



HOCHSCHULE
NEUBRANDENBURG

University of Applied Sciences

Fachbereich Agrarwirtschaft und Lebensmittelwissenschaften
Studiengang Agrarwirtschaft

Masterarbeit

zur Erlangung des akademischen Grades
„Master of Science (M.Sc.)“

“Tiergesundheitsüberwachung von Rindern via Videosystem und Objekterkennung“

vorgelegt von:
Gabriel Schmidt

Erstprüferin: Prof. Dr. Lisa Bachmann
Zweitprüfer: Dr. Timo Homeier-Bachmann

Neubrandenburg
30.08.2023

urn:nbn:de:gbv:519-thesis2023-0238-7

Inhaltsverzeichnis

“Tiergesundheitsüberwachung von Rindern via	I
Videosystem und Objekterkennung“	I
Inhaltsverzeichnis	II
Abbildungsverzeichnis	V
Tabellenverzeichnis	VII
Abkürzungsverzeichnis	IX
1 Einleitung	1
2 Literaturübersicht und Stand des Wissens	3
2.1 Bedeutung der Überwachung der Tiergesundheit/des Tierwohls in landwirtschaftlichen Betrieben	3
2.1.1 Definition Tiergesundheit/Tierwohl	3
2.1.2 Überwachung der Tiergesundheit/des Tierwohls	3
2.1.3 Wandel des Fokus vom Stall zum Tier	3
2.1.4 Die Rolle des Tierhalters	4
2.1.5 Gesetzliche Vorgaben	4
2.1.6 Unterschied zwischen betrieblichen Eigenkontrollen und täglichen Tierkontrollen	5
2.1.7 Strukturwandel in der Landwirtschaft und ihre Folgen	5
2.1.8 Digitalisierung als Ausweg	5
2.2 Monitoring Systeme	6
2.2.1 Tierbeobachtung durch geschultes Personal	6
2.2.2 Sensor gestützte Systeme in Tierhaltungen	14
2.2.3 Künstliche Intelligenz	20
3 Material	26
3.1 Computer-Hardware	26
3.2 Computer-Software	26
3.3 Experimenteller Aufbau	26
3.3.1 Tiere und Haltungsbedingungen	26
3.3.2 Verwendete Kameratechnik	26
3.4 Verwendete Bild- und Videodateien	28
3.4.1 Videomaterial aus den Tierversuchsställen des Friedrich-Loeffler-Instituts	28
3.4.2 Weiteres Videomaterial	28
3.4.3 Bildmaterial	30
4 Methoden	31
4.1.1 Auswahl der Videodateien	31

4.1.2	Software-basierte Sichtung der ausgewählten Videosequenzen.....	31
4.2	Klassifizieren von Bildern.....	31
4.2.1	Klassifizierung Objekteigenschaft.....	31
4.2.2	Klassifizierung Objekteigenschaft der Kühe aus dem Laufstall.....	32
4.2.3	Klassifizierung Objekterkennung.....	32
4.2.4	Verwendung klassifizierter Bilder.....	33
4.3	Anlernen von YOLOv4.....	33
4.3.1	YOLOv4: Ein leistungsstarker Algorithmus für Echtzeit-Objekterkennung mit CNN	33
4.3.2	Lernen aus klassifizierten Bildern für präzise Klassifizierung und Lokalisierung.....	33
4.3.3	Training und Evaluierung von Objekterkennung mit Trainings- und Testgruppen.....	34
4.3.4	YOLOv4-Parameter zur Objekterkennung von „stehenden“ / „liegenden“ Kühen und deren Individualisierung.....	35
4.3.5	Wichtige Parameter zur Bewertung der Leistung eines Modells.....	35
4.4	Training Objekteigenschaft „stehend“ bzw. „liegend“.....	37
4.4.1	Versuch 1.....	37
4.4.2	Versuch 2.....	38
4.4.3	Versuch 3.....	39
4.5	Anwendung des Detektors/neuronalen Netzes auf fremde Umgebungen.....	41
4.5.1	Laufstall 1.....	41
4.5.2	Laufstall 2.....	43
4.6	Training Individualisierung der Kühe.....	44
4.7	Manuelle Messung der Steh- und Liegezeiten der individualisierten Kühe.....	45
4.8	Automatisierte Messung der Steh- und Liegezeiten der Kühe als Gruppe anhand eines Tages.....	46
4.8.1	Vergleich zur manuellen Methode.....	46
4.8.2	Automatisierte Auswertung eines gesamten Tages.....	48
5	Ergebnisse.....	49
5.1	Training „stehender“ / „liegender Kühe“.....	49
5.1.1	Versuch 1.....	49
5.1.2	Versuch 2.....	50
5.1.3	Versuch 3.....	52
5.2	Anwendung des Detektors/ neuronalen Netzes auf fremde Umgebungen.....	58
5.2.1	Laufstall 1.....	58
5.2.2	Laufstall 2.....	63
5.3	Training Individualisierung der Kühe.....	67

5.4	Manuelle Messung der Steh- und Liegezeiten der individualisierten Kühe	69
5.5	Automatisierte Auswertung der Steh- und Liegezeiten auf Gruppenebene	70
5.5.1	Validierung der automatisierten Methode mit der manuellen Auswertung ...	70
5.5.2	Nutzung der automatisierten Methode auf Gruppenebene	70
6	Diskussion	72
6.1	Bewertung der Tiergesundheit in landwirtschaftlichen Betrieben	72
6.2	Sensorgestützte Systeme zur Unterstützung der Tiergesundheitserkennung	73
6.3	Einsatz von künstlicher Intelligenz und Objekterkennungssoftware	73
6.4	Kritik der Methoden.....	74
6.5	Analyse und Diskussion der Versuchsergebnisse.....	74
6.5.1	Training der Objekteigenschaften „stehender“ und „liegender“ Kühe	74
6.5.2	Anwendung des Detektors/ neuronalen Netzes auf fremde Umgebungen ..	78
6.5.3	Bewertung der Individualisierung von Kühen	81
6.5.4	Manuelle Messung der Steh- und Liegezeiten der individualisierten Kühe ..	82
6.5.5	Automatisierte Messung der Steh- und Liegezeiten der Kühe auf Gruppenebene.....	83
7	Zusammenfassung und Ausblick	85
8	Literaturverzeichnis.....	87
A	Eidesstattliche Erklärung	A-1

Abbildungsverzeichnis

Abbildung 1 Eigene Darstellung einer Laufbox aus der Vogelperspektive. Hier werden die Positionen und toten Winkel aller Kameras der Einfachheit halber in einer Grafik zusammengefasst dargestellt. Rot markierte Bereiche zeigen die toten Winkel der Kameras auf.	27
Abbildung 2 Eigene Darstellung des Laufstalls aus der Vogelperspektive mit Sichtfeldern der Kameras und Bereichen die nicht eingesehen werden können.	29
Abbildung 3 Manuelles Labeln der Objekteigenschaften mithilfe von Labelling. Die Rechtecke umrahmen die Körperflächen der Kühe und werden separat als Koordinaten gespeichert und weiterverwendet.	32
Abbildung 4 Ablauf und Entstehung eines Objekterkennungsmodells und die einzelnen Schritte bis ein Modell anwendbar ist (Daglioglu, 2021).	34
Abbildung 5 Berechnung der IoU (Daglioglu, 2021)	36
Abbildung 6 Klassifizieren der Kühe im Laufstall in „stehend“ und „liegend“ mit gelabelten Kühen im ersten Versuch.	42
Abbildung 7 Klassifizieren der Kühe im Laufstall in „stehend“ und „liegend“ mit weniger gelabelten Kühen im zweiten Versuch. Hier wurden nur Label aus dem Nahbereich der Kamera verwendet.	42
Abbildung 8 Klassifizieren der Kühe im Laufstall in „stehend“ und „liegend“ aus Sicht einer anderen Kamera im ersten Versuch des Laufstalls 2.	43
Abbildung 9 Klassifizieren der Kühe im Laufstall in „stehend“ und „liegend“ mit weniger gelabelten Kühen aus Sicht einer anderen Kamera im zweiten Versuch. Auch hier wurden die Kühe nur im Nahbereich der Kamera klassifiziert, die verwendeten Bilder blieben dieselben.	44
Abbildung 10 Präzisionen der Trainingsgruppe von „stehenden“ und „liegenden“ Kühen in Abhängigkeit von der Anzahl der jeweilig erstellten Label im ersten Versuch.	50
Abbildung 11 Präzisionen der Trainingsgruppe von „stehenden“ und „liegenden“ Kühen in Abhängigkeit von der Anzahl der jeweilig erstellten Label im zweiten Versuch.	51
Abbildung 12 Präzisionen der Trainingsgruppe von „stehenden“ und „liegenden“ Kühen in Abhängigkeit von der Anzahl der jeweilig erstellten Label im dritten Versuch.	53
Abbildung 13 Das Verhältnis zwischen der Anzahl der Label und Bilder von den Kühen und ihren Objekteigenschaften zeigt die einzelnen Graphenpunkte der Trainingsgruppen 1 bis 9 aus Versuch 3.	54
Abbildung 14 Eigenständige Erkennung der Objekteigenschaft durch den Detektor. Die über den Boxen stehenden Informationen sind die Objekteigenschaft und die jeweilige Präzision, mit der sie detektiert wurde.	56
Abbildung 15 Auch auf dieser Grafik identifiziert der Detektor eine zum größten Teil verdeckte Kuh und ist fähig zwei weitere Kühe zu klassifizieren, die durch das Fressfanggitter unregelmäßig verdeckt werden.	56
Abbildung 16 Hier wird eine Kuh korrekt klassifiziert, die zum größten Teil durch eine andere Kuh verdeckt wird.	57
Abbildung 17 Gegenüberstellung „liegender“ und „stehender“ Kühe mit Angabe der durchschnittlichen Präzision für die Detektion während des Tages und der Nacht im ersten Versuch mit mehr Label.	59
Abbildung 18 Darstellung von falschen Ergebnissen vom Objekterkennungsmodell bei drei „stehenden“ Kühen die offensichtlich „liegen“	59

