuerte, bildbasierte Objekterkennung genutzt werden [Gi14; Re15]. Ziel unserer Arbeit ist die automatisierte Detektion von Feldhamsterbauen anhand dieser ML-Ansätze auf Grundlage von RGB- und Thermalorthomosaik im Kontext einer nachhaltigen und ressourcenschonenden Landwirtschaft.

2 Material und Methoden

2.1 Untersuchungsgebiet und Datengrundlage

Das Untersuchungsgebiet (Abb. 1a) konzentriert sich auf eine Fläche von insgesamt 0,6 ha in der Nähe von Prosigk (Landkreis Anhalt-Bitterfeld, Sachsen-Anhalt). Der dort ansässige landwirtschaftliche Betrieb wirtschaftet pfluglos bzw. im Direktsaatverfahren. Der Boden des Standortes wird der Tschernosem-Lössböde zugeordnet [Mib; Mi99]. Auf dieser nährstoffreichen Schwarzerde wurde im Untersuchungszeitraum Winterweizen angebaut – die anbaustärkste Kultur Sachsen-Anhalts [La]. Das Gebiet ist aufgrund abiotischer und biotischer Faktoren ein geeignetes Habitat für Feldhamster und Feldmäuse. Feldhamsterbaue lassen sich in ihrer Form und ihrem Verteilungsmuster von Feldmausbauen gut differenzieren.

Im Vergleich sind die Eingänge von Feldhamsterbauen meßbar größer (bspw. 8 statt 3 cm im Durchmesser) und tiefer angelegt.



Abb. 1: a) Räumliche Verortung des Untersuchungsgebiets. b) Loch mit Fraßkreis (Zoomfoto: 120 m)

Die Drohnenbefliegungen mit parallel stattfindender Feinkartierung des betroffenen Schlages erfolgten am 24.04. und 05.05.2023. Zu diesem Zeitpunkt waren bereits Feldhamster aktiv. Geöffnete Fallröhren zeichneten sich durch Fraßkreise aus (Abb. 1b). Für die Drohnenbefliegung nutzten wir die *DJI Matrice 30 T* (M30T) in Höhen von 12, 30, 50, 100 und 120 m bei einer Fluggeschwindigkeit von 1 m/s. Die M30T verfügt über einen Weitwinkel- (W), einen Zoom- (Z) und einen Thermalsensor (T). Bei dem W-Sensor handelt es sich um einen 12 MP 1/2"CMOS-Scanner, mit einer Brennweite von 4.5 mm, einer f/2.8-Blende und einer maximalen Bildauflösung von 4000x4000 px [DJ]. Der Z-Sensor setzt auf einen 48 MP 1/2"CMOS-Scanner, mit einer variablen Brennweite zwischen 21 und 75 mm, f/2.8 bis f/4.2 für die Blende und einer maximalen Auflösung von 8000x6000 px [DJ]. Der T-Sensor ist ein ungekühltes VOx-Mikrobolometer mit einer Brennweite von 9.1 mm, einer f/1.0-Blende und einer maximalen Auflösung von 640x512 px mit Messgenauigkeiten von ± 2 °C [DJ]. Die Feinkartierung wurde unmittelbar im Anschluss an die Befliegungen durchgeführt. Die gefundenen Feldhamsterbaue maßen wir mit einem differentiellen GNSS (ppm 10xx GNSS-Sensor) zentimetergenau ein.

Höhe [m]	Flugdauer [min]	Gebiet [ha]	GSD T [cm/px]	GSD W [cm/px]	GSD Z [cm/px]	W	Z	T
12	88,27	0,6	1,58	0,43	-	x	-	x
30	28,29	0,6	3,96	1,07	0,11	x	x	x
50	17,43	0,6	6,59	1,78	0,19	x	x	-
100	9,20	0,6	13,19	3,56	0,38	x	x	-
120	11,8	0,6	15,82	4,27	0,46	x	x	-

Tab. 1: Überblick der Flugparameter und eingesetzter Sensoren. GSD Ground Sampling Distance, W Weitwinkel, Z Zoom, T Thermal

Die Validierung der Güte der KI-Ansätze auf Grundlage dieser Befliegungen und der Feinkartierung erfordert bereits trainierte Modelle. Die in dieser Studie eingesetzten KI-Modelle trainierten wir anhand von über 2.200 Bildern, die zwischen *Juni 2022* und *März*

2023 an drei Standorten unterschiedlicher Landschaftseinheiten Sachsen-Anhalts aggregiert wurden (Prosigk, Eilsleben, Wanzleben). Zirka 2.000 dieser Luftbildaufnahmen basierten auf den Sensoren W und Z und gingen in das Training der RGB-KI-Modelle (Faster und Mask R-CNN) ein. Auf das Thermalmodell (Mask R-CNN) entfielen ca. 200 Bilder.

