

Entwicklung eines automatischen Monitoringsystems für die Geburtsüberwachung bei Sauen

Martin Wutke^{1,2}, Clara Lensches¹, Jan-Hendrik Witte³, Johann Gerberding³, Marc-Alexander Lieboldt⁴ und Imke Traulsen¹

Abstract: Die Überwachung des Abferkelungsverlaufs ist in der Schweinehaltung von großer Bedeutung, um auftretende Geburtsstörungen frühzeitig erkennen und geeignete Maßnahmen ergreifen zu können. Da eine zeitnahe Geburtserkennung und -betreuung aufgrund intensivierter Haltungsbedingungen oftmals nur schwer zu erzielen ist, war das Ziel der vorliegenden Studie, die Eignung neuronaler Netzwerke zur automatischen Identifikation des Geburtsmomentes zu untersuchen. Anhand einer YoloV5-Netzwerkarchitektur bestimmten wir auf Basis der Detektion unterschiedlicher Körperteile der Muttersau den potentiellen Geburtsbereich innerhalb der Abferkelbucht und identifizierten den Moment der Geburt des ersten Ferkels anhand der Objektdetektion des Ferkels innerhalb des Zielbereichs. Wir validierten unser Analysemodell durch zweistufigen Ansatz und erreichten einen Precision-, Recall- und MAP-Wert von 0.982, 0.989 und 0.993 im Rahmen der Objektdetektion sowie einen Accuracy-, Recall- und Precision-Wert von 0.9, 0.8 und 1 bei der Bestimmung des Geburtszeitpunktes.

Keywords: Geburtsüberwachung, maschinelles Lernen, Deep Learning, Videoanalyse

1 Einleitung

In der Ferkelerzeugung sind eine hohe Anzahl lebend geborener Ferkel je Sau und Jahr, geringe Aufzuchtverluste sowie das Hervorbringen gesunder, uniformer und marktkonformer Ferkel essentiell für den wirtschaftlichen Erfolg eines ferkelerzeugenden Betriebes [HGK16]. In den vergangenen Jahren hat sich die Anzahl der gesamt geborenen Ferkel je Sau und Wurf stark erhöht, wobei gleichzeitig ein gesteigertes Auftreten von Totgeburten und frühen postnatalen Verlusten beobachtet werden konnte [Le03]. Diesbezüglich hat der geburtsnahe Zeitraum große Auswirkungen auf die Überlebensfähigkeit neugeborener Ferkel [vv04], wobei als eine der häufigsten Ursachen für Geburtsstörungen und Ferkelverluste die perinatale Asphyxie bei der Geburt anzuführen ist [Ed02]. Eine Asphyxie während des Geburtsvorgangs kann entweder direkt zu einer Totgeburt oder zu Ferkeln mit herabgesetzter Vitalität und geringerer Anpassungsfähigkeit an das extrauterine Leben führen [He96]. Als wesentliche Risikofaktoren für das Auftreten perinataler Asphyxie gelten hierbei vor allem in der Wurfreihenfolge später geborene Ferkel, die Wurfgröße und die Dauer der

¹ Georg-August-Universität Göttingen, Systeme der Nutztierhaltung, Albrecht-Thaer-Weg 3, 37075 Göttingen, martin.wutke@uni-goettingen.de, clara.lensches@uni-goettingen.de, imke.traulsen@uni-goettingen.de

² Fachhochschule Südwestfalen, Statistik und Data Science in der Agrarwirtschaft, Lübecker Ring 2, 59494 Soest, wutke.martin@fh-swf.de

³ Carl von Ossietzky Universität Oldenburg, Department für Informatik, Ammerländer Heerstr. 114-118, 26129 Oldenburg, jan-hendrik.witte@uni-oldenburg.de, johann.gerberding@uni-oldenburg.de

⁴ Landwirtschaftskammer Niedersachsen, Geschäftsbereich Landwirtschaft, FB 3.7, Mars-la-Tour-Straße 6, 26121 Oldenburg, marc-alexander.lieboldt@lwk-niedersachsen.de

