

# Künstliche Intelligenz in der Landwirtschaft

Katharina Böttcher  
Aktuelle Themen (AM3), WS 22/23  
Hochschule der Medien, Stuttgart  
Matrikelnummer: 42792  
kb140@hdm-stuttgart.de

## EINLEITUNG

Künstliche Intelligenz (KI) gewinnt in vielen Lebensbereichen immer mehr an Bedeutung. Dazu zählt auch die Landwirtschaft. Hier kann Künstliche Intelligenz insbesondere aufgrund von schwer vorhersehbaren Einflüssen, wie zum Beispiel Wetterveränderungen, eine Unterstützung bei der Steuerung und Planung der Arbeit sein. So soll es möglich werden, dass die Landwirtschaft profitabler und gleichzeitig nachhaltiger wird [1]. Die sogenannte Precision Agriculture beschäftigt sich dazu mit dem Management von Ressourcen basierend auf gesammelten Daten [2]. Im Anbetracht der wachsenden Weltbevölkerung ist ein besserer Ertrag aus der Landwirtschaft unumgänglich [3]. Anwendungsfälle für Künstliche Intelligenz sind die Bewässerung von Feldern und die Vorhersage von Ernteerträgen, aber auch Ernteroboter oder die Überwachung des Gesundheitszustandes von Nutztieren.

## DEFINITIONEN

Die Begriffe Machine Learning und KI werden häufig synonym verwendet, obwohl im Kern verschiedene Vorgehen gemeint sind. In diesem Kapitel wird daher auf die wichtigsten Begrifflichkeiten eingegangen, bevor es um die eigentlichen Anwendungsfälle geht.

Künstliche Intelligenz beschäftigt sich mit Programmen, welche Eingabedaten ähnlich wie ein Mensch verarbeiten kann. Diese Definition ist sehr vage und verändert sich über die Zeit. Vor fünf Jahrzehnten galt ein Schachprogramm noch als künstliche Intelligenz, heute ist es selbstverständlich in jedem Computer integriert [4]. Eine Künstliche Intelligenz entscheidet aufgrund von vorgegebenen Regeln, wie sie sich in welcher Situation zu entscheiden hat. Diese

Regeln muss sie aber nicht zwingend selbst lernen.

Algorithmen, welche auf Machine Learning basieren, lernen hingegen selbstständig aufgrund von gemachten Erfahrungen und Fehlern. Dazu werden ihnen große Datensätze zur Verfügung gestellt. Diese können entweder gelabelt sein, also gekennzeichnet, welche Inhalte wo im Datensatz vorkommen, oder keine Labels beinhalten. Die Arbeit mit gelabelten Daten wird Supervised Learning genannt. Beim Unsupervised Learning wird in den Daten ohne Labels nach Gemeinsamkeiten gesucht und so Cluster erstellt [4].

Ein Teilaspekt von Machine Learning ist Deep Learning. Für Deep Learning sind Neuronale Netzwerke notwendig. Sie sind das Grundgerüst für Deep Learning, da Deep Learning Algorithmen aus mindestens drei Neuronalen Netzwerken bestehen [5].

Neuronale Netzwerke basieren auf Neuronen. Neuronen sind im menschlichen Gehirn dafür zuständig elektrische Signale von einem Ende zum anderen zu schicken. Im Prinzip nehmen sie ein Signal entgegen und verarbeiten dies, bevor es als Ausgabe weitergegeben wird. Die Ausgabe erfolgt jedoch nur, wenn das Signal wichtig genug ist und einen Schwellenwert überschreitet [6].

Diese menschliche Funktionsweise wird vom Neuronalen Netzwerk übernommen. Die vier Komponenten von neuronalen Netzwerken sind Inputs, Weights, Bias und der Output.