Abbildung 19 Kameraperspektive von der anderen Stallseite. Nähere Kühe werden hinsichtlich der Objekteigenschaft erkannt. Weiter entferntere Kühe werden nicht sicher oder falsch detektiert.	60
Abbildung 20 Gegenüberstellung „liegender“ und „stehender“ Kühe mit Angabe der durchschnittlichen Präzision für die Detektion während des Tages und der Nacht im zweiten Versuch mit weniger Label.	61
Abbildung 21 Bis auf eine Kuh, werden alle anderen richtig detektiert und korrekt klassifiziert.	62
Abbildung 22 Bis zu der Absperrung auf dem Laufgang werden alle Kühe detektiert und korrekt klassifiziert.	62
Abbildung 23 Gegenüberstellung „liegender“ und „stehender“ Kühe des Laufstalls 2 mit Angabe der durchschnittlichen Präzision für die Detektion während des Tages und der Nacht im ersten Versuch mit mehr Label.	64
Abbildung 24 Das Objekterkennungsmodell detektiert Stalleinbauten als „stehende“ Kuh.	64
Abbildung 25 Stalleinrichtung und Tiere werden falsch identifiziert und klassifiziert.	65
Abbildung 26 Gegenüberstellung „liegender“ und „stehender“ Kühe des Laufstalls 2 mit Angabe der durchschnittlichen Präzision für die Detektion während des Tages und der Nacht im zweiten Versuch mit weniger Label.	66
Abbildung 27 Kühe werden nicht oder teils detektiert. Stalleinbauten werden auch hier als „stehende“ Kuh klassifiziert.	67
Abbildung 28 Ergebnis der Individualisierung der einzelnen Kühe mit der Kennzeichnung und der jeweiligen Präzision über der Box.	68
Abbildung 29 Steh- und Liegeverhalten der Kuhgruppe über einen gesamten Tag hinweg.	71
Abbildung 30 Ablauf einer möglichen automatischen Videoauswertung: Weiß: Rohmaterial, Blau: Detektion und Analyse, Rot: Ergebnisse, verändert nach Schütz (2023).	86

Tabellenverzeichnis

Tabelle 1 Methoden der Brunsterkennung und deren Erkennungsraten, verändert nach Becker, Kanitz, and Heuwieser (2005); Holman et al. (2011); Zieger (2004).....	7
Tabelle 2 YOLOv4-Parameter zur Objekterkennung von „stehenden“ / „liegenden“ Kühen und deren Individualisierung	35
Tabelle 3 Aufteilung der Bilder in Trainings- und Testgruppe mit Anzahlen der Label der jeweiligen Objekteigenschaften im ersten Versuch.	38
Tabelle 4 Aufteilung der Bilder und Label auf die unterschiedlichen Trainingsgruppen im ersten Versuch.	38
Tabelle 5 Aufteilung der Bilder in Trainings- und Testgruppe mit Anzahlen der Label der jeweiligen Objekteigenschaften im zweiten Versuch.	38
Tabelle 6 Aufteilung der Bilder und Label auf die unterschiedlichen Trainingsgruppen im zweiten Versuch.....	39
Tabelle 7 Aufteilung der Bilder in Trainings- und Testgruppe mit Anzahlen der Label der jeweiligen Objekteigenschaften im dritten Versuch.	40
Tabelle 8 Aufteilung der Bilder und Label auf die unterschiedlichen Trainingsgruppen im dritten Versuch.	40
Tabelle 9 Aufteilung der Label von "stehenden" und "liegenden" Tieren in Tag- und Nachtaufnahmen im ersten Versuch des Laufstalls 1.....	41
Tabelle 10 Aufteilung der Label von "stehenden" und "liegenden" Tieren in Tag- und Nachtaufnahmen im zweiten Versuch des Laufstalls 1.	42
Tabelle 11 Aufteilung der Label von "stehenden" und "liegenden" Tieren in Tag- und Nachtaufnahmen im ersten Versuch des Laufstalls 2.....	43
Tabelle 12 Aufteilung der Label von "stehenden" und "liegenden" Tieren in Tag- und Nachtaufnahmen im zweiten Versuch des Laufstalls 2.	44
Tabelle 13 Aufteilung der Bilder der einzelnen Kühe in Test- und Trainingsgruppe.....	45
Tabelle 14 Manuell erfasste Steh- und Liegezeiten der einzelnen Kühe in Sekunden für jedes einzelne Video zur Stunde 0.....	46
Tabelle 15 Manuelle und automatisierte Gruppenauswertung der ersten zwei Stunden mit 6 Videos in Excel im Vergleich. Alle Zahlenangaben sind in Sekunden.....	47
Tabelle 16 Darstellung der Präzisionen der einzelnen Trainingsgruppen von "stehenden" und "liegenden" Kühen in Abhängigkeit von der Anzahl der Bilder und Label im ersten Versuch.	49
Tabelle 17 Darstellung der Präzisionen der einzelnen Trainingsgruppen von "stehenden" und "liegenden" Kühen in Abhängigkeit von der Anzahl der Bilder und Label im zweiten Versuch.	51
Tabelle 18 Darstellung der Präzisionen der einzelnen Trainingsgruppen von "stehenden" und "liegenden" Kühen in Abhängigkeit von der Anzahl der Bilder und Label im dritten Versuch.	52
Tabelle 19 Darstellung der Ergebnisse des dritten Versuchs mit den wichtigsten Parametern zur Bewertung der Leistung eines Modells.	54
Tabelle 20 Aufgliederung der präzisesten Trainingsgruppe in die Objekteigenschaften mit den wichtigsten Parametern zur Bewertung eines Modells.....	55
Tabelle 21 Durchschnittliche Präzisionen der Objekteigenschaften in Abhängigkeit von der Anzahl der Bilder, Label, sowie Tag- und Nachtaufnahmen im ersten Versuch des Laufstalls 1.	58

Tabelle 22 Durchschnittliche Präzisionen der Objekteigenschaften in Abhängigkeit von der Anzahl der Bilder, Label, sowie Tag- und Nachtaufnahmen im zweiten Versuch des Laufstalls 1.....	61
Tabelle 23 Durchschnittliche Präzisionen der Objekteigenschaften in Abhängigkeit von der Anzahl der Bilder, Label, sowie Tag- und Nachtaufnahmen im ersten Versuch des Laufstalls 2.	63
Tabelle 24 Durchschnittliche Präzisionen der Objekteigenschaften in Abhängigkeit von der Anzahl der Bilder, Label, sowie Tag- und Nachtaufnahmen im zweiten Versuch des Laufstalls 2.....	65
Tabelle 25 Darstellung von Ergebnissen der Objekterkennung aller einzelnen Kühe mit den wichtigsten Parametern zur Bewertung der Leistung eines Modells.	68
Tabelle 26 Darstellung des Ergebnisses der Objekterkennung für alle Kühe als Durchschnitt mit den wichtigsten Parametern zur Bewertung der Leistung eines Modells.	68
Tabelle 27 Ergebnisse der manuellen Erfassung von Steh- und Liegezeiten der einzelnen Kühe am ersten Tag.	69
Tabelle 28 Ergebnisse der manuellen Erfassung von Steh- und Liegezeiten der einzelnen Kühe am zweiten Tag.	70

Abkürzungsverzeichnis

GPU	Graphics processing unit / Grafikprozessor
Video RAM	Video Random-Access Memory / Grafikspeicher
Fps	Frames per second / Bilder pro Sekunde
TierSchG	Tierschutzgesetz
TierSchNutzV	Tierschutz- Nutztierhaltungsverordnung
d.h.	Das heißt
Sog.	So genannt
BCS	Body Condition Score
IR	Infrarot
GB	Gigabyte
VLC	VideoLan Client
Dpi	Dots per inch / Punkte pro Zoll
CNN	Convolutional Neural Network
AP	Average Precision
TP	True positive
FP	False positive
FN	False negative
mAP	Mean Average Precision
IoU	Intersection over Union
UHF-RFID	Ultra High Frequency – Radio frequency identification
KI	Künstliche Intelligenz
NIR	Nah-Infrarot
IoU	Intersection over Union

1 Einleitung

Die Überwachung der Tiergesundheit in landwirtschaftlichen Betrieben hat in den letzten Jahrzehnten zunehmend an Bedeutung gewonnen. Sie ist nicht nur ein zentraler Aspekt des Tierwohls, sondern auch entscheidend für die Produktivität und Rentabilität der Betriebe. Traditionelle Tierbeobachtungsmethoden, die auf geschultes Personal angewiesen sind, stoßen jedoch oft an ihre Grenzen, da sie zeitaufwändig, kostenintensiv und manchmal unzuverlässig sind. Sensor gestützte Monitorsysteme können rund um die Uhr Daten erfassen und sie auswerten, allerdings sind sie invasiv. In dieser Arbeit soll die Möglichkeit einer innovativen, nicht-invasiven Tiergesundheitsüberwachung mittels eines Kamerasystems in Kombination mit Objekterkennungssoftware untersucht werden. Sie bietet eine kontaktlose Tierüberwachung, ohne dass das Verhalten der Tiere beeinflusst wird und benötigt verhältnismäßig wenig Technik, weil keine Sensoren genutzt werden müssen.

Das Hauptziel besteht darin, ein leistungsfähiges Objekterkennungssystem zu erstellen, das mithilfe von extrahierten Bildern aus Videos bestimmte Objekteigenschaften und Objekterkennung zuverlässig detektieren kann und letztlich das Verhalten von Rindern überwacht. Konkret soll in einem Versuch angestrebt werden, das System in die Lage zu bringen, „liegende“ und „stehende“ Rinder zu detektieren und zu klassifizieren. Ein weiteres Ziel ist, die Individualisierung von Rindern innerhalb einer Gruppe zu erreichen, um eine Einzeltierbeobachtung zu ermöglichen. Dies wäre eine Voraussetzung, um einzeltierspezifische Aussagen treffen zu können.

Die Relevanz der Versuche ist vielfältig. Zum einen wird die Tiergesundheitsüberwachung in der Landwirtschaft immer wichtiger, da Tierwohlvorschriften und Verbrauchieranforderungen zunehmen. Ein effizientes, kostengünstiges und nicht-invasives System könnte nicht nur dazu beitragen Krankheiten früher zu erkennen, sondern auch das Wohlbefinden der Tiere insgesamt zu verbessern, indem frühzeitig vor Unregelmäßigkeiten des Verhaltens gewarnt werden kann. Zum anderen wird die Forschung die Integration von künstlicher Intelligenz und Computer Vision in der Landwirtschaft weiter vorantreiben. Zahlreiche Studien beschäftigen sich schon seit Jahren damit, da sie das Potential haben, die Effizienz und Genauigkeit der Tiergesundheitsüberwachung erheblich zu verbessern.