Abferkelung, sowie verlängerte Geburtsintervalle zwischen der Geburt aufeinanderfolgender Ferkel [He96; va05]. Aus diesen Gründen kommt der Überwachung der Geburtsverläufe eine hohe Bedeutung zu und ist essentiell, um frühzeitig geeignete Maßnahmen bei der Erkennung von Geburts- und Gesundheitsstörungen ergreifen zu können. In diesem Zusammenhang zeigen die jüngsten Fortschritte im Bereich des maschinellen Lernens das Potential überwachter Lernalgorithmen bei der Erkennung von Problemsituationen und der automatisierten Auswertung großer, unstrukturierter Datenmengen [Ga20; Ki21; Wu21]. Insbesondere im perinatalen Zeitraum können Systeme des Precision Livestock Farmings eine Unterstützung von LandwirtInnen und MitarbeiterInnen ferkelerzeugender Betriebe im Hinblick auf das Vermeiden von Ferkelverlusten leisten [Oc16]. Zwar fanden ML-Algorithmen im Rahmen des Geburtsmonitorings bereits in früheren Studien Anwendung, allerdings fokussierten sich diese Arbeiten entweder auf die Untersuchung von Verhaltensmerkmalen der Sau vor der Geburt [Kü20] oder auf die Analyse der Ferkelvitalität [HTK21]. Ziel der vorliegenden Studie war die Entwicklung und Bewertung eines solchen Unterstützungssystems zur automatisierten Geburtsüberwachung und Erkennung von Problemsituationen. Hierfür analysierten wir Videoaufnahmen von 52 Abferkelungen und trainierten ein convolutional neural network (CNN) zur Objektdetektion, um das Tierverhalten innerhalb der Abferkelbucht kontinuierlich überwachen zu können und den Zeitpunkt des Geburtsbeginns automatisiert zu identifizieren und zu dokumentieren.

2 Material und Methoden

Die Videodaten wurden im Rahmen des Verbundprojektes „Experimentierfeld DigiSchwein“ (Förderkennzeichen: 28DE109F18) im Zeitraum von Mai 2021 bis Oktober 2022 erhoben [Li21]. Hierfür wurden RGB-Kameras vom Typ Axis 3206LVE 3 m senkrecht über Einzelabferkelbuchten installiert, welche die stattfindenden Geburtsvorgänge mit einer Auflösung von 1920 x 1080 Pixeln sowie einer Rate von 20 Bildern pro Sekunde aufzeichneten. Für das Modelltraining wurden 750 Einzelbilder vor und nach der Geburt des ersten Ferkels zufällig ausgewählt und manuell annotiert. Für die Bildannotation wurden vier Objektklassen definiert (Kopfreion, Hinterteilregion, Schwanz, neugeborene Ferkel) und mittels eines Bounding-Box-Ansatzes markiert. Um den Informationsgehalt in den Daten im Rahmen des Modelltrainings zu erhöhen, wurde jedes Bild durch Verwendung einer horizontalen Drehung, einer vertikaler Drehung und einer zufälligen Rotation augmentiert, wodurch sich der Gesamtdatensatz auf 3000 Bilder erhöhte.



Abb. 1: Die in Graustufenbilder umgewandelten Videoframes zeigen die Abferkelbucht bei Tageslicht (A) und bei Nacht (B)

Abschließend wurden die annotierten Einzelbilder in einen unabhängigen Trainings- und Testdatensatz unterteilt, wobei wir dem Vorgehen früherer Studien folgten [Kc21; SM18; Th19] und 90 Prozent der Daten für das Modelltraining und 10 Prozent der Daten für die Modellevaluation nutzten. Die Abferkelbuchten sowie die annotierten Objektklassen sind beispielhaft für zwei Videoframes in Abbildung 1 dargestellt.

2.1 Modellimplementierung

Das vorgestellte Analyseframework folgt einem zweistufigen Ansatz, bei dem zunächst die annotierten Körperteilpositionen geschätzt werden. Basierend auf diesen Körperteilinformationen wird in einem nachgelagerten Schritt die Orientierung der Sau in der Bucht sowie der Geburtsbereich nahe dem Hinterteil als Zielregion bestimmt. Über die Detektion konsistenter Ferkelpositionen innerhalb des Zielbereichs und der entsprechenden Videoframenummer wird darauf aufbauend der Zeitpunkt des Geburtsbeginns identifiziert und als Information zur weiteren Verarbeitung abgelegt. Die Einführung der Zielregion hat sich als empirisch vorteilhaft erwiesen, da Ferkeldetektion in angrenzenden Buchten und falsch-positive Klassifikationen im Rahmen des Detektionsprozesses frühzeitig identifiziert und von der weiteren Analyse ausgeschlossen werden können. Zur Detektion der Körperteil- und Ferkelpositionen folgten wir dem Vorgehen früherer Studien [INK21; Ya21] und verwendeten ein CNN mit einer YoloV5-Architektur [Jo20]. Während des iterativen Trainingsprozesses wurde das CNN über 100 Iterationen darauf trainiert, für jedes Eingangsbild die Objektpositionen in Form der Bounding-Box-Koordinaten, des Boxmittelpunkts und der zugehörigen Klasseninformation zu generieren. Nach dem Modelltraining kann das trainierte CNN dazu verwendet werden, die Objektklasse und Position für bisher unbekannte Bilder zu schätzen.