2.2 Gewählter Ansatz des maschinellen Lernens

Für das Vorhaben der automatisierten Erfassung von Feldhamsterstrukturen wurden bildbasierte ML-Ansätze zur Objekterkennung gewählt: Faster R-CNN und Mask R-CNN (ResNet-50), deren Implementierung mit Tensorflow²⁴ (TF2) und Detectron²⁵ (D2) erfolgte. Beide stellen Weiterentwicklungen der Ansätze CNN, R-CNN und Fast R-CNN dar, die in Kontexten der Gesichtserkennung und des autonomen Fahrens entwickelt wurden [Gi13; Gi15; ON15]. Das Ziel dieser ist es, anhand von Bildmaterial festgelegte Objektklassen automatisiert zu erfassen [Gi14; Re15]. Faster R-CNN und Mask R-CNN setzten auf zwei zentrale Verfahren: einem Regional Proposal Network (RPN) und einem Convolutional Neural Network (CNN) [Re15]. Das RPN ist dem CNN vorgeschaltet. Auf Grundlage eines eingegangenen Bildes werden durch das RPN grobe rechteckige Objektvorschläge, auch Regions of Interest (ROI) genannt, bestimmt und diese an das CNN übermittelt [He17; Re15]. Das CNN extrahiert Merkmale dieser Objektvorschläge und führt Klassifikationen und Regressionen basierend auf diesen aus. Die Ausgabe ist ein Bild mit Bounding Boxen, die das detektierte Objekt umrahmen und die Objektklasse samt Klassifikationsgüte ausgeben [Gi14; He17; Re15]. Mask R-CNN erweitert diesen Ansatz um ein Fully Convolutional Network (FCN), das parallel zum CNN geschaltet ist (Abb. 2) [He17]. Im Gegensatz zum CNN lokalisiert und klassifiziert das FCN Objekte auf Basis der ROIs pixelbasiert. So ist eine exakte Größenbestimmung der detektierten Objekte möglich [WZL19]. Um eine objektbasierte Detektion von Feldhamsterbauen zu erzielen, müssen die ML-Ansätze auf Basis solcher Datensätze trainiert werden. Für Faster R-CNN wurden die auf den Trainingsbildern sichtbaren Hamsterbaue mit Bounding Boxen gelabelt, wohingegen wir für Mask R-CNN pixelgenaue Polygonmasken verwendeten. Selbiges gilt für das Training des Thermal Mask R-CNN Modells. Hier generierten wir aus den Rohbilddaten zunächst Orthomosaik, um die in den Randbereichen ausgeprägten Temperaturverzerrungen zu umgehen.

2.3 Methode

Das Verfahren zur Anwendung und Auswertung der KI-Modelle begann mit der Datenerhebung. Diese setzte sich aus Feldkartierungen zur Sammlung von Ground Truth Daten und parallelen UAS-Flügen zusammen. Die gesammelten UAS-Daten wurden mit der Software

⁴ <https://www.tensorflow.org/>

⁵ <https://github.com/facebookresearch/detectron2>




Abb. 2: Grundaufbau von Faster R-CNN (ohne FCN) und Mask R-CNN (mit FCN)

Pix4DMapper zu Orthomosaiken verarbeitet (vgl. Tab. 1). Diese boten eine vollständige und detaillierte Darstellung des untersuchten Gebiets und bildeten die Grundlage für die spätere räumliche Verortung der erfassten Objekte sowie für die nachfolgenden KI-basierten Analysen. Um die Berechnungsintensität des Detektionsprozesses zu verringern und die KI-Algorithmen effizienter zu gestalten, wurden die Orthomosaik in individuelle Kacheln zerteilt. Hierbei betrug die Größe der Kacheln für Weitwinkel- und Thermaldaten 500x500 Pixel, während für Zoom-Kamera-Daten Kacheln mit einer Größe von 1000x1000 Pixel verwendet wurden. Diese Kacheln wurden an die trainierten Modelle übergeben, welche anhand dieser eine Reihe von Bounding-Boxen bzw. Polygonmasken erstellten, die potenzielle Feldhamsterbaue darstellten, und deren Genauigkeitsbewertung bestimmten. Für die Detektionen wurden spezifische Grenzwerte⁶ für die Genauigkeitsbewertung festgelegt. Detektionen, die diese Grenzwerte nicht erreichen konnten, wurden nicht ausgegeben. Das Festlegen dieser spezifischen Grenzwerte erfolgte auf Grundlage der Datenqualität und Bodenaufklärung (GSD).

