

# Früherkennung von Schwanzbeißen bei Schweinen auf der Basis von Deep Learning

## Entwicklungskonzept eines praxistauglichen Frühwarnsystems

Peter Wißkirchen<sup>1</sup>, Friederike K. Warns<sup>2</sup>, Katharina Dahlhoff<sup>2</sup>, Carina Goretzky<sup>1</sup>,  
Timo Brune<sup>1</sup>, Fouad Bitti<sup>1</sup>, Harald Mathis<sup>1</sup> und Astrid van Asten<sup>2</sup>

**Abstract:** Schwanzbeißen (Caudophagie) bei Schweinen stellt ein schwerwiegendes und zugleich komplexes Problem in der landwirtschaftlichen Nutztierhaltung dar. Ziel des Projektvorhabens KISS (Künstliche Intelligenz gegen Schwanzbeißen bei Schweinen) ist die Konzeption und prototypische Entwicklung eines Decision Support Systems zur Analyse des Verhaltens einer Schweinegruppe, welches im Sinne eines Frühwarnsystems Hinweise auf verändertes Verhalten gibt. Zur automatischen Analyse bekannter Frühindikatoren dienen Verfahren des Deep Learning, deren Tragfähigkeit auch unter dem Aspekt praktikabler, kostengünstiger Lösung dargestellt wird.

**Keywords:** Schweine, Schwanzbeißen, Deep Learning, Frühwarnsystem, Decision Support System

## 1 Einleitung

In den vergangenen Jahren wurde in wissenschaftlichen Forschungsarbeiten bereits eine Vielzahl von Faktoren beschrieben, die als Ursachen von Schwanzbeißen fungieren können und belegen, dass Schwanzbeißen ein multifaktoriell bedingtes Problem ist [Mo03]. Als mögliche endogene und externe Einflussfaktoren werden die Genetik, der Gesundheitsstatus, das Geschlecht, Alter und Gewicht der Tiere diskutiert, ebenso wie die Gruppengröße, das Absetzalter und -management, die Belegdichte, das Futter, die Fütterungstechnik, die Luftqualität und das Beschäftigungsmaterial [SS01, Ta10, So13].

Zur effektiven Prävention eines Ausbruchs von Schwanzbeißen ist das rechtzeitige Ergreifen von Gegenmaßnahmen entscheidend. Vor diesem Hintergrund wurden in den vergangenen Jahren Änderungen im Verhalten der Schweine zur Früherkennung eines bevorstehenden Schwanzbeißen-Ausbruchs intensiv erforscht. Hier zeigte sich, dass bereits bis zu sieben Tage vor dem Auftreten erster blutiger Schwanzverletzungen eine Änderung im Tierverhalten festzustellen ist [Zo11, We18, LAP19]. Die Ruhezeiten der Tiere

---

<sup>1</sup> Fraunhofer-Anwendungszentrum SYMILA, Paracelsuspark 3, 59063 Hamm,  
peter.wisskirchen@fit.fraunhofer.de; carina.goretzky@fit.fraunhofer.de; timo.brune@fit.fraunhofer.de;  
fouad.bitti@fit.fraunhofer.de; harald.mathis@fit.fraunhofer.de

<sup>2</sup> Landwirtschaftskammer Nordrhein-Westfalen, Versuchs- und Bildungszentrum Landwirtschaft Haus Düsse,  
Haus Düsse 2, 59505 Bad Sassendorf, friederike.warns@lwk.nrw.de; katharina.dahlhoff@lwk.nrw.de;  
astrid.vombrocke@lwk.nrw.de

verkürzen sich bei gleichzeitig ansteigender Aktivität [Zo11, LAP19], die Schweine beschnüffeln und beknabbern vermehrt die Ringelschwänze der Buchtgenossen und der Anteil von hängend oder eingeklemmt getragenen Ringelschwänzen nimmt zu [De18, LAP18, We18].

## 2 Methoden und Material

Unter den Forschungsansätzen zur automatisierten Erkennung dieser Frühzeichen bilden Methoden auf der Basis von Video-Aufzeichnungen einen gewissen Schwerpunkt, da sie anstreben, Bewegungsdynamik und Schwanzhaltung zu erkennen, ohne dass hierfür Markierungen der Schweine oder angeheftete Sensoren erforderlich sind. So ermittelten D'Eath et al. die Schwanzhaltung als Winkel des Schwanzes zum Boden mithilfe von 3D-Kamera-Aufnahmen und einem Algorithmus auf Gruppenebene [De18]. Will man die Schwanzhaltung und das dynamische Verhalten, z. B. Aggressionen und Verfolgungen auf tierindividueller Basis in einer normal besetzten Mastbucht erkennen, so zeigen aktuelle Forschungsergebnisse, dass hierzu Methoden des Deep Learning erfolgversprechend sind. Zur automatisierten Erkennung des Verhaltens von Schweinen mit Hilfe von Deep Learning wird in [Na19, Li20] ein Überblick gegeben. Die darin verfolgten Ansätze unterscheiden sich dadurch, ob statisches Verhalten wie z. B. Sitz- und Liegehaltungen [Na19] oder zeitlich-dynamisches Verhalten wie Rankämpfe und Verfolgungen [Li20] erkannt werden soll.