3 Ergebnisse und Diskussion

Zur Eignungsbeurteilung des vorgestellten Ansatzes zur Geburtsüberwachung und Bestimmung des Geburtszeitpunktes haben wir unser Analyseframework in zwei Stufen evaluiert. Die erste Evaluationsstufe zielt darauf ab, die Leistung des Detektionsmodells zur Bestimmung der Körperteilpositionen zu bewerten. Hierfür wurden die 300 manuell annotierten Bilder des Testdatensatzes verwendet und die Precision, Recall und Mean Average Precision (MAP) Metrik berechnet. Die Ergebnisse der ersten Evaluationsstufe sind nachfolgend in Tabelle 1 aufgeführt.

Objektklasse	Häufigkeit	Precision	Recall	MAP
Kopf	300	0,997	0,998	0,995
Hinterteil	300	0,988	0,993	0,992
Ferkel	151	0,968	0,99	0,995
Schwanz	176	0,977	0,974	0,99
Alle	927	0,982	0,989	0,993

Tab. 1: Evaluationsergebnisse des Detektionsmodells für den Testdatensatz

Wie in Tabelle 1 zu erkennen ist, zeigt das Detektionsnetzwerk für alle Objektklassen durchgehend Leistungswerte im hohen 90er-Bereich auf. Vor allem die Objektklassen Kopf

und Hinterteil mit einem Recall-Wert von 0,998 und 0,993 verdeutlichen, dass in Situationen, in denen diese Objektklassen zu erkennen waren, das CNN diese korrekt lokalisiert und klassifiziert hat. Die geringste Detektionsgüte wurde bei den Klassen Ferkel und Schwanz erzielt, was durch die Verteilungshäufigkeit im Trainingsdatensatz erklärt werden kann. Im Unterschied zu den Objektklassen Kopf und Hinterteil, welche in jedem Videobild vorhanden waren, waren die Klassen Ferkel und Schwanz nicht in jedem Bild sichtbar und somit im Datensatz unterrepräsentiert.

Für die zweite Evaluationsstufe überprüften wir, ob die vorgestellte Methodik einerseits in der Lage ist, den Moment der Geburt des ersten Ferkels verlässlich zu bestimmen und andererseits in Phasen ohne Geburtsaktivitäten keine Falschmeldung zu generieren. Für diesen zweiten Evaluationsschritt wurden insgesamt 20 zehnminütige Videosequenzen mit und ohne Geburtsvorgang unterschiedlicher Sauen ausgewählt. Zur Validierung wurde jedes Video durch einen Experten manuell gesichtet, welcher binär klassifizierte, ob eine Geburt im betrachteten Zeitraum stattfand. Darüber hinaus wurde der Geburtszeitpunkt sowie die zeitliche Abweichung des automatisch identifizierten Geburtszeitpunktes vom manuell bewerteten Zeitpunkt bestimmt. Zur Beurteilung der binären Klassifikation folgten wir dem Vorgehen früherer Studien [De19; Mo19] und bestimmten die richtig-positiv-Rate (TP), die falsch-positiv-Rate (FP), die richtig-negativ-Rate (TN) und die falsch-negativ-Rate (FN) und berechneten die Accuracy-, Recall- und Precision-Werte. Die Ergebnisse der zweiten Evaluationsstufe sind in Tabelle 2 aufgeführt.