In dieser Arbeit wird die Methode des Anlernens des Objekterkennungsalgorithmus YOLOv4 verwendet, um diese Ziele zu erreichen. Der Versuch wird Einblicke in die Machbarkeit und Effizienz dieses Ansatzes bieten und möglicherweise Hinweise für zukünftige Entwicklungen, Forschungen und Ausblicke geben.

Das erste Kapitel (2.1) handelt von der Bedeutung der Überwachung der Tiergesundheit in landwirtschaftlichen Betrieben und thematisiert danach verschiedene Monitoringsysteme

(2.2). Anschließend werden der Aufbau und die Methoden der Versuche erklärt (Kapitel 3 und 4). Im fünften Kapitel werden die Ergebnisse dargestellt und anschließend im sechsten Kapitel diskutiert. Danach folgen schlussendlich die Zusammenfassung und ein Ausblick.

2 Literaturübersicht und Stand des Wissens

2.1 Bedeutung der Überwachung der Tiergesundheit/des Tierwohls in landwirtschaftlichen Betrieben

2.1.1 Definition Tiergesundheit/Tierwohl

Das Tierwohl lässt sich mit den fünf Freiheiten des Tieres darstellen. Ein Tier muss frei von Durst, Hunger und Unterernährung leben können, durch freien und leichten Zugang zu frischem und sauberem Wasser und einer Ernährung, die die Gesundheit und Vitalität erhält und fördert. Das Bereitstellen eines geeigneten Umfelds, welches Schutz, Unterschlupf und einen bequemen Ruhebereich bietet, soll dem Tier ermöglichen, frei von Unannehmlichkeiten zu leben. Die Freiheit von Schmerzen, Verletzungen und Krankheiten sollte durch Prävention, schnelle Diagnose und eine Behandlung gewährleistet sein. Ein Tier muss sein Verhalten normal und frei äußern können, indem man ihm ausreichend Platz in einer geeigneten Einrichtung und Kontakt zu Artgenossen gewährt. Die Freiheit eines Tieres von Angst und chronischem Stress als letzter Punkt muss durch Bedingungen und Behandlungen gewährleistet sein, die psychisches Leid vermeiden (Brambell, 1965) (FAWC, 2012). Die Tiergesundheit selbst umfasst physiologische Grundbedürfnisse wie Futter, Wasser, Licht, Luft, Ruhe und Raum, sowie die Abwesenheit, Prävention und Bekämpfung von Krankheit und Verletzung (MLVB MEL, 2023; David Fraser, 2008; D. Fraser, Weary, Pajor, & Milligan, 1997; Hulsen, 2021).

2.1.2 Überwachung der Tiergesundheit/des Tierwohls

Das Tierwohl, das die Gesundheit und das Wohlbefinden der Tiere umfasst, betrifft jeden Nutztierhalter und ist jedem verantwortungsbewussten Tierhalter ein Anliegen. Um es messen und bewerten zu können muss klar sein, was Tierwohl ist. Die fünf Freiheiten stellen dies durch die Beschreibung der Gesundheit, des Verhaltens und der Emotionen des Tieres dar. Entscheidend für den Erfolg ist der Faktor Mensch, der die Tiere genau beobachtet. Er ist als Halter nicht nur für die Tiere verantwortlich, sondern hat auch den größten Einfluss auf deren Leistung und damit auf seinen eigenen wirtschaftlichen Erfolg, die Sicherung seines Einkommens (KTBL, 2021). Daneben fordert auch die Gesellschaft eine tiergerechte Haltung von den Tierhaltern, was berechtigt ist und ernst genommen werden sollte (Kunzmann, 2015). Wichtig dabei ist anzumerken, dass es darum geht, was wirklich mess- und prüfbar und eben nicht „gefühlte“ tiergerecht ist.

2.1.3 Wandel des Fokus vom Stall zum Tier

In der Vergangenheit wurde unter „tiergerechter Haltung“ häufig verstanden, dass baulich-technische Anforderungen innerhalb des Haltungssystems wie beispielsweise Mindestauslauffläche und anderes zu prüfen und einzuhalten sind. Zwar sind möglichst optimale Haltungssysteme eine grundlegende Voraussetzung für eine tiergerechte Haltung; doch viel wichtiger sind die eigenen Ansprüche der verschiedenen Tiere, die mit den gegebenen

Rahmenbedingungen erreicht und befriedigt werden müssen. Somit hat sich der Ansatz durchgesetzt, die Folgen der Haltungsbedingungen und der Managementmaßnahmen des Tierhalters auf das Tier zu erfassen. Der höchste Stallkomfort nutzt nichts, wenn die Ernährung und der Umgang des Tierhalters mit den Tieren nicht stimmen. Der Fokus richtet sich also direkt auf das Tier selbst, bei dem die Gesundheit und das Verhalten am besten erkannt und durch „tierbezogene“ Kenngrößen erhoben werden kann (KTBL, 2021).

2.1.4 Die Rolle des Tierhalters

Um das Tierwohl zu erreichen ist es erforderlich, dass eine selbstkritische Überprüfung der Situation der Tierbestände sachlich und faktenbasiert erfolgt. Diese Überprüfung schärft einerseits den Blick des Tierhalters bezüglich des Tierwohls und hilft andererseits eine mögliche Betriebsblindheit zu vermeiden. Eine Schwachstellenanalyse des Betriebs kann dem Nutztierhalter helfen, Risiken für das Tierwohl innerhalb des Betriebs früh zu erkennen, geeignete Maßnahmen zu ergreifen und so sein Management zu verbessern. Betriebliche Eigenkontrollen bieten außerdem die Chance, die polarisierenden gesellschaftlichen Diskussionen zum Thema Tierwohl innerhalb der Nutztierhaltung zu versachlichen (KTBL, 2021).

2.1.5 Gesetzliche Vorgaben

Tägliche Tierkontrollen sind zudem gesetzlich verankert. Der Tierhalter hat nach § 4 Abs.1 Satz 1 und 2 der TierSchNutztV sicherzustellen, dass das Befinden der Tiere mindestens einmal täglich durch eine direkte visuelle Kontrolle überprüft wird. Dafür muss es genügend Personal geben, welches die dafür erforderlichen Kenntnisse und Fähigkeiten vorweisen kann (TierSchNutztV, 2021). Um den Anforderungen der Nutztierhaltung zu Erwerbszwecken gerecht zu werden, müssen für die betriebliche Eigenkontrollen nach §11 Absatz 8 des TierSchG geeignete tierbezogene Merkmale erhoben, bewertet und festgehalten werden (TierSchG, 2020). Problematisch hierbei ist, dass im TierSchG weder Angaben darüber gemacht werden, welche Tierschutzindikatoren für die betrieblichen Eigenkontrollen geeignet sind, noch darüber, wie sie festgehalten werden sollen. Auch die erforderlichen Kenntnisse und Fähigkeiten über die Gesundheit, Ernährung, Pflege, Haltung, tierschutzrechtliche Vorschriften, aber auch Grundkenntnisse über Biologie und Verhalten von Rindern werden im Gesetz nicht erklärt oder definiert. So lässt der Begriff ‚erforderlich‘ einen gewissen Handlungsspielraum zu (Feldner & Donicht, 2016). Das Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. bietet beispielsweise für den Anwender Praxisleitfäden für die verschiedenen Nutztiere an, in denen Tierschutzindikatoren behandelt und erklärt werden (KTBL, 2016, 2020a, 2020b). In dem Projekt „EiKoTiGer“ (Eigenkontrolle Tiergerechtigkeit) haben verschiedene Autoren in Zusammenarbeit die Praxistauglichkeit und Verlässlichkeit von Tierschutzindikatoren für die betriebliche Eigenkontrolle erforscht und sind zu dem Schluss gekommen, dass die Erhebung von Tierschutzindikatoren in der Praxis leicht für jeden anwendbar sind (Schultheiß et al., 2021).

2.1.6 Unterschied zwischen betrieblichen Eigenkontrollen und täglichen Tierkontrollen

Betriebliche Eigenkontrollen und tägliche Tierkontrollen unterscheiden sich in der Ausführung und Zielsetzung voneinander. Bei den täglichen Tierkontrollen sollen akut vorliegende Probleme erkannt und beseitigt werden, das heißt der Schwerpunkt liegt auf dem unverzüglichen Einleiten von Maßnahmen. Dies können sofortige Behandlungen, Separierungen von einzelnen kranken Tieren oder notwendige Tötungen verletzter Tiere sein. Aber auch das Hinzuziehen eines Tierarztes oder Reparaturen innerhalb der Anlagen wie beispielsweise der Futter- und Wasserversorgung oder der Lüftungsanlagen zählen dazu. Bei der betrieblichen Eigenkontrolle soll jedoch durch die regelmäßige Erhebung und Auswertung der Tierschutzindikatoren eine mittel- und langfristige betriebliche Entwicklung des Betriebs hinsichtlich der Situation des Tierwohls beurteilt werden. Es ermöglicht so, ergriffene Maßnahmen bezüglich ihrer Effektivität über einen gewissen Zeitraum zu beurteilen und auf diese Weise das Bestandsmanagement zu steuern (KTBL, 2016).

2.1.7 Strukturwandel in der Landwirtschaft und ihre Folgen

Der Wandel der Betriebsstrukturen innerhalb der Landwirtschaft trägt dazu bei, dass sich die Rolle der Verantwortung gegenüber der Überwachung der Tiergesundheit stark verändert. So ist beispielsweise die Anzahl der Schweine haltenden Betriebe zwischen 2010 bis 2019 um 35 % gesunken. Zwar sind es weniger vorhandene Betriebe, doch die Anzahl der Tiere insgesamt blieb gleich. Dies erfordert mehr Personal oder weitere Hilfsmittel, wie zum Beispiel den Einsatz von Sensoren und anderer Technik, um der Aufgabe der Tierhaltung gerecht zu werden. Auch bei Rindern haltenden Betrieben ist dieser Trend zu beobachten (Destatis, 2020). Dies hat zur Folge, dass sich der Nutztierhalter und die Tiere voneinander entfernen, da auf eine Person noch mehr Tiere kommen, für die er Sorge zu tragen hat (Norton, Chen, Larsen, & Berckmans, 2019). Der Beobachtungsgrad verringert sich, die Häufigkeit des Kontakts zwischen Mensch und Tier wird folglich weniger (Buller, Blokhuis, Lokhorst, Silberberg, & Veissier, 2020). Durch die zunehmende Anzahl von Tieren ist es also noch schwieriger geworden, das Verhalten und die Gesundheit der Nutztiere zu überwachen (Berckmans, 2017). Nicht verwunderlich erscheint es dann, dass die Wochenarbeitszeit von Landwirten deutlich höher als in anderen Sektoren ist (Destatis, 2018). Weitere Folgen sind, dass Burnout in der Landwirtschaft zu einem Problem geworden zu sein scheint und die Suizidrate bei Landwirten höher als im Durchschnitt der Bevölkerung ist (BLE, 2021; Hoffmann, 2020; Zinke, 2019).