Die Eingabe, die in ein Neuron reingeht, durchläuft drei Schritte. Zunächst werden die Eingabewerte gewichtet und anschließend

addiert. Zusätzlich wird der Bias addiert. Auf diese Summe wird dann eine Aktivierungsfunktion angewendet. Der Ausgabewert erhält dadurch einen aussagekräftigen Wert. Dieser liegt in der Regel zwischen 0 und 1 [7]. Das Lernen des Netzwerks basiert auf dem Anpassen von den Weights und Biases. Dazu muss der Fehler, also der Loss, zwischen dem vorhergesagten Output und der Ground Truth berechnet werden. Dieser Fehler soll minimal sein. Daher ist ein Optimierungsalgorithmus notwendig, der berechnet, wie die Weights verändert werden müssen, damit der Fehler kleiner wird. Hierzu wird das Gradientenabstiegsverfahren verwendet [6]. Um herauszufinden, wie die Änderungen eines Weights den Loss beeinflusst, benötigt man die partielle Ableitung, die mithilfe von Backpropagation berechnet wird [7]. Diese beiden Verfahren zusammen, ergeben eine verbesserte Variante von Weights und Biases. Nun kann ein neuer Loss berechnet werden. Das Verfahren wird dann beliebig oft wiederholt, bis der Loss gering genug ist.

Im Folgenden Kapitel geht es darum, wie diese Techniken die Landwirtschaft unterstützen können.

## ANWENDUNGEN IN DER LANDWIRTSCHAFT

In der Landwirtschaft wird sich unter anderem unter dem Begriff Precision Agriculture mit dem Thema Künstliche Intelligenz auseinandergesetzt. Precision Agriculture beschäftigt sich mit der Überwachung und Optimierung der Landwirtschaft mit Hilfe von digitalen Technologien. Der Begriff Precision Agriculture kommt davon, dass beispielsweise nicht mehr auf Verdacht gedüngt wird, sondern dass Messungen erfolgen, anhand derer abgelesen werden kann, wo eine Düngung notwendig ist [8]. Wichtig ist dafür das sogenannte Remote Sensing, also eine Datenerfassung auf Distanz. Das Ziel von Precision Agriculture ist es den Ertrag der Landwirtschaft zu steigern und gleichzeitig den Aufwand zu verringern [8]. Langfristig soll so die Ernährungssicherheit für die Erde sichergestellt werden.

## ÜBERWACHUNG VON TIEREN

Künstliche Intelligenz kommt nicht nur im Ackerbau zum Einsatz, sondern auch bei der Viehzucht. Beispielweise kann die Gesundheit von Kühen überwacht werden. Dadurch soll es ermöglicht werden frühzeitig Krankheiten oder Geburten zu erkennen. Die Zustände, die erkannt werden sollen, sind folgende: Lahmheiten, Östrus, Kalben, Mastitis, allgemein Krankheiten oder Unfälle. Die notwendigen Datensätze zum Training der Künstlichen Intelligenz bestehen aus den Daten von Sensoren, welche stündlich die Aktivität der Kuh erfassen. Dabei werden drei Stati definiert: Ausruhen, Stehen/Laufen und Fressen. Mit diesen Daten wird das stündliche Aktivitätslevel der Kuh beschrieben. Die stündlichen Daten werden für einen Tag zusammengefasst und beinhalten Informationen über die Verteilung der Aktivitäten, die Variation zwischen den Aktivitäten, sowie die zyklische Abfolge von Aktivitäten. Jeder Tag wird im Anschluss mit dem Zustand der Kuh an diesem Tag, wie sie von einem Pfleger festgestellt wurde, gelabelt. Außerdem wurden Stressfaktoren, wie Tierarztbesuche oder Umzüge auf andere Weiden/Ställe festgehalten. Die Label eines auffälligen Zustandes starten teilweise einige Tage bevor die Pfleger den Zustand bemerkten. Auf die so erhaltenen Datensätze wird der Random Forest Algorithmus angewendet [9].

Der Random Forest Algorithmus besteht aus mehreren Entscheidungsbäumen, welche die gegebenen Informationen auswerten und jeweils zu einem Ergebnis kommen. Das Ergebnis, welches am häufigsten gewählt wurde von den Bäumen, ist das Endresultat [9]. Dieses Verfahren wird in Abbildung 1 grafisch dargestellt.