Die im folgenden dargestellten Resultate und Konzepte gliedern sich in den erwähnten Kontext des Deep-Learning-Ansatzes ein. Grundlage ist hierbei das aus dem Deep-Learning-Bereich bekannte Erkennungsverfahren der Posenschätzung, bei dem in der Regel sehr feingliedrige skelettartige Körperteile und Gelenke erkannt werden. Leitgedanke für die nachfolgend beschriebenen eigenen Aktivitäten ist das Ziel, einen funktionsfähigen Prototyp zu entwickeln, bei dem Einsatzfähigkeit und Kosteneffizienz im Fokus stehen. Die beschriebenen Arbeiten sind Teil des Projektvorhabens KISS (Künstliche Intelligenz gegen Schwanzbeißen bei Schweinen), das aus Mitteln des Zweckvermögens des Bundes bei der Landwirtschaftlichen Rentenbank gefördert wird. Ziel des Projektvorhabens KISS ist die Konzeption und Entwicklung eines Decision Support Systems zur Analyse des Verhaltens einer Schweinegruppe, welches im Sinne eines Frühwarnsystems Hinweise auf verändertes Verhalten in Bezug auf Frühindikatoren von Schwanzbeißen gibt. Mithilfe der Erkennung von Posen aus Echtzeit-2D-Videoaufnahmen analysiert das System das dynamische Verhalten, indem es Position, Bewegungen und Interaktionen auf tierindividueller Basis auswertet. Ergänzend soll die Schwanzhaltung klassifiziert werden. Wichtig ist festzuhalten, dass die Erkennung von Posen sowie der Schwanzhaltung zunächst nur eine, wenn auch wichtige Basis für das Frühwarnsystem darstellt. Das hieraus abgeleitete Verhalten wird im nächsten Schritt aggregiert in Form zeitabhängiger Statistiken. Anschließend folgt die Bewertung dieses

Materials im Sinne der Relevanz für Warnhinweise. Hierzu dient der beschriebene Versuchsaufbau.

## 2.1 Versuchsaufbau

Die Verhaltensanalyse und Beobachtung wird durchgeführt im Versuchs- und Bildungszentrum Landwirtschaft Haus Düsse der Landwirtschaftskammer Nordrhein-Westfalen in Bad Sassendorf, Deutschland. Die Tiere haben ein durchschnittliches Absetzgewicht von ca. 7,80 kg. Der Versuch erfolgt im Rahmen der konventionellen Ferkelaufzucht in vier Buchten mit einer Gruppengröße von jeweils 35 Tieren. Die Haltungsumwelt kennzeichnet sich durch ein erhöhtes Platzangebot (0,5 m<sup>2</sup> je Tier), ad libitum Trockenfütterung, offene Tränkeschalen und verschiedene Beschäftigungsmaterialien. Das Verhalten der Tiere wird kontinuierlich über die gesamte Dauer der Ferkelaufzucht von sechs Wochen auf Video aufgezeichnet. Dazu wurden je Bucht zwei stationäre HD-Kameras (Bascom Bullet-Kamera Plus VB40, 1080p, 20 fps) installiert. Auf Grundlage dieser Videoaufzeichnung findet die weitere Auswertung statt.

## 3 Konzeptioneller Ansatz

Es wird ein überwachter Ansatz verfolgt (supervised deep learning), für den Trainingsdaten erforderlich sind. Die Erkennung von komplexeren Verhaltensformen von Schweinen baut auf den einzelnen Schweinen zugeordneten Grundformen auf. Statt der häufig [Na19 Li20] erwähnten Grundform des umhüllenden, achsenparallelen Rechtecks einerseits und andererseits feingliedrigen Posen [Gr19] wird eine einfache Pose, bestehend aus Nacken, Schwanzposition und gerichteter Rückenlinie von Nacken zu Schwanz benutzt. Im Gegensatz zu einem umgebenden Rechteck kann durch Kenntnis der Position von Kopf- und Schwanzposition auch die Orientierung im Raum bestimmt werden bis hin zu Maul-Schwanznäherungen.