2.1.8 Digitalisierung als Ausweg

Aus einer Umfrage von 500 Betrieben nutzen bereits etwa 82 % der landwirtschaftlichen Betriebe Smart-Farming-Technologien. Der Einsatz von Fütterungsautomaten und intelligenten Fütterungssystemen liegt bei 46 %, wonach dieser Teil der Tierhaltung am weitesten digitalisiert und automatisiert ist. Farm-/Herdenmanagement-Systeme nutzen 40 % der Befragten,

weitere 24 % planen oder diskutieren den Einsatz derer. Hierbei ist ein deutlicher Trend bei größeren Betriebsstrukturen ab 100ha zu verzeichnen, wonach 91 % schon digitale Technologien nutzen. Der Fokus von zukünftigen Investitionen liegt auf teilflächenspezifischer Applikationen mit 41 %, Sensortechnik mit 38 % und der Einsatz von künstlicher Intelligenz bei 35 % (Rohleder, Krüsken, & Reinhardt, 2020)

2.2 Monitoring Systeme

2.2.1 Tierbeobachtung durch geschultes Personal

2.2.1.1 Rind

Die grundlegendste Möglichkeit und gesetzliche Forderung die Tiergesundheit und das Tierwohl auf landwirtschaftlichen Betrieben zu erheben und zu bewerten, stellt die visuelle Tierbeobachtung durch entsprechend geschultes Personal dar (TierSchG, 2020; TierSchNutzTV, 2021). Hilfestellung für die dafür zu erhebenden Daten geben die im Unterkapitel 2.1.5 genannten Quellen für die Praxisleitfäden. Gesunde Tiere erbringen gute Leistungen und sichern so die Wirtschaftlichkeit von Betrieben (LfULG, 2013). Der moderne Tierhalter führt eine anspruchsvolle Tätigkeit aus, die umfangreiches Wissen über landwirtschaftliches Management und Tierhaltung erfordert. Es besteht die Möglichkeit, dass aufgrund von Betriebsvergrößerungen und der steigenden Arbeitsbelastung sowohl die Tierhalter als auch ihre Berater Gefahr laufen, den Fokus auf das Wohlergehen der Tiere in ihren Betrieben zu verlieren. Folglich fehlt oft die Zeit für eine gute Beobachtung, wodurch deren Qualität sinkt. Auch Betriebsblindheit stellt eine bedeutende Gefahr für den Landwirt dar, da sie das Potenzial birgt, offensichtliche Hinweise auf Probleme zu übersehen (Hulsen, 2021).

Ein Beispiel ist die visuelle Brunstbeobachtung. Sie gilt als klassische Form der Brunsterkennung, wobei der Erfolg dieser Methode stark von der Erfahrung des Beobachters, der Häufigkeit und Dauer der täglichen Beobachtungsphasen, technologischen Einflüssen, dem Gesundheitszustand der Herde sowie dem Anteil der Tiere, die gleichzeitig brünstig sind, beeinflusst wird (Heuwieser & Mansfeld, 1995; Nebel, Dransfield, Jobst, & Bame, 2000; Roelofs, van Eerdenburg, Soede, & Kemp, 2005; Sveberg et al., 2011; Van Eerdenburg, Karthaus, Taverne, Merics, & Szenci, 2002). Auch der Zeitpunkt der Tierbeobachtung spielt eine wichtige Rolle. So beeinflussen beispielsweise häufige Arbeiten im Stall wie Füttern, Melken und Umtreibevorgänge das Brunstverhalten der Tiere (Pennington, Albright, & Callahan, 1986). Vor dem Melken werden beispielsweise schlechtere Beobachtungsergebnisse erzielt, als nach dem Melken (Van Vliet & Van Eerdenburg, 1996). Weiterhin sind eine fehlerfreie Identifikation der Tiere, Kenntnisse über Brunstsymptome und das Verhalten der Tiere für eine effektive Brunsterkennung und korrekte Interpretation des Geschehens Grundvoraussetzung. Zudem sind Motivation, Verantwortlichkeit und persönliche Einstellung des Beobachters Faktoren, die

den Erfolg der visuellen Brunstbeobachtung beeinflussen können (Diskin & Sreenan, 2000; Nebel et al., 2000; Roelofs et al., 2005).

Die Häufigkeit und Länge der Beobachtung sind relevant für den Brunsterkennungserfolg. So können bei drei Beobachtungen zu je 30 Minuten pro Tag 86 % der brünstigen Tiere erkannt werden, während zwei Beobachtungen zu je 30 Minuten pro Tag schon 23 % weniger, also 63 % brünstige Kühe identifiziert werden (Van Eerdenburg et al., 2002; Van Vliet & Van Eerdenburg, 1996). Eine Beobachtungslänge von 30 statt 20 Minuten wirkt sich erfolgreich auf die Brunsterkennungsrate aus (Van Vliet & Van Eerdenburg, 1996), während sich eine Erhöhung der einzelnen Beobachtungsdauer von 30 Minuten oder eine Gesamtbeobachtungszeit von über 90 Minuten am Tag sich nicht positiv auf die Brunsterkennungsrate auswirkt (Pennington et al., 1986). In der Praxis hat sich allerdings gezeigt, dass durch Probleme wie Zeitmangel nur 40 – 60 % aller brünstigen Kühe erkannt werden (Firk, Stamer, Junge, & Krieter, 2002; Liu & Spahr, 1993). Auch die Fakten, dass hochleistende Kühe immer weniger Anzeichen von Brunst zeigen und die Brunst häufig in der Nacht stattfindet, erschweren die Brunsterkennung durch geschultes Personal. Über 70 % der Tiere beginnen mit der Brunst in der Nacht (Weiß, Pabst, Strack, & Granz, 2005). Wie bereits in Unterkapitel 2.1.7 dargestellt erschweren steigende Herdengrößen bei begrenzt vorhandener Zeit die Brunsterkennung. Neben der visuellen Möglichkeit gibt es eine Reihe technischer Methoden, die es ermöglichen Brunsten zu erkennen. Nachfolgend sind einige zum Vergleich tabellarisch aufgeführt.

Tabelle 1 Methoden der Brunsterkennung und deren Erkennungsraten, verändert nach Becker, Kanitz, and Heuwieser (2005); Holman et al. (2011); Zieger (2004).

Methoden	Anteil richtig erkannter Brunsten (%)
Estrus Alert	70
Heat- Mount Detector (KaMaR®)	61 - 87
Videoanalyse	75 - 80
Heat Watch®- System	90 - 98
DEC TM - System	90
Bewegungsaktivität (Pedometer (SAE Afikim) o. Neck Collar (Heatime®, SCR Engineers)	55 - 95
Neck Collar (Heatime®, SCR Engineers) + visuelle Brunstbeobachtung	75
Pedometer (SAE Afikim) + visuelle Brunstbeobachtung	74
Neck Collar (Heatime®, SCR Engineers) + KaMaR®	76
Pedometer (SAE Afikim) + KaMaR®	76

2.2.1.1.1 Die gesunde Kuh

Eine gesunde Kuh ist aufmerksam und aktiv. Sie betrachtet ihre Umwelt aufmerksam und kann tun, was sie will. Auf Geräusche und andere Reize reagiert sie neugierig und hat lebhaftes Augen und spielende Ohren. Ihr Fell ist sauber und glänzt, liegt an und ist frei von Verletzungen. Eine Kuh, die sich wohlfühlt, frisst und trinkt gut, was sich an der Pansen- und Bauchfüllung erkennen lässt. Wenn sie sich bewegt oder steht, sieht man keine Anzeichen von Schmerzen, ihr Rücken bleibt in der Bewegung gerade, der Kopf ist nicht gesenkt. Sowohl beim Gehen als auch Stehen zeigt sie keine Entlastungsbewegungen (Hulsen, 2021).

2.2.1.2 Objektivierbare Parameter zur Beurteilung des Tierwohls von Rindern (Tierwohlindikatoren)

2.2.1.2.1 Körperkonditionsbeurteilung

Mit der Körperkonditionsbeurteilung oder dem BCS (body condition scoring) schätzt man die Unterhautfettauflage im Beckenausgang, an den Hüften und den Lenden einer Kuh subjektiv ein. Somit ist es möglich, über- und unterkonditionierte Tiere in der Herde ermitteln zu können. Dies zeigt, ob die Nährstoffversorgung der Tiere bedarfsgerecht ist oder angepasst werden muss. Die Veränderungen selbst finden über Wochen und Monate statt. Die Konditionsnote steigt, wenn die Kuh zu viel Energie bekommt und fällt, wenn sie in ein Energiedefizit gesetzt wird. Die Noten reichen dabei von 1 bis 5. Eine sehr dünne Kuh erhält die Note 1, eine verfettete Kuh bekommt die Note 5. Die Noten 2 bis 4 erhalten die Kühe, welche sich dazwischen befinden. Überkonditionierte Kühe sind anfälliger für Geburtsschwierigkeiten, Stoffwechsel- und Fruchtbarkeitsstörungen. Zudem läuft eine fette Kuh Gefahr, dass sie um die Geburt herum und zu Beginn der Laktation zu wenig frisst. Eine zu magere Kuh besitzt wenig Abwehrkraft und ist anfälliger für Krankheiten, da sie sich in einer Energiemangelsituation befindet. Unterkonditionierte Kühe können zu Laktationsbeginn zu viel Körpersubstanz abgebaut und gleichzeitig über längere Zeiträume nicht genügend Futter aufgenommen haben. Durch die zu starke Abmagerung kommt es zu Fruchtbarkeitsproblemen, die durch Eierstockzysten, inaktive Eierstöcke, mangelnde Brunstabzeichen, sowie eine schlechte Qualität des Gelbkörpers entstehen. Die optimale Bandbreite des BCS liegt zwischen 2,5 und 3,5. Zu Beginn der Laktation ist es akzeptabel, dass die Konditionsnote auf 2,3 fallen kann, da die Kuh in den ersten 100 Tagen eine stark negative Energiebilanz aufweist und Körpersubstanz abbaut. Im Laufe der Laktation sollte der Wert aber wieder in den Normbereich kommen (Büscher et al., 2021; Hulsen, 2021; KTBL, 2016).