Datensatz	Anzahl Videos	Geburten erkannt	Abweichung (in Sek.)	Accuracy	Recall	Precision
Mit Geburt	10	8	11,5	-	-	-
Ohne Geburt	10	0	-	-	-	-
Alle	20	8	11,5	0,9	0,8	1

Tab. 2: Evaluationsergebnisse für die zweite Evaluationsstufe zur Erkennung des Geburtszeitpunktes

Das vorgestellte Analyseframework zeigt sowohl bei der Identifizierung als auch bei der Überwachung von Phasen ohne Geburtseignisse gute Ergebnisse. Von den zehn ausgewählten Videosequenzen mit Geburtsverlauf konnte der Zeitpunkt der ersten Ferkelgeburt in acht Fällen korrekt bestimmt werden, wobei die automatische Bestimmung im Durchschnitt 11,5 Sekunden später erfolgte als der von einem menschlichen Beobachter ermittelte Zeitpunkt. In zwei Videosequenzen wurde der Blick auf das neugeborene Ferkel durch den Ferkelschutzkorb und die Muttersau verdeckt und war auch für den geschulten Beobachter nur bedingt als Geburt erkennbar. Das Problem verdeckter Ferkel kann in diesem Zusammenhang als limitierender Faktor für den kontinuierlichen Praxiseinsatz eingestuft werden, welcher bei längeren Phasen der Verdeckung die Modellleistung wesentlich beeinflussen kann. Zur Adressierung dieser Limitation könnten Vorhersagemodelle aus dem Bereich des Objekttrackings eingesetzt werden, welche über die Schätzung zukünftiger Objektpositionen den Einfluss von falsch negativen Detektionen reduzieren könnten [Cu22]. Darüber hinaus untersuchten frühere Studien wie Küster et al. [Kü20] Veränderungen im Verhaltensbild der Sau, um beispielsweise verstärktes Nestbauverhalten zu identifizieren. In Problemsituationen und zur Erhöhung der Robustheit des vorgestellten Ansatzes zur

Bestimmung des Geburtszeitpunktes könnten solche Verhaltensmerkmale als zusätzliche Informationsquelle eingesetzt werden und somit den Mehrwert der vorgestellten Methodik steigern. In der Gruppe ohne Geburtsergebnisse lieferte die vorgestellte Methodik konsistente Ergebnisse ohne Fehlklassifikationen.

4 Zusammenfassung und Ausblick

Die zunehmende Intensivierung der Schweinehaltung führt im Bereich der Abferkelung einerseits zu einer hohen personellen und zeitlichen Inanspruchnahme von LandwirtInnen und stellt andererseits einen wesentlichen Zeitpunkt zur Sicherstellung des Tierwohls dar. Ziel dieser Studie war es deshalb, die Eignung moderner maschineller Lernmethoden aus dem Bereich der neuronalen Netzwerke zur Überwachung des Geburtsprozesses eingehender zu analysieren. Durch die Detektion unterschiedlicher Körperregionen und neugeborener Ferkel konnte die Orientierung der Muttersau in der Abferkelbucht sowie ein potentieller Geburtsbereich bestimmt werden, in dem bei wiederholter Erkennung neuer Ferkel abschließend der Geburtszeitpunkt bestimmt werden kann. Durch diesen automatisierten Prozessschritt ist es möglich, eine zeitnahe Erstkontrolle der Ferkel durchzuführen und bei Auftreten von Geburtsstörungen geeignete Maßnahmen einzuleiten. Darauf aufbauend soll das vorgestellte Geburtsüberwachungssystem im Rahmen zukünftiger Arbeiten durch Einbeziehen der individuellen Geburtsintervalle, einer Unterscheidung zwischen lebend und tot geborenen Ferkeln sowie einer Ausweitung des Analyserahmens auf unterschiedliche Buchtensysteme ergänzt werden.

Literaturverzeichnis

- [As21] Ashhar, S. M. et al.: Comparison of deep learning convolutional neural network (CNN) architectures for CT lung cancer classification. *International Journal of Advanced Technology and Engineering Exploration* 74/8, S. 126-134, 2021.
- [Cu22] Cui, Y. et al.: Remote Sensing Object Tracking With Deep Reinforcement Learning Under Occlusion. *IEEE Transactions on Geoscience and Remote Sensing* 60, S. 1-13, 2022.
- [De19] Debelee, T. G. et al.: Classification of Mammograms Using Texture and CNN Based Extracted Features. *Journal of Biomimetics, Biomaterials and Biomedical Engineering* 42, S. 79-97, 2019.
- [Ed02] Edwards, S.: Perinatal mortality in the pig: environmental or physiological solutions? *Livestock Production Science* 1/78, S. 3-12, 2002.
- [Ga20] García, R. et al.: A systematic literature review on the use of machine learning in precision livestock farming. *Computers and Electronics in Agriculture* 179, S. 105826, 2020.
- [He96] Herpin, P. et al.: Effects of the level of asphyxia during delivery on viability at birth and early postnatal vitality of newborn pigs. *Journal of animal science* 9/74, S. 2067-2075, 1996.
- [HGK16] Hoy, S.; Gauly, M.; Krieter, J.: *Nutztierhaltung und -hygiene*. Verlag Eugen Ulmer, Stuttgart, 2016.
- [HTK21] Ho, K.-Y.; Tsai, Y.-J.; Kuo, Y.-F.: Automatic monitoring of lactation frequency of sows and movement quantification of newborn piglets in farrowing houses using convolutional neural networks. *Computers and Electronics in Agriculture* 189, S. 106376, 2021.