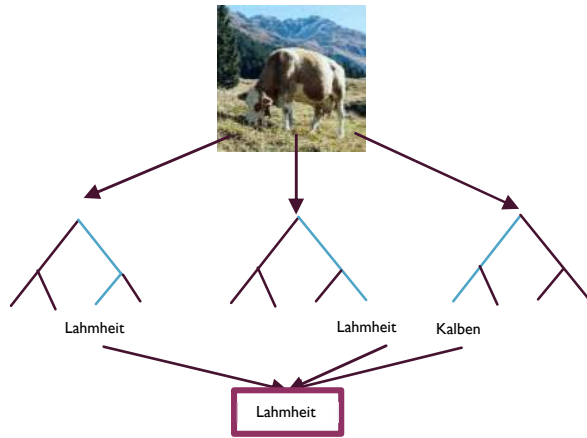


Abbildung 1: Random Forest Algorithmus zur Zustandserkennung von Kühen. Quelle: Eigene Abbildung.

Der Algorithmus klassifiziert einen Zustand, wenn er ihn erkennt meistens richtig. Jedoch werden oft Zustände nicht erkannt, oder es kommt zu Fehlalarmen. Dennoch bietet das Verfahren bereits den Vorteil, dass viele Zustände ein bis zwei Tage vor einem Pfleger erkannt werden können und somit schneller gehandelt werden kann [9].

### BEWÄSSERUNG

In Anbetracht der zunehmenden Wasserknappheit, spielt es eine immer größere Rolle, dass möglichst sparsam mit Wasser umgegangen wird. Das betrifft insbesondere die Landwirtschaft, da 70% des Wasserverbrauchs der Welt hier stattfindet [10].

Künstliche Intelligenz ermöglicht es automatische Bewässerungssysteme zu programmieren, indem sie beispielweise Wetterbedingungen vorhersagt. Dies ist insbesondere in Gegenden mit wechselnden Regenfällen, wie Indien wichtig. Ein Machine Learning Algorithmus berechnet die Wahrscheinlichkeit für Niederschlag in den nächsten 30 Minuten, sowie die geschätzte Regenmenge [11]. Auch hierfür wurde die Random Forest Regression verwendet, da sie sich besser dynamischen Echtzeitdaten anpasst, als es ein Artificial Neural Network und eine Support Vector Machine (SVM) tun. Für die Vorhersage von Regen sind 11 Parameter wichtig. Dazu gehören beispielweise die

durchschnittliche Monatstemperatur, sowie die jeweils höchste und niedrigste Temperatur, Luftfeuchtigkeit und -druck im letzten Zeitfenster. Der Machine Learning Algorithmus lernt mit Hilfe von Wetteraufzeichnungen aus dem jeweiligen Gebiet. Desweiteren wird ein Machine Learning Algorithmus gelernt, welcher aufgrund von den Wetterinformationen, Bodensensoren und Informationen über die Bodenbeschaffenheit und das angepflanzte Getreide bestimmt, wie viel Wasser das Feld benötigt. Der dazu benötigte Datensatz besteht aus Entscheidungen, die ein Landwirtschaftsexperte aufgrund der gegebenen Informationen trifft. Als Machine Learning Algorithmus wird die Partial Least Square Regression (PLSR) verwendet. Der Vorteil dieses Algorithmus ist, dass er gut damit zurechtkommt, wenn die Anzahl der Eingabevariablen deutlich größer ist, als die der möglichen Ausgaben [11].

Doch auch die Farbe des Getreides kann Rückschlüsse über die notwendige Bewässerung eines Feldes geben. Dazu muss eine Drohne über das Feld fliegen und Fotos aufnehmen. Die Fotos müssen eindeutig einem eigenständig ansteuerbarem Bewässerungsabschnitt des Feldes zugeordnet werden können. Dafür wird anstelle von GPS, Radio Frequency Identification verwendet. Das aufgenommene Luftbild wird weiterverarbeitet, um die durchschnittliche Getreidefarbe zu erhalten. Dazu werden nur die zusammenhängende Farbbereiche verwendet, welche Getreide ähneln. Der Input Layer für das verwendete Recurrent Neural Network besteht aus dem Farbmittelwert, der Temperatur und Informationen über das aktuelle Licht, dazu kommt selbige Information von der zuletzt erfolgten Datenerfassung, sowie der vorherige Output des RNN. Der Output repräsentiert das zur Bewässerung notwendige Wasservolumen [12]. Recurrent Neural Networks zeichnen sich dadurch aus, dass die Neuronen einer Schicht auch mit Neuronen einer vorherigen Schicht verbunden sein können. Dadurch können sie gut zeitlich codierte Daten entdecken [13]. In diesem Fall erkennen sie den Zusammenhang zwischen Bewässerung und der Veränderung der Pflanzenfarbe. Es wäre auch möglich, dass das