2.2.1.2.2 Pansenbeurteilung

Um die Futteraufnahme und Passagegeschwindigkeit der letzten Stunden bewerten zu können, beurteilt man die Pansenfüllung. Man beurteilt sie als Routine in der täglichen oder wöchentlichen Kontrolle oder wenn es einen Anlass gibt. Dabei steht man links hinter der Kuh

und betrachtet die Haut an den Querfortsätzen, die Hautfalte beim Hüftbeinhöcker und die Hungergrube hinter dem Rippenbogen. Gleich wie bei der Konditionsbeurteilung werden auch hier 5 Noten vergeben. Anders ist jedoch, dass eine Kuh je nach Stadium eine unterschiedlich erwünschte Pansennote aufweisen sollte. Optimal bei laktierenden Kühen sollte die Haut über den Querfortsätzen zuerst eine Handbreite senkrecht nach unten verlaufen und dann nach außen abbiegen. Die Hautfalte vor dem Hüftbeinhöcker sollte nicht zu sehen sein, die Hungergrube ist jedoch noch sichtbar. Die erwünschte Pansennote liegt bei 3. Ist die Kuh jedoch kurz vor Ende der Laktation, sollte keine Hungergrube mehr zu sehen sein und die Haut über den Querfortsätzen biegt dann direkt nach außen ab. Sie bekommt die Pansennote 4. Die Pansennote 5 ist lediglich für trockenstehende Kühe erwünscht. Dabei sind die Querfortsätze aufgrund des gut befüllten Pansens nicht mehr sichtbar und die gesamte Bauchhaut ist rund gespannt. Ein Übergang von der Flanke zu den Rippen sollte nicht mehr zu sehen sein. Die Pansennote 1 bekommen Kühe, bei denen die Hungergrube mehr als eine Handbreit tief eingefallen ist und die Haut schon unter den Querfortsätzen anliegt. Eine Kuh mit dieser Pansennote ist entweder krank, die Futterverfügbarkeit ist mangelhaft oder das Futter an sich ist schlecht. Jedenfalls hat solch eine Kuh sehr wenig oder nichts gefressen. Bei der Pansennote 2 liegt die Haut ebenfalls unter den Querfortsätzen an, die Hungergrube ist etwa eine Handbreit tief und bildet ein Dreieck. Häufig sehen Kühe nach der ersten Woche der Geburt so aus. Wenn sich dieser Zustand im Laufe der Laktation nicht ändert, signalisiert es eine ungenügende Futteraufnahme oder zu hohe Passagegeschwindigkeit. Die Verdauungs- und Passagegeschwindigkeit hängt von den Futtereigenschaften, ob sie im Pansen leicht oder schwer abbaubar sind, der Futterstruktur und dem Verhältnis der Nährstoffe im Pansen ab (Hulsen, 2021).

2.2.1.2.3 Kotbeurteilung

Einen Schritt danach stellt der Kot den Spiegel der Verdauung dar. Anhand dessen Beurteilung erhält man einen Eindruck hinsichtlich der Ausgewogenheit des Futters. Wichtig dabei sind die Konsistenz und der Verdauungsgrad. Das Verhältnis von Wasser zu Feststoffen stellt die Konsistenz dar. Enthält das Futter zu viele unverdauliche Teile, werden diese mit viel Flüssigkeit aus dem Dünndarm gespült. Andere Gründe für sehr flüssigen Kot können Giftstoffe oder zu viele Mineralstoffe sein. Den Verdauungsgrad beurteilt man durch Beschauen und Erfühlen von unverdauten Futterresten. Grundsätzlich sollte das Futter vollständig abgebaut sein. Das, was nicht verdaut wurde, ist entweder nicht verdaubar oder hatte durch ein nicht stimmiges Eiweiß-Energieverhältnis zu wenig Zeit, um verdaut zu werden. Zwischen der Futteraufnahme und dem Kotabgang liegen etwa anderthalb bis drei Tage. Für die Beurteilung von frischem Kot werden ebenfalls 5 Noten vergeben, dabei gilt je kleiner die Note, desto besser. Gut verdauter Kot glänzt und ist homogen. Es sind keine unverdauten Futterreste zu finden. Je matter und heterogener der Kot wird, umso schlechter wurde verdaut. Die Konsistenz optimalen Kots

lässt sich durch eine Stiefelprobe durchführen. Bleibt kein Sohlenprofil zurück und wird der Stiefel nicht vom Kot angesaugt ist er ideal und die Ration wird gut verdaut (Hulsen, 2021).

2.2.1.2.4 Lahmheit

Lahmheiten sind Störungen des Gangbildes und lassen sich in Stützbein- und Hangbeinlahmheit unterteilen und haben verschiedene Ursachen. Bei der Stützbeinlahmheit hat die Kuh Schmerzen in Gelenken, Knochen oder den Klauen. Die Bewegung an sich schmerzt nicht, die Belastung jedoch schon. Anders ist es bei der Hangbeinlahmheit, wo sich die Schmerzen in Sehnen und Muskeln befinden und die Bewegung schmerzt, nicht jedoch die Belastung. Das Tier versucht das Bein so wenig wie möglich zu bewegen. Wie in den vorangegangenen Indikatoren sind hier 5 verschiedene Bewegungsscores vorhanden. Bewegungsscore 1 stellt das Optimum dar. Verglichen wird dabei der Rücken sowohl im Stand als auch beim Laufen. Eine gesunde Kuh hat den Rücken sowohl beim Laufen und Stehen flach und waagrecht und setzt alle Klauen gleichmäßig sicher auf. Beim Gang setzen sich die Hinterklauen in die Spuren der Vorderklauen. Je gekrümmter der Rücken im Stehen und Laufen ist, desto schlechter der Bewegungsscore. Beim Laufen werden mit einem oder mehreren Beinen verkürzte Schritte gemacht, Klauen werden beim Auftreten deutlich geschont oder das Bein wird gar nicht belastet und die Kuh hinkt. Häufig bleiben solche Kühe liegen und haben große Schwierigkeiten aufzustehen. Folglich haben lahme Kühe nicht nur Schmerzen, auch der Zugang zu Wasser und Futter sind deutlich erschwert, wodurch die Milchleistung und Fruchtbarkeit dieser Kühe geringer ausfällt. Wichtige Risikofaktoren sind der Liegebereich durch Überbelegung, harte Liegeflächen, unpassende Liegeboxenmaße, aber auch rutschige, unebene, verschmutzte und feuchte Laufflächen. Weiterhin können Stoffwechselstörungen durch Fütterungsfehler wie Pansenübersäuerung, Eiweißüberschuss und Mineralstoffmangel oder eine unregelmäßige, schlechte und fehlende Klauenpflege zu Lahmheiten führen. Überwiegend gehen Lahmheiten von Klauenerkrankungen oder Infektionen der Haut am Unterfuß oder Gelenksveränderungen aus (Hulsen, 2021; KTBL, 2016).

2.2.1.2.5 Klauenzustand

Mängel an den Klauen lassen Rückschlüsse auf den Pflegezustand der Tiere zu. Dies können übermäßig lange Klauen, Verletzungen und Überwachungen des Wandhorns sein. Die Folgen können Fehlstellungen und dadurch eine unphysiologische Gewichtsverteilung, ein verändertes Gangbild und Beeinträchtigungen des Verhaltens wie im Unterkapitel 2.2.1.2.4 beschrieben sein. Ein schlechter Klauenzustand beeinflusst das Wohlbefinden der Kühe und begünstigt Klauenerkrankungen. Klauenfäule beispielsweise verändert die Klauenstellung, da die Außenklaue schneller wächst als die innere Klaue. Die Ursachen für kranke Klauen liegen häufig an Bakterien, schlechten Abwehrkräften, nicht wiederkäuergerechter Fütterung und Giftstoffen, welche in den Kreislauf gelangen und die kleinen Blutgefäße in den Klauen und

Gelenken schädigen. Weitere Gründe sind eine zu schnelle Futterumstellung und Verletzungen wie Quetschungen der Klaue mit folgenden Entzündungen. Begründet sind die Probleme zumeist im Klauenpflegemanagement, den Umweltbedingungen im Stall wie zu nasse und verdreckte Böden, sie können aber auch genetisch bedingt sein (Hulsen, 2021; KTBL, 2016).

2.2.1.2.6 Verschmutzung der Tiere

Der Verschmutzungsgrad der Tiere gibt den Hygienezustand des Betriebes wieder. Je schmutziger die Kühe sind, desto größer ist das Risiko von Euter- und Hautinfektionen. Das Wohlbefinden kann durch einen hervorgerufenen Juckreiz vermindert werden und die darunter liegende Haut kann sich entzünden. Zudem ist die Thermoregulierung durch Verdreckung gestört. Steigt die Verschmutzung, nehmen auch die Zellzahlen in der Milch zu. Die Schwachstellen liegen häufig in der Haltung und dem Management. Wichtige Faktoren, die zur Lösung beitragen können, sind ein gutes Stallklima, eine wiederkäuergerechte Fütterung, richtige Maße der Liegeboxen und die Sauberkeit von Laufgängen. Auch die passende Art und Menge der Einstreu spielen eine Rolle (Dahlhoff, 2020; Hulsen, 2021; KTBL, 2016).

2.2.1.2.7 Integumentschäden

Schäden an der Haut wie zum Beispiel Schwellungen und frische oder verkrustete Wunden bedeuten Schmerzen für das Tier und können der Eingang für Infektionen sein. Gelenkveränderungen können sich dabei auch zu Lahmheiten entwickeln. Die äußere Haut ist die Schnittstelle vom Tier zu der Umwelt, die sie umgibt und zeigt dadurch, wie erfolgreich sich die Tiere mit der direkten Einwirkung von Haltungstechnik und sozialem Umfeld der anderen Tiere auseinandersetzen können. Die meisten Schäden entstehen an den Sprunggelenken und Vorderfußgelenken und sind meist auf eine nicht tiergerechte Liegefläche zurückzuführen. Das heißt, dass die Liegeflächen nicht weich genug, verformbar, sauber und trocken sind. Schäden am Nacken oder am Hals liegen häufig an nicht angepasste Fressgitterhöhen für die Herde oder schlecht eingestellte Nackenbügel in den Liegeflächen (KTBL, 2016).