3 Ergebnisse und Diskussion

Die Feinkartierung ermittelte die Standorte von 16 Feldhamsterbauen. Tab. 2 fasst die Detektionsergebnisse aller Sensoren und Flughöhen zusammen. Die höchste Anzahl an Detektionen, die mit der Feinkartierung übereinstimmen, gehen auf Mask R-CNN mit 14 (Weitwinkel: 12 m), 12 (Thermal: 12 m) und 11 (Zoom: 100 m) zurück. Faster R-CNN ermittelte im Vergleich für *Weitwinkel: 12 m* und *Zoom: 100 m* 9 Baue. Falsch-positive Detektionen traten für Faster R-CNN nur marginal auf (Maximalwert = 5 bei *Weitwinkel: 12 m*). Demgegenüber stehen die Werte von Mask R-CNN, die bei niedrigen Flughöhen zwischen 13 - 39 betragen.

Abb. 3 stellt die Detektionen von *Thermal: 12 m* und *Zoom: 100 m* gegenüber. Dargestellt werden die tatsächlich detektierten Löcher, um einen besseren Vergleich zwischen diesen und der Feinkartierung zu ermöglichen. Beide Sensoren erzeugen vergleichbare Detektionen.

⁶ RGB-Weitwinkel = 50 % | RGB-Zoom = 60 % | Thermal = 25 %)

Höhe [m]	Weitwinkel [RGB]						Zoom [RGB]						Thermal		
	Mask R-CNN			Faster R-CNN			Mask R-CNN			Faster R-CNN			Mask R-CNN		
	r	z	f	r	z	f	r	z	f	r	z	f	r	z	f
12	14	6	39	9	5	5	-	-	-	-	-	-	12	4	13
30	8	1	1	4	0	0	-	-	-	-	-	-	0	0	0
50	6	1	1	4	1	0	6	1	21	6	0	0	-	-	-
100	0	0	0	0	0	0	11	1	9	9	0	2	-	-	-
120	0	0	0	0	0	1	9	7	2	9	5	0	-	-	-

Tab. 2: Detektionsergebnis der KI-Modelle.

(Legende: r = Detektiertes Loch; von der Feinkartierung erfasst | z = Detektiertes Loch; von der Feinkartierung nicht erfasst | f = Falsch-positiv; ein Objekt wurde fälschlicherweise als Loch detektiert.)




Abb. 3: Gegenüberstellung der tatsächlich kartierten und detektierten Löcher der Modelle Mask R-CNN Thermal für 12 m und Mask R-CNN Zoom (RGB) für 100 m.

Diese Studie konnte zeigen, dass eine KI-basierte, automatisierte Detektion von Feldhamsterterbauen anhand von UAS RGB- und Thermalbildern möglich ist und vielversprechende Ergebnisse erzielen kann. Die von uns eingesetzten Modelle, denen die im Rahmen dieser Studie analysierten Daten nicht bekannt waren, sind je nach Flugparameter und Sensor in der Lage, bis zu 87,5 %⁷ der kartierten Baue zu erfassen. Zusätzlich können Baue detektiert werden, die die Feinkartierung nicht erfasste. Diese Erkenntnis deckt sich mit anderen Studien [Co21]. Unsere KI-Modelle wurden größtenteils mit Daten einer anderen Vegetationsperiode trainiert. Dies kann als eine Ursache der aktuell noch unzureichenden Ergebnisqualität betrachtet werden [Hu21].

4 Zusammenfassung und Ausblick

Weitere Ansätze, um die Fehlerquote der Mask R-CNN Ergebnisse zu verringern, liegen in der Anwendung von Denoising-Algorithmen oder der Sensor-Fusion der UAS-Sensoren, die innerhalb des Projektes bereits vorbereitet werden [Ha17; Na20; SZL19]. Die bisherigen Ergebnisse zeigen jedoch schon jetzt das große Potenzial KI-basierter und Drohnen-gestützter Befliegungen landwirtschaftlicher Flächen an - insbesondere im Hinblick auf die Umsetzung der SDG2- und GAP-Ziele, die eine zeitnahe und fallspezifische Festlegung von Strategien benötigen.