gleiche Netz den Zusammenhang zwischen Düngernutzung und Pflanzenfarbe lernt. Die Autoren achten darauf, dass die Methode auch in Entwicklungsländern ohne Internet- oder GPS Empfang funktioniert. Insbesondere in diesen Ländern ist es wichtig, Wasser zu sparen. Das System reguliert die Bewässerung so, dass das Getreide gerade so viel Wasser erhält, wie es benötigt, um gesund zu bleiben [12].

#### *ERNTEVORHERSAGEN*

Yield Mapping ist ein häufig verwendetes Verfahren in der Precision Agriculture. Diese Karten treffen Aussagen über den Ertrag, den ein Feldabschnitt erbracht hat und liefern so wichtige Informationen: Der Landwirt kann damit erkennen welche Stellen im Feld wenig Ertrag liefern und inwiefern sich dies durch eine angepasste Bewässerung oder Düngung ändert. Als Yield Mapping zu Beginn der 1990er Jahre aufkam, wurden Karten anhand von GPS- und Bodensensordaten erstellt.

Ein Beispiel für das Vorgehen bei Yield Mapping ist die Arbeit von Wei et al. [14]. Sie erstellen Yield Maps, die den Ertrag der Karottenernte mithilfe von spektralen Luftbildern vorhersagen. Dazu wird das Machine Learning Verfahren Random Forest Regression genutzt. Zunächst ist es notwendig Daten zu erhalten, von denen die KI lernen kann. Das Verfahren funktioniert so, dass die Karotten von einer Maschine geerntet und in Kisten gefüllt werden. Die Kisten bleiben auf dem Feld stehen. Im Anschluss werden Luftbilder genommen, wobei ein Pixel einer Fläche von 3x3m entspricht. Im Anschluss wird für jedes Pixel die Anzahl der Karottenkisten gezählt. Die Luftbilder beinhalten vier spektrale Bänder für Blau, Grün, Rot und nahes Infrarot (NIR). Es wurden insgesamt 88 Bilder im Laufe des Wachstums der Karotten aufgenommen. Im Folgenden wird die spektrale Verteilung pro Pixel in Relation mit den geernteten Karotten für dieses Pixel gesetzt. Dies geschieht mithilfe von Machine Learning und der Random Forest Regression. Dabei stellt sich heraus, dass die fünf wichtigsten Variablen für die Bestimmung der Erntemenge das NIR spektrale Band an den Tagen 92 und 79 nach Aussaat, das grüne spektrale Band an Tag 50 und das blaue

spektrale Band an den Tagen 92 und 81 nach Aussaat sind. Sie beweisen damit, dass es möglich ist, die Ernte auf Grundlage von Luftbildern und Machine Learning vorherzusagen [14].

#### *SCHUTZ VOR KRANKHEITEN*

Pestizide sind in der Landwirtschaft notwendig, um die Pflanzen beispielweise vor Insekten oder Pilzen zu schützen. Jedoch sind sie auch für Tiere und Menschen giftig, weswegen sie nicht grundlos verwendet werden sollten.

Die Firma Blue River Technology entwickelt ein Verfahren, welches erkennt, ob eine Pflanze erwünscht oder nicht erwünscht ist. Nur auf die nicht erwünschten wird dann ein Pestizid gesprüht. Dadurch kann die Nutzung von Pestiziden um mehr als 2/3 reduziert werden, da nicht mehr das ganze Feld behandelt wird. Damit das Verfahren funktioniert, fährt ein Traktor mit einem Ausleger über das Feld. Daran sind in regelmäßigen Abständen Kameras und Pestizidsprayer befestigt. Die Kameras erfassen die Pflanzen vor sich und analysieren mithilfe von Machine Learning, um was für eine Pflanze es sich handelt. Je nach Ergebnis wird für den Bereich das Pestizid versprüht oder nicht. Die Entscheidung dafür wird in dem Bruchteil einer Sekunde getroffen [15].