2.2.1.2.8 Liegeplatznutzung

Kühe liegen normalerweise etwa 10 bis 14 Stunden am Tag. Denn das Liegen ist für die Tiere sehr wichtig. Sie können sich ausruhen, die Klauen, welche das gesamte Gewicht tragen müssen, können sich erholen und abtrocknen. In den Laufgängen ist mehr Platz für den Kuhverkehr und weniger Gedränge. Ein weiterer Vorteil ist, dass 30 % mehr Blut durch das Euter fließt und mehr Milch produziert wird. Ist der Komfort nicht optimal, werden die Liegeflächen erst dann genutzt, wenn die Tiere wirklich erschöpft sind, anschließend bleiben sie aber zu lange liegen. Folglich fressen und trinken sie weniger, das Risiko selektiver Futteraufnahme erhöht sich. Durch das zu lange liegen entstehen eher körperliche Probleme wie dicke Sprunggelenke. Behindert die Boxenkonstruktion die Tiere beim Hinlegen und Aufstehen, bleiben die Kühe zu lange vor oder auf der Liegefläche stehen und weisen häufiger Verletzungen an den

Vorderknien und Sprunggelenken vor. Eine optimale Box ermöglicht einer Kuh das Hinlegen innerhalb kürzester Zeit ohne Absichtsbewegungen, die nicht ausgeführt werden, weil sie etwas hindert oder stört. Auch das normalerweise flüssige Aufstehverhalten muss durch eine optimale Box gewährleistet sein, ohne dass die Tiere überfordert und unsicher sind. Die Liegeplatznutzung lässt also Rückschlüsse auf die Anzahl, Verfügbarkeit, Qualität und Dimensionierung der Liegeboxen zu. So kann beispielsweise eine Nichtnutzung der Liegeflächen und gleichzeitiges Stehen oder Warten vieler Tiere im Laufgang darauf hindeuten, dass die Liegeplätze nicht optimal gestaltet sind, was zu einer mangelnden Akzeptanz und zu reduzierten Liegezeiten führt. Sollten Milchkühe drei Stunden nach der Futterablage noch nicht liegen, kann es auf eine zu geringe Anzahl von Fressplätzen hindeuten, da noch nicht jede Kuh fressen konnte. Kühe mit nur zwei Beinen in der Box können auf eine nicht angepasste Nackenrohrbegrenzung hindeuten. Andere Tiere, die mit allen vier Beinen in der Box stehen, sich aber nicht hinlegen, können auf Schwächen der Liegeflächenqualität aufzeigen. Indikatoren für Fehleinstellungen der Boxeneinrichtungen können Kühe sein, die nur halb oder schräg in der Box liegen (Hulsen, 2021; KTBL, 2016).

2.2.1.2.9 Ausweichdistanz

Der Mensch hat durch den täglichen Umgang einen erheblichen Einfluss auf die Tiere. Um die Qualität der Mensch-Tier-Beziehung zu beurteilen ist die Ausweichdistanz ein guter Indikator für die Furchtreaktion der Tiere vor dem Menschen. Deshalb gilt, je näher ein Mensch sich einem Tier nähern kann, desto besser ist die Beziehung. Lauter, grober, hektischer und überraschender Umgang ist negativ und kann zu Schäden, Schmerzen und chronischem Stress führen. Zudem entwickeln die Tiere ein negatives Verhalten gegenüber dem Menschen, was sich letztlich auf die Gesundheit und Leistung der Tiere auswirkt (KTBL, 2016).

2.2.1.2.10 Wasserversorgung

Eine sichere Wasserversorgung und ein unbeschränkter Zugang sind entscheidend für das Wohlbefinden der Tiere und die Vermeidung von Leistungseinbußen und Krankheiten. Eine Kuh braucht 5 Liter Wasser um 1 kg Trockenmasse aufnehmen zu können. Dafür ist es wichtig, eine ausreichende Anzahl an korrekt installierten und frostsicheren Tränkeplätzen mit angemessener Dimensionierung der Anschlüsse bereitzustellen. Als Faustregel gelten etwa 20 Tiere für eine große Tränke. Korrosion und Ablagerungen können die Wasserdurchflussrate beeinträchtigen. Daher sollte im Rahmen der betrieblichen Eigenkontrolle regelmäßig die Funktionssicherheit der Tränken überprüft werden. Es ist wichtiger, genügend Tränkestellen für alle Tiere bereitzustellen, anstatt sich nur auf die Gesamtlänge der Tränken zu konzentrieren, da ranghohe Tiere den Zugang blockieren können. Defekte Tränken sollten sofort repariert, falsch dimensionierte Leitungen zeitnah ausgetauscht und fehlende Tränken ergänzt werden. Die Wasserversorgung sollte täglich routinemäßig überprüft werden, einschließlich der

visuellen Beurteilung von Verschmutzungen an Tränken und der Sauberkeit des Wassers. Bei wiederholter Verschmutzung sollte die Positionierung der Tränke überprüft werden (Hulsen, 2021; KTBL, 2016).

2.2.1.2.11 Schwergeburten

Schwergeburten sind mit langanhaltenden Schmerzen und verschiedenen Risiken für Kuh und Kalb verbunden. Milchleistung, Fruchtbarkeit und Tiergesundheit werden beeinträchtigt. Risikofaktoren sind Färsenkalbungen, Zwillingsgewürten, hohe Kälbergewichte und bestimmte Rassen. Fehler bei der Bullenauswahl, Bewegungsmangel und Verfettung während der Trächtigkeit tragen ebenfalls zum Risiko bei. Bei zunehmenden Herdengrößen kann die Aufmerksamkeit für schwierige Geburten verringert sein. Es wird die Anzahl von Schwergeburten erfasst, die definiert sind als Kaiserschnitt, tierärztliche Assistenz, Einsatz eines mechanischen Geburtshelfers oder Zughilfe durch mehrere Personen. Aus der Dokumentation heraus, sollten Maßnahmen erstellt und durchgeführt werden, um die Risiken von Schwergeburten zu reduzieren (KTBL, 2016).

2.2.1.2.12 Nutzungsdauer

Eine lange Nutzungsdauer ist ein indirekter Indikator für Tiergesundheit und wirtschaftlich interessant, vorausgesetzt, andere Gesundheitsindikatoren sind in Ordnung. Kühe erreichen ihr maximales Milchleistungsniveau in der 5. Laktation und halten es für mehrere Laktationen. Strategische Managemententscheidungen des Tierhalters und Verkauf junger Kühe als Zuchttiere oder für die Fleischnutzung können die Nutzungsdauer beeinflussen. Eine Remontierungsrate von über 30 %, viele Krankheitsfälle, zu niedrige Leistung bei älteren Kühen und eine damit verbundene kurze Nutzungsdauer können auf eine schlechte Immunabwehr der Herde hinweisen. Die Nutzungsdauer allein ist jedoch kein aussagekräftiger Indikator für das Tierwohl. Dafür wird das Abgangsalter aller Kühe erfasst, mit Ausnahme der Kühe, die auf anderen Betrieben durch beispielsweise Verkauf oder Zucht weiter genutzt werden. Die Nutzungsdauer kann aus den verfügbaren Kalbe- und Abgangsdaten in verschiedenen Datenbanken wie MLP, HI-Tier oder den Jahresberichten der LKV oder des VIT berechnet werden. (Hulsen, 2021; KTBL, 2016).

2.2.1.2.13 Tierverluste

Tierverluste umfassen verendete, notgetötete und euthanasierte Tiere. Sie sind abhängig vom betrieblichen Management und haben sowohl Tierschutz- als auch wirtschaftliche Bedeutung. Unfälle, Produktionskrankheiten, Lahmheiten und infektiöse Erkrankungen sind die Hauptursachen. Rasse, Herdengröße und Weidegang können ebenfalls Einfluss auf die Tierverluste haben. Hierzu wird die Mortalitätsrate berechnet (KTBL, 2016).

2.2.1.3 Schwein und Geflügel

Wie bereits im Unterkapitel 2.2.1.2 die Tierwohlindikatoren für das Rind aufgeführt wurden, sind für das Schwein und Geflügel sehr ähnliche objektivierbare Parameter zur Beurteilung des Tierwohls vorhanden. Sie können sinngemäß auch auf das Schwein und Geflügel übertragen werden (KTBL, 2016, 2020a, 2020b). Bis auf einige Ausnahmen wie Anzeichen von Ektoparasiten bei Schweinen, oder der Fokus auf den Verlauf der Legeleistung von Hennen und die äußere Eiqualität, woraus sich Haltungs- und Fütterungsprobleme erklären lassen, ähnelt sich die Herangehensweise zur Kontrolle der Tiergesundheit und des Tierwohls zum Rind (KTBL, 2016, 2020a, 2020b)

2.2.2 Sensor gestützte Systeme in Tierhaltungen

Sensortechnologien kommen in der Tierhaltung in Stallungen aber auch in der Weidewirtschaft zum Einsatz. Hier lassen sich drei verschiedene Anwendungsgebiete nennen. Zum einen geht es um das Herdenmanagement der Tiere durch die Einzeltierbeobachtung, aber auch um Melk- und Fütterungsprozesse und die Regelung des Stallklimas (Kehl, Meyer, & Steiger, 2021). Während Sensoren für Stallklima und Lichtmanagement dem gesamten Bestand dienen, ermöglichen spezielle Sensoren ein Monitoring des Einzeltieres. Als Standard gelten die Identifizierung des einzelnen Tieres, dessen Aktivität, sowie das Bewegungsprofil und das Fressverhalten (dlg, 2018). Seit den 1980er Jahren werden Sensoren für die Milchviehhaltung entwickelt und sind in diesem Bereich am weitesten entwickelt (Kehl et al., 2021; LfL, 2023). Sensoren revolutionieren die Tierbeobachtung in einer Art und Weise, wie sie bisher noch nicht dagewesen ist. Durch die Anwendung liegen plötzlich mehr und gültige Informationen vor als vorher. Insbesondere für einzelne Tiere. Die angewendeten Systeme sind von ihrer Leistungsfähigkeit unschlagbar, selbst sehr erfahrene Tierhalter können hier nicht Schritt halten. Herannahende Erkrankungen können bis zu 8 Tage vor irgendwelchen Symptomen unspezifisch erkannt werden. Die Sensoren erheben Vitalparameter rund um die Uhr, was ein Mensch nicht in der Lage wäre durchzuführen (Fasching & Gasteiner, 2021). Die am oder im Tier gemessenen Werte werden an ein Empfängergerät gesendet und von dort aus zumeist an einen zentralen Computer des Betriebes übertragen. Dort erfolgt die Auswertung der zusammengeführten Sensordaten durch ein Herdenmanagementprogramm. Auffallende Verhaltensweisen können durch den Abgleich früherer und aktuellen Daten erkannt und in Echtzeit über eine Benachrichtigung auf unterschiedlichsten Endgeräten visualisiert werden (Kehl et al., 2021).