⁷ Mask R-CNN: Zoom 100m

Literatur

- [Ba19] Banaszek, A.; Bogomolov, P.; Feoktistova, N.; La Haye, M.; Monecke, S.; Reiners, T.; Rusin, M.; Surov, A.; Weinhold, U.; Ziomek, J.: IUCN Red List of Threatened Species: *Cricetus cricetus*. IUCN Red List of Threatened Species/, Juni 2019, URL: <https://www.iucnredlist.org/en>, Stand: 25.05.2023.
- [BMEL] Bundesministerium für Ernährung und Landwirtschaft: BMEL fördert Projekte zum Einsatz von Künstlicher Intelligenz in der Landwirtschaft und den ländlichen Räumen, URL: <https://www.bmel.de/DE/themen/digitalisierung/kuenstliche-intelligenz.html>, Stand: 25.05.2023.
- [Bua] Bundesamt für Naturschutz: Kombinierte Vorkommen- und Verbreitungskarte der Pflanzen- und Tierarten der FFH-Richtlinie - 1339 *Cricetus cricetus* (Feldhamster), Stand: 03.05.2023.
- [Bub] Bundesministerium für Justiz: § 44 Vorschriften für besonders geschützte und bestimmte andere Tier- und Pflanzenarten, Gesetz über Naturschutz und Landschaftspflege, URL: https://www.gesetze-im-internet.de/bnatschg_2009/_44.html, Stand: 14.04.2023.
- [Ch18] Christen, M.; Guillaume, M.; Jablonowski, M.; Moll, K.: Zivile Drohnen-Herausforderungen und Perspektiven. vdf, Zürich, 2018, ISBN: 978-3-7281-3893-4.
- [Co21] Cox, T. E.; Matthews, R.; Halverson, G.; Morris, S.: Hot stuff in the bushes: Thermal imagers and the detection of burrows in vegetated sites. *Ecology and Evolution* 11/11, S. 6406–6414, Juni 2021, ISSN: 2045-7758, 2045-7758, URL: <https://onlinelibrary.wiley.com/doi/10.1002/ece3.7491>, Stand: 27.05.2023.
- [CR] CRIFORA: CR*I*cetus FOR*A*mins Radar Detektion, URL: <https://www.crifora.de/>, Stand: 03.05.2023.
- [Di] Directorate General for Agriculture and Rural Development: Key policy objectives of the CAP 2023-27, URL: https://agriculture.ec.europa.eu/common-agricultural-policy/cap-overview/cap-2023-27/key-policy-objectives-cap-2023-27_en#:~:text=Key%20objective%3A%20contribute%20to%20climate,well%20as%20promoting%20sustainable%20energy., Stand: 21.05.2023.
- [DJ] DJI: Specs - Matrice 30 Series - DJI Enterprise, URL: <https://enterprise.dji.com/matrice-30/specs>, Stand: 25.05.2023.
- [EI19] Eli-Chukwu, N. C.: Applications of Artificial Intelligence in Agriculture: A Review. *Engineering, Technology & Applied Science Research* 9/4, S. 4377–4383, Aug. 2019, ISSN: 1792-8036, 2241-4487, URL: <http://etasr.com/index.php/ETASR/article/view/2756>, Stand: 25.05.2023.