Neben der Erkennung von nicht erwünschten Pflanzen, ist auch die Erkennung von Insekten wichtig. Traditionelle Methoden zur Erkennung von befallenen Pflanzen sind langsam und wenig effizient. Dies kann mit Hilfe von Convolutional Networks zur Objekterkennung verbessert werden. Durch eine konstante Überwachung ist es möglich, Krankheiten der Pflanzen früher als üblich zu erkennen und so schnell einzudämmen. Die Künstliche Intelligenz basiert auf dem Model YOLOv5. Dabei handelt es sich um ein Convolutional Network zur Objekterkennung. Sie extrahieren in einem ersten Schritt sogenannte Features aus Bildern. Dazu werden Faltungen mit gelernten Kernel auf das Bild angewendet. Außerdem wird mit dem sogenannten Pooling die Bildgröße verändert, wodurch Merkmale in unterschiedlichen Frequenzbereichen extrahiert werden können. Im Anschluss werden die so

gefundenen Features der unterschiedlichen Bildgrößen zusammengefügt. Im letzten Schritt erfolgt dann die Klassifizierung der Features und die Berechnung der Bounding Box, die angibt, wo sie ein gefundenes Objekt im Bild befindet. Im Falle der Erkennung von Insekten, die Pflanzen befallen haben, wird das Netzwerk mit einem Datensatz an gelabelten Bildern, auf denen verschiedene Tiere zu sehen sind, trainiert. Einige Bilder, die dazu verwendet wurden, sind in Abbildung 2 dargestellt [16].



Abbildung 2: Bilder von mit Insekten befallenen Pflanzen. Quelle: [15]

### ERNTEROBOTER

Künstliche Intelligenz kann auch die Ernte von Obst oder Gemüse unterstützen und beschleunigen. Die Firma ARCO entwickelt dazu einen Apfelernteroboter. Der Roboter befindet sich auf einem Anhänger, der von einem Traktor durch die Apfelplantage gezogen wird. Damit der Greifer die Äpfel zielgenau ohne Schaden anzurichten pflücken kann, muss er Äpfel an ihrer Form erkennen und ihre Position im Raum berechnen können. Um dies zu ermöglichen, ist in die Mitte des Greifers, welcher zum Pflücken ein Vakuum aufbaut, eine Kamera eingebaut. Zur eigentlichen Ernte wird der Baum von einem Zelt umhüllt, um konstante Lichtbedingungen zu gewährleisten. Im Anschluss werden aus 40 Perspektiven Fotos von dem Baum aufgenommen. Auf diese Bilder wird eine Segmentierung ausgeführt, die angibt, welcher Teil des Bildes zu einem Apfel gehört und welcher zum Hintergrund. Dies erfolgt durch das Training eines Machine Learning Algorithmus auf die Farbe von Äpfeln. In Abbildung 3 ist das Ergebnis einer Segmentierung dargestellt, die gefunden Äpfel wurden hier rot eingefärbt.



Abbildung 3: Segmentierung von Äpfeln in einem Bild. Die erkannten Äpfel wurden rot eingefärbt. Quelle: [17]

Mithilfe von zwei aufgenommenen Bildern von ein und demselben Apfel kann über Triangulation die Distanz zum Apfel berechnet werden. Der Greifer des Roboters kann dann in Position gefahren werden. Bis kurz vor dem Apfel wird Luft aus dem Greifer geblasen, um umliegende Blätter zur Seite zu schieben. Am Apfel angekommen, wird ein Vakuum erzeugt und der Apfel so geerntet. Die Ernte eines Apfels dauert mit diesem Verfahren etwa 8-10sec. Es ist davon auszugehen, dass diese Zeit noch verkürzt werden kann. Darüber hinaus werden etwa 85% aller Äpfel geerntet, was der Rate einer händischen Ernte entspricht [17].