Zudem sind Sensoren ein wichtiges Element in der Automatisierung der Melk- und Fütterungsprozesse. So können sie etwa Melkvorgänge steuern und Milchmenge und -qualität durch Bestimmung der Farbe und elektrischer Leitfähigkeit der Milch kontrollieren. Hinsichtlich des Stallmanagements kommen andere Sensoren zum Einsatz, wie beispielsweise Temperatursensoren zur Temperaturkontrolle in Ställen, zur Steuerung der Trinkwassertemperatur in der Geflügelhaltung oder auch chemische Sensoren, die Schadgaskonzentrationen in Geflügel-

oder Schweineställen erfassen. Die Messwerte der Sensoren werden meist fortlaufend mit vorher definierten Zielwerten verglichen und durch entsprechende Regelungs- und Steuerungstechnik in den gewünschten Zielzustand gebracht (Kehl et al., 2021). Folgend sollen die vorhandenen Sensoren aufgezeigt und ihre Anwendungsbereiche dargestellt werden.

2.2.2.1 Rind

2.2.2.1.1 Positionssensoren

Mit Positionssensoren werden die Bewegungen und die Position eines Rindes ermittelt (Kehl et al., 2021). Auch kann damit erfasst werden, wie viel sich ein Tier bewegt (Büscher et al., 2021). Sie helfen bei der Analyse von Verhaltensweisen und erleichtern eine Identifikation und Lokalisierung des Tieres bei einer Alarmmeldung sowohl im Stall als auch auf der Weide. Sensoren in Ohrmarken oder an Halsbänder senden zusammen mit der Tiererkennung Signale, die von mehreren Empfängergeräten im Stall aufgenommen und mittels Triangulation die Position in Echtzeit der Tiere bestimmen (Kehl et al., 2021). Kühe können mittels passiver Ohrmarken und auf Basis vorher definierten Zonen im Stall geortet werden. Anhand von Zonenwechseln kann das Verhalten der Kühe abgeleitet und festgestellt werden. Um diese Daten zu erhalten wird der Abstand zwischen der Leseantennen und dem Transponder des einzelnen Tieres erfasst und ausgewertet (Büscher et al., 2021).

2.2.2.1.2 Bewegungssensoren/Aktivitätssensoren

Mit Bewegungs- oder Beschleunigungssensoren können verschiedene Bewegungsmuster von Tieren aufgezeichnet werden (Neethirajan, Tuteja, Huang, & Kelton, 2017). Die Messung der Bewegungsaktivität kann durch verschiedene Sensoren erfolgen. Zum einen können die Anzahl der Bewegungsimpulse in Form von Schrittzahlen gemessen und bewertet werden. Dies erfolgt über ein am Fuß angebrachtes Pedometer. Zum anderen messen Bewegungssensoren am Halsband, in den Ohrmarken oder am Ohr, am Schwanzansatz oder im Pansen mithilfe eines Drei-Achsen-Systems die Bewegungsart und können so typische Bewegungsmuster erkennen. Mithilfe von Beschleunigungssensoren können die Rechts-Links-Bewegungen des Kopfes und dessen Haltung beim Fressen erfasst werden. Aus den gesammelten Daten werden für die einzelnen Tiere gleitende Mittelwerte ermittelt, um für jede Kuh ein normales Bewegungsmuster zu erstellen, wodurch Abweichungen erkannt werden können (Büscher et al., 2021; Kehl et al., 2021).

2.2.2.1.3 Drucksensoren

Ein Drucksensor, der am Nasenband eines Halfters angebracht ist, kann die Nahrungsbisse durch Dehnung und Stauchung auf einem Dehnungsmessstreifen erfassen (Kehl et al., 2021). Der Sensor wandelt dabei die mechanische Größe Druck in ein verhältnismäßiges elektronisches Signal um (Gries & Gassmann, 2009).

2.2.2.1.4 Akustische Sensoren

Anhand von akustischen Sensoren werden Signale wie Beißen und Kauen erkannt. Das Erkennen von Auffälligkeiten bei Wiederkäuern hilft bei der Gesundheitsüberwachung. Der Sensor befindet sich am Halsband der Kuh (Kehl et al., 2021; Neethirajan et al., 2017).

2.2.2.1.5 Temperatursensoren

Mittels Temperatursensoren können sowohl die äußere als auch die innere Körpertemperatur gemessen werden. Die Messung der äußeren Körpertemperatur erfolgt durch Ohrsensoren. Eine sehr präzise Messung der inneren Körpertemperatur kann durch eine Sensorkapsel im Pansen der Kuh erreicht werden. Sie liefert Informationen über den Gesundheitszustand und Phasen des Reproduktionszyklus wie Abkalbung oder Brunst (Fasching, 2016).

2.2.2.1.6 Chemische Sensoren

Sowohl in den Tieren als auch in Ställen finden chemische Sensoren Anwendung. Den Tieren können diese Sensoren als Kapsel in den Pansen gegeben werden, um den Pansen pH-Wert zu messen (Kehl et al., 2021). Allerdings sollen pH-Wert-Veränderungen zwischen 6,0 zu 7,0 nicht zuverlässig gemessen werden können und zu falschen Ergebnissen führen. Abweichungen in den anderen pH-Wert-Bereichen werden für etwa 0,2 pH-Wert-Einheiten angenommen (Jilg, Gerster, Hertel-Böhnke, & Pries, 2018). In Stallanlagen angebrachte chemische Sensoren hingegen dienen zur Erfassung von Schadgaskonzentrationen (Kehl et al., 2021).

2.2.2.1.7 Weitere Sensoren

Des Weiteren werden Leitfähigkeitssensoren, sowie Farb- oder Blutsensoren in der Milchviehhaltung eingesetzt. Diese finden vor allem bei automatischen Melksystemen Anwendung (Kehl et al., 2021).

2.2.2.1.8 Gesundheitsüberwachung

Mittels Temperatursensoren kann beispielsweise Fieber erkannt werden, was auf eine Infektion, eine Untertemperatur wie sie vor einer Abkalbung möglich ist, oder auf eine Gebärparese hinweisen, als solche erkannt und davor rechtzeitig warnen (Fasching, 2016). Bewegungssensoren die neben der Ohrtemperatur das Fress- und Wiederkäuerverhalten gleichzeitig messen, können durch diese Kombination zu präziseren und früheren Alarmen führen (Cowmanager, 2023). Ein am Fuß angebrachter Bewegungssensor, auch Pedometer genannt, kann Aktivitäten wie die Steh-, Liege- und Laufzeiten festhalten (Neethirajan et al., 2017).

2.2.2.1.9 Brunsterkennung

Die Brunsterkennung ist mit Sensoren möglich, denn brünstige Kühe zeigen im Gegensatz zu nicht brünstigen Kühen eine deutlich gesteigerte Aktivität (Fasching, 2016). Meist werden dafür mehrere Parameter aus Halsbandsensoren, Pedometer, Pansensensoren oder Ohrmarken genutzt (Fasching, Ofner-Schröck, Huber, Taferner, & Gasteiner, 2018). Dadurch lassen sich

bis zu 94 % der brünstigen Kühe identifizieren (LfL, 2023; Pfeiffer, Gandorfer, & Ettema, 2020; Pfeiffer, Gandorfer, & Wendl, 2018). Die Funktion der Brunsterkennung ist als gut bis sehr gut einzustufen. Je nach Sensor werden Rückgang der Körpertemperatur durch Temperatursensoren, eine Verminderung der Wiederkautätigkeit und Änderungen in der Bewegungsaktivität über Bewegungs- oder Beschleunigungssensoren erfasst (Kehl et al., 2021; LfL, 2023). Sie helfen, das Brunst- und Krankheitsgeschehen zu überwachen (Kehl et al., 2021). Tierhalter können mit der visuellen Beobachtung im groben Durchschnitt etwa 60 % der brünstigen Kühe erkennen. Der Erfolg der visuellen Beobachtung hängt stark von der Erfahrung und der im Stall zur Beobachtung genutzten Zeit ab und ist in Unterkapitel 2.2.1.1 näher erläutert. Je nach den Umweltbedingungen wie etwa eine rutschige Stallfläche oder Belegung kann es auch zu schlechteren Ergebnissen mit Sensoren führen, wobei die Fehler eher weniger in den Sensorsystemen zu suchen oder finden sind, sondern im Haltungssystem (Fasching & Gasteiner, 2021). Einzelne Sensoren können also auch mehrere Parameter abdecken.

2.2.2.1.10 Zeitpunkt der Abkalbung

Ein Bewegungs- bzw. Beschleunigungssensor, welcher speziell für eine Warnung einer nahenden Kalbung gedacht ist, wird wenige Tage vor der dem errechneten Abkalbetermin am Schwanzansatz der Kuh angebracht. Das Bewegungsverhalten des Schwanzes kurz vor der Geburt des Kalbes wird sich hier zu Nutze gemacht. Weitere Sensoren, die gleichzeitig auch für andere Parameter genutzt werden, können ebenfalls eine herannahende Geburt melden. Als Beispiele können hier der Pansenbolus, das Pedometer oder Sensoren am Halsband genannt werden. Je nach Sensor, wird die Senkung der Körpertemperatur, ein Rückgang des Wiederkauens und Änderungen in der Aktivität von Bewegungen erfasst, welche markante Anzeichen vor einer Geburt sind (LfL, 2023; smaXtec, 2020).

2.2.2.1.11 Überwachung der Wasser- und Futteraufnahme

Um Zeitpunkt, Häufigkeit und Dauer von der Futter- und Wasseraufnahme zu erfassen, werden akustische, Temperatur- Druck- und Bewegungssensoren eingesetzt. Dabei befindet sich der Drucksensor im Nasenband eines Halfters und zeichnet gemeinsam mit einem Bewegungssensor die Nahrungsbisse, die Kaubewegungen und die Wasseraufnahmen auf. Auch hier kann die Wiederkauaktivität gemessen werden (Ruuska, Kajava, Mughal, Zehner, & Mononen, 2015; Werner et al., 2018). Für die Aktivität des Fressverhaltens kommen Sensoren am Halsband und Pansensensoren zum Einsatz. Die Temperatursensoren im Pansen erfassen Trinkzyklen durch die bei der Wasseraufnahme entstehenden Temperaturschwankungen, wodurch sie sich überwachen lässt und atypisches Trinkverhalten aufgedeckt werden kann (Fasching, 2016; LfL, 2023). Ebenso können auch akustische Sensoren eingesetzt werden. Anhand der Identifizierung von akustischen Signalen von Beißen und Kauen lässt sich die Wiederkauaktivität bestimmen (Neethirajan et al., 2017). Das Aufdecken von Auffälligkeiten

beim Wiederkauen hilft bei der Gesundheitsüberwachung der Kühe, um rechtzeitige Diagnosen zu stellen und Behandlungen von Krankheiten einzuleiten (LfL, 2023).