- [EWR11] Eggert, J.; Wolff, C.; Richter, K.: Searching for alternative methods for a sustainable population management of the common vole (*Microtus arvalis*) in Saxony-Anhalt. en, Julius-Kühn-Archiv; 432; 154-155/, Artwork Size: p. 154-155 ISBN: 9783930037827 Medium: application/pdf Publisher: Julius Kühn-Institut, p. 154–155, Okt. 2011, URL: https://www.openagrar.de/receive/openagrar_mods_00083329, Stand: 25.05.2023.
- [Gi13] Girshick, R. B.; Donahue, J.; Darrell, T.; Malik, J.: Rich feature hierarchies for accurate object detection and semantic segmentation. CoRR abs/1311.2524/, 2013, arXiv: 1311.2524, URL: <http://arxiv.org/abs/1311.2524>.
- [Gi14] Girshick, R.; Donahue, J.; Darrell, T.; Malik, J.: Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. In: 2014 IEEE Conference on Computer Vision and Pattern Recognition. ISSN: 1063-6919, S. 580–587, Juni 2014.
- [Gi15] Girshick, R. B.: Fast R-CNN. CoRR abs/1504.08083/, 2015, arXiv: 1504.08083, URL: <http://arxiv.org/abs/1504.08083>.
- [Gi19] Gil, J. D. B.; Reidsma, P.; Giller, K.; Todman, L.; Whitmore, A.; van Ittersum, M.: Sustainable development goal 2: Improved targets and indicators for agriculture and food security. en, Ambio 48/7, S. 685–698, Juli 2019, ISSN: 1654-7209, URL: <https://doi.org/10.1007/s13280-018-1101-4>, Stand: 25.05.2023.
- [Gr22] Grenzdörffer, G.: UAV in der Landwirtschaft - Eine Übersicht aktueller Anwendungen und zukünftiger Potenziale./, S. 103–126, März 2022.
- [Ha17] Ha, Q.; Watanabe, K.; Karasawa, T.; Ushiku, Y.; Harada, T.: MFNet: Towards real-time semantic segmentation for autonomous vehicles with multi-spectral scenes./, S. 5108–5115, 2017.
- [He17] He, K.; Gkioxari, G.; Dollar, P.; Girshick, R.: Mask R-CNN. In: 2017 IEEE International Conference on Computer Vision (ICCV). IEEE, Venice, S. 2980–2988, Okt. 2017, ISBN: 978-1-5386-1032-9, URL: <http://ieeexplore.ieee.org/document/8237584/>, Stand: 25.05.2023.
- [Hu21] Hu, C.; Sapkota, B. B.; Thomasson, J. A.; Bagavathiannan, M. V.: Influence of Image Quality and Light Consistency on the Performance of Convolutional Neural Networks for Weed Mapping. Remote Sensing 13/11, S. 2140, 29. Mai 2021, ISSN: 2072-4292, URL: <https://www.mdpi.com/2072-4292/13/11/2140>, Stand: 27.05.2023.
- [JT10] Jacob, J.; Tkadlec, E.: Rodent outbreaks in Europe: dynamics and damage. In: Rodent Outbreaks: Ecology and impacts. Journal Abbreviation: Rodent Outbreaks: Ecology and impacts, S. 207–223, Jan. 2010.

- [Ju21] Jung, J.; Maeda, M.; Chang, A.; Bhandari, M.; Ashapure, A.; Landivar-Bowles, J.: The potential of remote sensing and artificial intelligence as tools to improve the resilience of agriculture production systems. en, *Current Opinion in Biotechnology, Food Biotechnology Plant Biotechnology* 70/, S. 15–22, Aug. 2021, ISSN: 0958-1669, URL: <https://www.sciencedirect.com/science/article/pii/S0958166920301257>, Stand: 25. 05. 2023.
- [KKW01] Köhler, A.; Kayser, M.; Weinhold, U.: Methoden zur Kartierung von Feldhamstern (*Cricetus cricetus*) und empfohlener Zeitbedarf. In: *Jahrbücher des Nassauischen Vereins für Naturkunde – 122*. S. 215–216, 2001, URL: https://www.zobodat.at/pdf/Jahrbuch-Nassauischen-Verein-Naturkunde_122_0215-0216.pdf.
- [La] Landesanstalt für Landwirtschaft und Gartenbau Sachsen-Anhalt: Winterweizen - Hinweise zur Sortenwahl 2022, URL: https://llg.sachsen-anhalt.de/fileadmin/Bibliothek/Politik_und_Verwaltung/MLU/LLFG/Dokumente/04_themen/sortenpruefung/sorten_hinweise/2022/wiwe.pdf, Stand: 04. 05. 2023.
- [Lu13] Luque-Larena, J.; Mougeot, F.; Viñuela, J.; Arroyo, B.; Jareño, D.; Arroyo, L.; Lambin, X.: Recent large-scale range expansion and outbreaks of the common vole (*Microtus Arvalis*) in NW Spain. *Basic and Applied Ecology in press*/, Juli 2013.
- [Mia] Ministerium für Umwelt, Landwirtschaft und Energie Sachsen-Anhalt: Ausschlussgebiete für den Einsatz von Rodentiziden mit dem Wirkstoff Zinkphosphid (Pflanzenschutz) in Sachsen-Anhalt im Zeitraum 1. März bis 31. Oktober, URL: <https://www.isip.de/isip/servlet/resource/blob/305610/5266c8459fe65f0c868d8c3aad6cbdb3/rodentizide-nt820-1-data.pdf>, Stand: 12. 05. 2023.
- [Mib] Ministerium für Wissenschaft, Energie, Klimaschutz und Umwelt (MWU) Sachsen-Anhalt: Vorläufige Bodenkarte von Sachsen-Anhalt 1:50000, URL: <https://metaver.de/trefferanzeige?docuuid=841cc2f3-5c07-4f19-a4e8-002e51ab6a39>, Stand: 25. 05. 2023.
- [Mi99] Michael Weller: *Bodenatlas Sachsen-Anhalt*. Geologisches Landesamt Sachsen-Anhalt, Halle (Saale), 1999.
- [Na20] Nayan, A.-A.; Saha, J.; Raqib Mahmud, K.; Kalam Al Azad, A.; Golam Kibria, M.: Detection of Objects from Noisy Images./, S. 1–6, 19. Dez. 2020, URL: <https://ieeexplore.ieee.org/document/9350521/>, Stand: 27. 05. 2023.
- [ON15] O’Shea, K.; Nash, R.: An Introduction to Convolutional Neural Networks. *CoRR abs/1511.08458*/, 2015, arXiv: 1511.08458, URL: <http://arxiv.org/abs/1511.08458>.