Mithilfe der Posen-Struktur in Kombination mit der Entfernung, Beschleunigung und Geschwindigkeit, gegenseitiger Orientierung, sowie Kopf- und Rücken-Position können außerdem kurzzeitige Attacken erkannt werden, die eine Basis für weitere Statistiken liefern (s. Abb. 1). Auch hier, zur sog. Action Recognition, ist der Einsatz von Lernverfahren möglich. In [Li20] werden sich bewegende, „interagierende“ Rechtecke in eine Sekunde dauernde Zeitblöcke geschnitten, trainiert und mit einem speziellen Deep-Learning-Verfahren (LSTM) ausgewertet. Wir werden grundlegende Interaktionen mit dem bewährten traditionellen Lernverfahren der Random Forests [Br01] trainieren und Merkmale nutzen, die sich unmittelbar aus der Auswertung der Posen ergeben.

Ziel ist es dann, möglichst viele aus der Verhaltensforschung zum Schwanzbeißen bekannten Merkmale (atypische Schwanzhaltungen, Sequenzen mit aggressivem Verhalten, Schwanz-in-Maul-Situationen, Verfolgungen) aufbauend auf den durch Learning erkannten und klassifizierten Actions automatisch zu erkennen und statistisch

auszuwerten. Die sich ergebenden Ist-Werte sollen dann mit aus der Verhaltensforschung bekannten Soll-Werten abgeglichen werden und für die Früherkennung von Schwanzbeissen genutzt werden, wobei dann auch in einer Rückkopplung neue Erkenntnisse zum Verhalten gewonnen werden können, insbesondere, wenn außerordentliche Ereignisse wie Schwanzbeissen stattgefunden haben sollten.




Abb. 1: Beispiel einer kurzzeitigen Attacke, entdeckt aus zeitlicher Änderung der Posen

## 4 Ergebnisse

Für die Erkennung der Posen und deren zeitliche Koordinierung (Tracking) wurden für ein Demonstrationsvideo zunächst eigene Trainingsdaten erhoben (s. Abb. 2) [Vi20]. Dies war mit wenigen manuellen Annotationen möglich<sup>3</sup>. Für die Annotation der Trainingsdaten wurde ein interaktiver Editor zur Erfassung von Nacken- und Schwanzposition entwickelt. Beim Training wurden hieraus Patches (Rechtecksbereiche) zufällig herausgeschnitten und mit einem Image-Generator zufällig in Form und Farbe geändert. Dann wurde ein Deep Learning neuronales Netz zum Training verwendet, wobei die in [Os20] verfügbare Software auf die in KISS verwendete Posen-Struktur umgewandelt wurde. Das neuronale Netz liefert als Ausgabe vier Heatmaps für Nacken, Schwanz, x- und y-Komponente des gerichteten Rückenvektorfeldes als verkleinerte Graustufenbilder. Die hieraus abgeleiteten Positionen können zum Teil noch fehlerhaft sein und werden für die Generierung zeitlicher Abläufe automatisch korrigiert. Für die Verbindung von Kopf und Rücken werden die Vektorfelder genutzt, um falsche Verbindungen zu vermeiden. Dies geschieht durch Anwendung eines Zuordnungs-Algorithmus (Ungarische Methode) [Un20]. Mit diesen Maßnahmen gelingt ein Tracking von Positionen und Verbindungen (Nacken, Schwanz, gerichtete Rückenlinie) im zeitlichen Ablauf für die Analyse der zeitlichen Dynamik. Ein wichtiges Resultat hierbei ist, dass Schwanzpositionen angenähert individuell und im zeitlichen Ablauf bereitstehen. Definiert man um diese Schwanzpositionen Umgebungs-Rechtecke, so ist die Grundlage für eine anschließende Klassifikation der Schwanzhaltung mit einem schnell auswertbaren Deep-Learning-Klassifizierer geschaffen.

Das Grundproblem der Bereitstellung von Trainingsdaten kann mittlerweile für die im Projekt verwendete Posen-Struktur als gelöst angesehen werden. Hierzu wurde der von

<sup>3</sup> Trainiert wurden 20 Einzelbilder und nach Auswertung 100 Einzelbilder korrigiert (Aufwand etwa 1 Stunde)

der Universität Nebraska bereitgestellte frei verwendbare Trainingsdatensatz genutzt und modifiziert [Ps19]. Dieser Datensatz besteht aus 2000 Bildern und 24.824 individuell manuell annotierten Schweine-Posen. Aus diesem Datensatz wurde die von uns verwendete Posen-Struktur gewonnen und durch künstliche Verlängerung der Rückenlinie in Richtung Schwanz modifiziert. Das Training mit den so für das Projekt angepassten Daten war mit den für KISS erhobenen Videos in Haus Düsse sofort erfolgreich.