### POST-HARVEST HANDLING

Bei Post Harvest Handling geht es um das, was mit dem Gemüse, Obst oder Getreide nach der Ernte passiert. Hierunter fallen beispielweise die Kontrolle der Lagerungen von geerntetem Gemüse. Muss dieses kühl und trocken gelagert werden, so können Sensoren die Feuchtigkeit und Temperatur im Lager erfassen. Algorithmen können dann vorhersagen, wann bestimmte Parameter überstiegen werden, wodurch es zu einem beschleunigten Verderben der Lebensmittel kommen würde. Bevor es dazu kommt, kann der Lagerbetreiber gewarnt werden [18].

Auch die Klassifizierung von Früchten, sowie die Erkennung des Reifegrades sind Anwendungsfälle im Post-Harvest Handling. Ausgeführt durch den Menschen nehmen diese Arbeiten viel Zeit in Anspruch. Allein die Analyse der Farbe der Frucht reicht nicht immer aus, um den Reifegrad zu bestimmen. Beispielsweise Wassermelonen verändern nicht



ihre Farbe. Stattdessen kann ein Netzwerkanalysator verwendet werden. Dieser misst Streuparameter. Die Parameter beschreiben das Verhältnis zwischen Eingang und Ausgang in einem elektrischen System, also wie viel von einem Signal reflektiert und transmittiert wird. Dazu wird die betreffende Frucht in den Netzwerkanalysator gelegt und die Streuparameter gemessen. Um Rauschen zu verhindern wird zusätzlich gemessen, wie sich die Streuparameter ohne eine Frucht verhalten. Evaluiert werden die so gewonnenen Daten zum einen mit K Nearest Neighbour (KNN) und zum anderen mit einem Neural Network. Ein KNN benötigt kein Training, sondern vergleicht ein Eingabebild mit den Bildern im Datensatz. Die Ausgabe des KNNs ist das Label, der Bilder, die am nächsten am Eingabebild liegen. Wobei  $k$ , der Anzahl der am nächsten liegenden Bildern entspricht. Dieses Verfahren funktioniert besser für die Erkennung des Reifegrades, während das Neuronale Netzwerk besser auf der Klassifizierung der Frucht performt [19].

## RISIKEN

Im Laufe der Vorstellung von verschiedenen Anwendungen sind bereits die Vorteile von KI in der Landwirtschaft klar geworden. Es ermöglicht eine Verbesserung des Ertrages durch eine bestmögliche Ressourcennutzung. Tzachor et al. sehen aber auch Gefahren in verschiedenen Bereichen. Zum einen geht es dabei, um die gewonnenen Daten, die zum Lernen für die Algorithmen verwendet werden. Hier liegt häufig ein Fokus auf Weizen, Reis und Mais. Insbesondere in ärmeren Regionen sind aber andere Getreidesorten, wie Quinoa, von größerer Bedeutung. Ebenfalls sind Techniken von indigenen Landwirten unterrepräsentiert, obwohl diese in ihren Gebieten häufig einen großen Beitrag zur Food Security leisten. Die Autoren befürchten, dass wenn kleinere oder indigene Betriebe Machine Learning Algorithmen verwenden, die Ernährungssicherheit sinkt, da die Algorithmen sich nicht auf alternative Getreidesorten adaptieren lassen oder diese Sorten weniger angebaut werden. Desweiteren sind die Daten häufig nicht interpretierbar oder nutzbar für andere Projekte, da Informationen über die

Bodenbeschaffenheit oder die Art der Düngung fehlen [20].

Eine zweite Gefahr sehen sie darin, dass in den letzten Jahrzehnten die Steigerung der Ernte zu einem Verlust der Biodiversität, sowie mehr Verschmutzung geführt haben. Im Falle von dem Einsatz von Künstlicher Intelligenz, bedeutet das, dass, auch kleine Fehler in den Algorithmen großen Schaden anrichten können, zum Beispiel durch eine fehlerhafte, exzessive Düngung, die das Mikrobiom des Bodens zerstört und so zu einer schlechteren Ernte führt [20].