- [Pa17] Park, S.; Ryu, D.; Fuentes, S.; Chung, H.; Hernández-Montes, E.; O’Connell, M.: Adaptive Estimation of Crop Water Stress in Nectarine and Peach Orchards Using High-Resolution Imagery from an Unmanned Aerial Vehicle (UAV). en, *Remote Sensing* 9/8, S. 828, Aug. 2017, ISSN: 2072-4292, URL: <http://www.mdpi.com/2072-4292/9/8/828>, Stand: 25.05.2023.
- [PR18] Patrício, D. I.; Rieder, R.: Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. en, *Computers and Electronics in Agriculture* 153/, S. 69–81, Okt. 2018, ISSN: 0168-1699, URL: <https://www.sciencedirect.com/science/article/pii/S0168169918305829>, Stand: 25.05.2023.
- [Re15] Ren, S.; He, K.; Girshick, R.; Sun, J.: Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. In: *Advances in Neural Information Processing Systems*. Bd. 28, Curran Associates, Inc., 2015, URL: https://papers.nips.cc/paper_files/paper/2015/hash/14bfa6bb14875e45bba028a21ed38046-Abstract.html, Stand: 25.05.2023.
- [SZL19] Sun, Y.; Zuo, W.; Liu, M.: RTFNet: RGB-Thermal Fusion Network for Semantic Segmentation of Urban Scenes. *IEEE Robotics and Automation Letters* 4/3, S. 2576–2583, 2019.
- [Ta20] Talaviya, T.; Shah, D.; Patel, N.; Yagnik, H.; Shah, M.: Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. en, *Artificial Intelligence in Agriculture* 4/, S. 58–73, Jan. 2020, ISSN: 2589-7217, URL: <https://www.sciencedirect.com/science/article/pii/S258972172030012X>, Stand: 25.05.2023.
- [Un] United Nations: Transforming our world: the 2030 Agenda for Sustainable Development | Department of Economic and Social Affairs, URL: <https://sdgs.un.org/2030agenda>, Stand: 25.05.2023.
- [Wo] Wolff, C.: Feldmausschäden im Ackerbau- Erfahrungen aus Sachsen-Anhalt. Präsentation. Feldtag der Gesellschaft für konservierende Bodenbearbeitung, URL: <https://www.gkb-ev.de/publikationen/2015/15-12-02-mause/feldtag-15-12-02-wolff.pdf>, .
- [WZL19] Wei, Z.; Zhang, B.; Liu, P.: Object Dimension Measurement Based on Mask R-CNN. In: *Intelligent Robotics and Applications: 12th International Conference, ICIRA 2019, Shenyang, China, August 8–11, 2019, Proceedings, Part IV*. Springer-Verlag, Berlin, Heidelberg, S. 320–330, 8. Aug. 2019, ISBN: 9783030275372, URL: https://doi.org/10.1007/978-3-030-27538-9_27, Stand: 27.05.2023.