Abb. 2: Erkennung der verwendeten Posen-Struktur im Demonstrationsvideo [Vi20]

Als erster Schritt zur automatischen Erkennung von aus der Verhaltensforschung zum Schwanzbeißen bekannten Aktionen (Sequenzen mit aggressivem Verhalten, Schwanz-in-Maul-Situationen, Verfolgungen) wurden repräsentative Ausschnitte aus den Videos aus fachkundlicher Sicht ausgewählt und dann die Nacken-Schwanz-Paare der beteiligten Akteure im zeitlichen Ablauf erfasst. Hieraus wird eine geeignete Datenstruktur als Eingabe für die automatische Action Recognition abgeleitet.

## 5 Fazit und Ausblick

Die mithilfe von Deep Learning erreichten Resultate bieten eine Grundlage für weitere Entwicklungen. Eine Herausforderung wird sein, die automatisierte Erfassung mit einer Warnung beim Erreichen von Schwellenwerten, ab denen Verhaltensweisen ein pathologisches Stadium erreichen, zu kombinieren. Hierzu wird eine benutzerfreundliche Gestaltung des Systems als Decision **Support** System angestrebt, sodass der Tierhalter in eigener Verantwortung Interventionsmaßnahmen ergreifen kann.

### Literaturverzeichnis

[Br01] Breiman, L.: Random forests. Machine Learning 45(1), 5-32, 2001.

- [De18] D'Eath, R.B. et al.: Automatic early warning of tail biting in pigs: 3D cameras can detect lowered tail posture before an outbreak. *PloS one*, 13(4), e0194524, 2018.
- [Gr19] Graving, J.M. et al: DeepPoseKit, a software toolkit for fast and robust animal pose estimation using deep learning. *eLife*. 2019; 8: e47994. Published online 2019 Oct 1. doi: 10.7554/eLife.47994, 2019.
- [LAP18] Larsen, M.L.V.; Andersen, H.M.L.; Pedersen, L.J.: Tail posture as a detector of tail damage and an early detector of tail biting in finishing pigs. *Applied animal behaviour science*, 209, 30-35, 2018.
- [LAP19] Larsen, M.L.V.; Andersen, H.M.L.; Pedersen, L.J.: Changes in activity and object manipulation before tail damage in finisher pigs as an early detector of tail biting. *Animal*, 13(5), 1037-1044, 2019.
- [Li20] Liu, D. et al.: A computer vision-based method for spatial-temporal action recognition of tail-biting behaviour in group-housed pigs. *Biosystems Engineering*, 195, 27-41, 2020.
- [Mo03] Moinard, C. et al.: A case control study of on-farm risk factors for tail biting in pigs. *Applied Animal Behaviour Science*, 81(4), 333-355, 2003.
- [Na19] Nasirahmadi, A. et al.: Deep Learning and Machine Vision Approaches for Posture Detection of Individual Pigs. *Sensors*, 19(17), 3738, 2019.
- [Os20] Osokin, D. Lightweight-human-pose-estimation, <https://github.com/Daniil-Osokin/lightweight-human-pose-estimation-3d-demo.pytorch>, Stand: 7.10.2020.
- [Ps19] Psota, E.T. et al.: Multi-Pig Part Detection and Association with a Fully-Convolutional Network. *Sensors*, 19(4), 852
- [SS01] Schröder-Petersen, D.L.; Simonsen, H.B.: Tail biting in pigs. *The Veterinary Journal*, 162(3), 196-210, 2001.
- [So13] Sonoda, L.T.: Tail Biting in pigs - Causes and management intervention strategies to reduce the behavioural disorder. A review. *Berl Munch Tierarztl Wochenschr*, 126(3-4), 104-12, 2013.
- [Ta10] Taylor, N.R. et al.: Tail-biting: a new perspective. *The Veterinary Journal*, 186(2), 137-147, 2010.
- [Un20] Ungarische Methode, [https://de.wikipedia.org/w/index.php?title=Ungarische\\_Methode&oldid=194102148](https://de.wikipedia.org/w/index.php?title=Ungarische_Methode&oldid=194102148), Stand: 27.10.2020.
- [Vi20] Demonstrations-Video, <https://www.landwirtschaftskammer.de/duesse/tierhaltung/schweine/projekte/kiss/index.htm>, Stand: 05.11.2020
- [We18] Wedin, M.: Early indicators of tail biting outbreaks in pigs. *Applied animal behaviour science*, 208, 7-13, 2018.
- [Zo11] Zonderland, J.J.: Characteristics of biter and victim piglets apparent before a tail-biting outbreak. *Animal*, 5(5), 767-775, 2011.