Desweiteren besteht für kleinere Farmen häufig kein Zugang zu den Machine Learning Verfahren, sei es aufgrund von Finanzierung oder schlechten Internetempfangs. Die Lücke zwischen großen, kommerziellen Farmen und kleineren Betrieben, wird so immer größer. Dadurch sind kleinere Betriebe zur Aufgabe gezwungen [20].

Ebenfalls nicht zu vernachlässigen ist die Gefahr durch Cyberangriffe. Angriffe auf Systeme beispielsweise bei der Lagerüberwachung oder der Fütterung von Tieren können weitreichende Folgen haben [20]. Um möglichst sichere Verfahren zu entwickeln, sollten daher mehr Tests in sicheren Sandboxes stattfinden.

## FAZIT

Eine Steigerung der Produktivität in der Landwirtschaft wird in Zukunft unumgänglich sein. Mit einer wachsenden Weltbevölkerung wächst auch der Bedarf an Nahrungsmitteln. Die Anwendung von Künstlicher Intelligenz bietet großes Potential, um die Landwirtschaft effizienter und produktiver zu gestalten. Insbesondere aufgrund der Vielzahl an Parametern, die sich auf die Ernte von Gemüse, Obst oder Getreide auswirken, bieten sich Machine Learning Algorithmen an, um hier Zusammenhänge zu erkennen.

Bei allen positiven Seiten sollte die Ausbreitung von KI basierten Methoden, aber die Fehler vorheriger Modernisierungen nicht wiederholen. Dazu gehört eine vergrößerte Ungleichheit zwischen kleinen und großen landwirtschaftlichen Betrieben, sowie negative Umweltfolgen.

## Referenzen

- [1] U. CLAAS Gruppe, "Künstliche Intelligenz in der Landwirtschaft: CLAAS E-Systems Projektpartner bei Agri-Gaia und resKIL," [Online]. Available: <https://www.claas.de/aktuell/meldungen-veranstaltungen/meldungen/kuenstliche-intelligenz-in-der-landwirtschaft--claas-e-systems-projektpartner-bei-agri-gaia-und-reskil/2492674>. [Accessed 26 12 2022].
- [2] "Precision Ag Definition," International Society of Precision Agriculture, Januar 2021. [Online]. Available: <https://www.ispag.org/about/definition>. [Accessed 13 01 2023].
- [3] W. Zhao, W. Yamada, T. Li, M. Digman and T. Runge, "Augmenting Crop Detection for Precision Agriculture with Deep Visual Transfer Learning - A Case Study of Bale Detection," *Remote Sens*, 2021.
- [4] R. Iriondo, "Machine Learning (ML) vs. Artificial Intelligence (AI)—Crucial Differences," towardsai, 15 10 2018. [Online]. Available: <https://towardsai.net/p/machine-learning/differences-between-ai-and-machine-learning-1255b182fc6>. [Accessed 07 01 2023].
- [5] E. Kavlakoglu, "AI vs. Machine Learning vs. Deep Learning vs. Neural Networks: What's the Difference?," IBM, 27 05 2020. [Online]. Available: <https://www.ibm.com/cloud/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks>. [Accessed 07 01 2023].
- [6] S. H. Han, K. W. Kim, S. Kim and Y. C. Youn, "Artificial Neural Network: Understanding the Basic Concepts without Mathematics," *Dement Neurocogn Disord*, vol. 17, no. 3, pp. 83-89, 09 2018.
- [7] V. Zhou, "Machine Learning for Beginners: An Introduction to Neural Networks," victorzhou, 03 03 2019. [Online]. Available: <https://victorzhou.com/blog/intro-to-neural-networks/>. [Accessed 08 01 2023].
- [8] R. Schrijver, "Präzisionslandwirtschaft und die Zukunft der Landwirtschaft in Europa," STOA, Brüssel, 2016.
- [9] R. Lardy, Q. Ruin and I. Veissier, "Discriminating pathological, reproductive or stress conditions in cows using machine learning on sensor-based activity data," *Computers and Electronics in Agriculture*, vol. 204, 2023.
- [10] S. Kang, X. Hao, T. Du, L. Tong, X. Su, H. Lu, X. Li, Z. Huo, S. Li and R. Ding, "Improving agricultural water productivity to ensure food security in China under changing environment: From research to practice," *Agricultural Water Management*, vol. 179, pp. 5-17, 2017.
- [11] S. Choudhary, V. Gaurav, A. Singh and S. Agarwal, "Autonomous Crop Irrigation System using Artificial Intelligence," *International Journal of Engineering and Advanced Technology*, vol. 8, no. 5S, Mai 2019.
- [12] A. Tschand, "Semi-supervised machine learning analysis of crop color for autonomous irrigation," *Smart Agricultural Technology*, vol. 3, 2023.
- [13] "Rekurrentes neuronales Netz," Wikipedia, [Online]. Available: [https://de.wikipedia.org/wiki/Rekurrentes\\_neuronales\\_Netz](https://de.wikipedia.org/wiki/Rekurrentes_neuronales_Netz). [Accessed 21 01 2023].
- [14] M. C. F. Wei, L. F. Maldaner, P. M. N. Ottoni and J. P. Molin, "Carrot Yield Mapping: A Precision Agriculture