- [INK21] Islam, M. M.; Newaz, A. A. R.; Karimodini, A.: A Pedestrian Detection and Tracking Framework for Autonomous Cars: Efficient Fusion of Camera and LiDAR Data: 2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC). IEEE, S. 1287-1292, 2021.
- [Jo20] Jocher, G. et al.: yolov5. Code repository, 2020.
- [Kc21] Kc, K. et al.: Evaluation of deep learning-based approaches for COVID-19 classification based on chest X-ray images. *Signal, image and video processing* 5/15, S. 959-966, 2021.
- [Ki21] Kim, M.-J. et al.: Research and Technology Trend Analysis by Big Data-Based Smart Livestock Technology: a Review. *Journal of Biosystems Engineering* 4/46, S. 386-398, 2021.
- [Kü20] Küster, S. et al.: Usage of computer vision analysis for automatic detection of activity changes in sows during final gestation. *Computers and Electronics in Agriculture* 169, S. 105177, 2020.
- [Le03] Leenhouders, J. I. et al.: Stillbirth in the pig in relation to genetic merit for farrowing survival. *Journal of animal science* 10/81, S. 2419-2424, 2003.
- [Li21] Lieboldt, M.-A. et al.: Experimentierfeld DigiSchwein. In (Meyer-Aurich, A., et al., Hrsg.): 41. GIL-Jahrestagung, Informations- und Kommunikationstechnologie in kritischen Zeiten. *Lecture Notes in Informatics (LNI)-Proceedings, Volume 309, Gesellschaft für Informatik, Bonn*, S. 391-396, 2021.
- [Mo19] Mobeen-ur-Rehman et al.: Classification of Diabetic Retinopathy Images Based on Customised CNN Architecture: 2019 Amity International Conference on Artificial Intelligence (AICAI). IEEE, S. 244-248, 2019.
- [Oc16] Oczak, M. et al.: Automatic estimation of number of piglets in a pen during farrowing, using image analysis. *Biosystems Engineering* 151, S. 81-89, 2016.
- [SM18] Shallu; Mehra, R.: Breast cancer histology images classification: Training from scratch or transfer learning? *ICT Express* 4/4, S. 247-254, 2018.
- [Th19] Thian, Y. L. et al.: Convolutional Neural Networks for Automated Fracture Detection and Localization on Wrist Radiographs. *Radiology. Artificial intelligence* 1/1, e180001, 2019.
- [va05] van Dijk, A. J. et al.: Factors affecting duration of the expulsive stage of parturition and piglet birth intervals in sows with uncomplicated, spontaneous farrowings. *Theriogenology* 7/64, S. 1573-1590, 2005.
- [vv04] van Rens, B. T. T. M.; van der Lende, T.: Parturition in gilts: duration of farrowing, birth intervals and placenta expulsion in relation to maternal, piglet and placental traits. *Theriogenology* 1-2/62, S. 331-352, 2004.
- [Wu21] Wutke, M. et al.: Detecting Animal Contacts-A Deep Learning-Based Pig Detection and Tracking Approach for the Quantification of Social Contacts. *Sensors (Basel, Switzerland)* 22/21, 2021.
- [Ya21] Yap, M. H. et al.: Deep learning in diabetic foot ulcers detection: A comprehensive evaluation. *Computers in biology and medicine* 135, S. 104596, 2021.
- [YLM22] Yang, N.; Li, Y.; Ma, R.: An Efficient Method for Detecting Asphalt Pavement Cracks and Sealed Cracks Based on a Deep Data-Driven Model. *Applied Sciences* 19/12, S. 10089, 2022.