- Approach Based on Machine Learning," *AI 2020*, vol. 1, pp. 229-241, 2020.
- [15] T. Doran, "See and Spray: Technology targets weeds only," *AGRINEWS*, 10 November 2022. [Online]. Available: <https://www.agrinews-pubs.com/news/farm-equipment/2022/11/11/see-and-spray-technology-targets-weeds-only/>. [Accessed 21 01 2023].
- [16] M. Dai, M. M. H. Dorjoy, H. Miao and S. Zhang, "A New Pest Detection Method Based on Improved YOLOv5m," *Insects*, vol. 14, no. 54, 2023.
- [17] L. Kreuzer, "Die vollautomatische Obsterntemaschine," *MVTec*, [Online]. Available: <https://www.mvtec.com/de/anwendungsbereiche/success-stories/die-vollautomatische-obsterntemaschine>. [Accessed 14 01 2023].
- [18] C. K. M. Chakshu, "Post-harvest crop management system using IoT and AI," *International Journal of Advance Research and Development*, vol. 4, no. 5, 2019.
- [19] V. L. Tran, T. N. C. Doan, F. Ferrero, T. L. Huy and N. Le-Thanh, "The Novel Combination of Nano Vector Network Analyzer and Machine Learning for Fruit Identification and Ripeness Grading," *Sensors*, vol. 23, no. 2, 2023.
- [20] A. Tzachor, M. Devare, B. King, S. Avin and S. Ó hÉigeartaigh, "Responsible artificial intelligence in agriculture requires systemic understanding of risks and externalities," *Nature Machine Intelligence*, vol. 4, pp. 104-109, 2022.
- [21] "Künstliche Intelligenz (KI) und maschinelles Lernen," [Online]. Available: <https://www.iks.fraunhofer.de/de/themen/kuenstliche-intelligenz.html>.
- [22] A. S. Paymode and V. B. Malode, "Transfer Learning for Multi-Crop Leaf Disease Image Classification using Convolutional Neural Network VGG," vol. 6, pp. 23-33, 2022.
- [23] T. Talaviya, D. J. Shah, N. Patel, H. Yagnik and M. Shah, "Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides," *Artificial Intelligence in Agriculture*, 2020.
- [24] S. Ahmad, A. Kalra and H. Stephen, "Estimating soil moisture using remote sensing data: A machine learning approach," *Advances in Water Resource*, vol. 33, pp. 69-80, 2010.
- [25] X. Ge, J. Ding, X. Jin, J. Wang, X. Chen, X. Li, J. Liu and B. Xie, "Estimating Agricultural Soil Moisture Content through UAV-Based Hyperspectral Images in the Arid Region," *Remote Sensing*, vol. 13, no. 8, 2021.
- [26] T. Thorat, B. K. Patle and S. K. Kashyap, "Intelligent insecticide and fertilizer recommendation system based on TPF-CNN for smart farming," *Smart Agricultural Technology*, vol. 3, 2023.