Während des Wiederkauens zeigt das Ohr einer Kuh ein bestimmtes und immer wiederkehrendes Bewegungsmuster, wodurch die Wiederkauaktivität mit Hilfe eines Bewegungssensors am Ohr ermittelt werden kann. Eine verringerte Wiederkauaktivität ist ein Hinweis auf Gesundheitsprobleme (Reiter et al., 2018).

Halsbänder mit Bewegungssensoren können über die Erfassung des Hebens und Senkens des Kopfes, sowie der Kaubewegungen die Dauer der Futteraufnahme, die Wiederkäuaktivität und das Weideverhalten erfassen. (Büscher et al., 2021; Neethirajan et al., 2017).

Schließlich können mithilfe von Bewegungs- bzw. Beschleunigungssensoren im Pansen auch die Pansenmotilität erfasst werden. Das bedeutet, dass die Kontraktionssequenzen des Pansens aufgezeichnet werden und dadurch Hinweise auf die Gesundheit bezüglich des Wiederkauens und der Durchmischung des Futters gegeben werden (LfL, 2023).

2.2.2.1.12 Pansen-pH

Mithilfe von chemischen Sensoren ist es auch möglich kontinuierliche Daten bezüglich des pH-Wertes zu erlangen. Der chemische Sensor ist fähig, ein Absinken des pH-Wertes durch beispielsweise steigende Verabreichung von Kraftfutter zur Erhöhung der Milchleistung zu messen. Ein zu starkes Absinken des pH-Wertes kann eine subklinische Pansenazidose zur Folge haben, was als tiergesundheitsliches Problem in der Milchviehhaltung weitverbreitet ist (Kehl et al., 2021). Anhand der Messung der pH-Werte lassen sich durch die Historie der Daten Rückschlüsse auf die Optimalität der Futterration ziehen und somit hinsichtlich des Ziels auch anpassen.

2.2.2.1.13 Überwachung der Eutergesundheit

In einem automatischen Melksystem kann mittels eines Sensors die elektrische Leitfähigkeit der Milch gemessen werden, um frühzeitig Euterentzündungen zu identifizieren. Der Hintergrund dabei ist, dass die Milch bei einer beginnenden Mastitis mehr Natriumchlorid enthält und so die Leitfähigkeit steigt. Da sich die Leitfähigkeiten der Milch von Tier zu Tier unterscheiden, werden Vergleiche des aktuellen Werts mit den Durchschnittsdaten der letzten Tage jeder Kuh gezogen, um eben Auffälligkeiten zu erkennen (Kamphuis, Pietersma, van der Tol, Wiedemann, & Hogeveen, 2008; Wagner, 2017). Die Eutergesundheit kann zudem anhand der Milchfarbe durch einen Blut- oder Farbsensor beurteilt werden. Blut wird somit in der Milch erkannt und kann separiert werden. Weiterhin kann eine Messung der Milchtemperatur mittels Sensor zusammen mit anderen Sensoren Hinweise auf bestimmte Krankheiten geben, da die Milchtemperatur mit der Körpertemperatur der Kuh korreliert (Wagner, 2017).

2.2.2.1.14 Weitere Sensoren

Weitere Verwendungen von Sensoren findet man für den Einsatz des Stallmanagements. So kontrollieren und steuern sie beispielsweise die Beleuchtung, Belüftung, Temperaturen und Luftbelastungen. Gerade hohe Temperaturen führen bei Kühen zu Hitzestress, Kreislaufproblemen, Energiemangel, verminderter Futterraufnahme und einer geringeren Milchleistung (Eilers, 2012; Kehl et al., 2021).

2.2.2.1.15 Grenzen der Systeme

Sensorsysteme können rund um die Uhr Daten erheben. Sie können Bewegungsmuster von Tieren überwachen und Verhaltensänderungen erkennen. Auch gesundheitliche Probleme können sehr früh erkannt werden (Kehl et al., 2021). Doch bleiben sie Monitoringsysteme, welche alleinig physiologische und pathologische relevante Parameter erheben, Ergebnisse visuell darstellen und zusätzliche Informationen für das Management geben können. Bei schlechter Fruchtbarkeit, Stoffwechselstörungen, Verletzungen der Tiere oder mangelhaften Fütterungs- und Haltungsbedingungen sind die Systeme nicht in der Lage diese Probleme zu lösen oder zu kompensieren. Die daraus resultierenden Maßnahmen muss der Tierhalter noch immer selbst in die Wege leiten oder durchführen. Schließlich lässt sich sagen, dass sich die Tiergesundheit nur insofern verbessert, wie man die Daten die erhoben werden zu nutzen weiß (Fasching & Gasteiner, 2021).

2.2.2.2 Schwein

In der Schweinehaltung sind Sensorsysteme zur Erfassung einzeltierbezogener Daten im Vergleich zur Rinderhaltung nicht weit verbreitet. Die derzeit eingesetzten Sensoren in Schweineställen dienen hauptsächlich der Überwachung des Stallklimas und der Tiergruppen. Dazu zählen Parameter wie die Feuchtigkeit, Temperatur, CO₂-Gehalt und der Ammoniakgehalt in den Ställen (BigDutchman, 2017; dlG, 2018, 2022). Die Überwachung der Gruppen wird durch das Messen und Vergleichen des Wasser- und Futtermittelsverbrauchs getätigt. Einzeltierbezogene Systeme für das Fress- und Trinkverhalten wurden erfolgreich untersucht, finden in der Praxis jedoch keine Anwendung, da die Systeme nicht marktreif sind (Adrion et al., 2018; Maselyne et al., 2016). Ebenso vorhandene Aktivitätssensoren, die das Verhalten von einzelnen Schweinen ermöglichen sind vorhanden, wurden jedoch nur in Studien verwendet (Kapun, Adrion, & Gallmann, 2020; Roxell, 2020). Allerdings kommen akustische Sensoren zum Einsatz, die zur Erkennung von Atemwegserkrankungen fungieren. Spezifische Merkmale von Hustengeräuschen werden in Echtzeit mithilfe spezieller Algorithmen analysiert, um erkrankte Schweine frühzeitig zu identifizieren (Berckmans, 2014).

2.2.2.3 Geflügel

Ähnlich wie in der Schweinehaltung gibt es auch in der Geflügelhaltung bis auf die Stallsensoren nur sehr wenige einzeltierbezogene Daten mittels Sensoren. Systeme, die

einzelntierbezogene Daten erheben, finden bislang keine kommerzielle Anwendung und befinden sich in der Forschung, nicht jedoch in der Marktreife (dlg, 2018, 2022; Kehl et al., 2021). Ein Beispiel dafür sind Beschleunigungssensoren an den Beinen von Hühnern, wodurch eine Aktivitäts- und Standortbestimmung und somit eine Verhaltensforschung möglich ist. Auch Bewegungsmuster können erstellt werden, um frühzeitig Probleme zu erkennen (Fröhlich, Böck, Thurner, Weinfurter, & Wendl, 2004; Siegford et al., 2016). Auch ist es möglich das Legeverhalten von Hühnern zu überwachen (Agillox, 2023). Um das Wachstum und die Entwicklung von Hühnern zu kontrollieren werden Aufsprungwaagen verwendet, um für Gruppen das Durchschnittsgewicht zu ermitteln. Zur Steuerung des Lichtklimas werden Lichtsensoren eingesetzt (HotracoAgri, 2023a, 2023b; Toppel & Kaufmann, 2023).

2.2.3 Künstliche Intelligenz

Künstliche Intelligenz (KI) ermöglicht es Maschinen, menschliche Fähigkeiten wie logisches Denken, Lernen, Planen und Kreativität zu imitieren. Dadurch können technische Systeme ihre Umgebung erfassen, Informationen verarbeiten und Probleme lösen, um bestimmte Ziele zu erreichen. KI-Systeme können ihr Handeln anpassen, indem sie die Auswirkungen früherer Aktionen analysieren und proaktiv arbeiten, statt lediglich zu reagieren (europarl, 2020; IKS-Fraunhofer, 2023).

Verschiedene Arten von Künstlicher Intelligenz umfassen Software, wie virtuelle Assistenten, Bildanalysesoftware sowie Sprach- und Gesichtserkennungssysteme und vieles mehr. Eine andere Form ist die "eingebettete" KI, die in Robotern, Drohnen und Anwendungen des "Internets der Dinge" zum Einsatz kommt. KI-Forscher verwenden oft den Begriff der "Rationalität" anstelle von "Intelligenz", da Letzteres ein vages Konzept ist. Die Rationalität eines KI-Systems wird erreicht, indem es Daten erhält oder durch Sensoren sammelt und dann interpretiert. Darauf aufbauend entscheidet das System, welche Aktion die beste ist, um seine Ziele zu erreichen, und handelt dementsprechend. Um diese Funktionalität zu ermöglichen, benötigen KI-Systeme die Daten, sowie ein Informationsverarbeitungsmodul, das diese Daten interpretiert und entscheidet, wie darauf zu reagieren ist. Maschinelles Lernen ist eine wichtige Technik, die es KI-Systemen ermöglicht, aus Beispielen zu lernen und komplexe Aufgaben zu bewältigen, die nicht einfach durch symbolische Regeln beschrieben werden können (EuropäischeKommission, 2019).

Allerdings kann es bei einigen maschinellen Lernansätzen zu einer "Black-Box" führen, bei der die Entscheidungen nicht nachvollziehbar, dadurch undurchsichtig sind und nicht leicht erklärt werden können. Die Erklärbarkeit ist daher ein wichtiger Aspekt, der in der KI-Forschung weiter untersucht wird. Aktuelle KI-Systeme sind zielorientiert und arbeiten auf der Grundlage der Vorgaben, die ihnen von Menschen gegeben werden. Einige KI-Systeme können jedoch mehr Freiheit bei der Entscheidung haben, wie sie ihre Ziele erreichen. KI-Systeme haben die

Fähigkeit, ihr Verhalten anzupassen, indem sie analysieren, wie ihre vorherigen Aktionen die Umgebung beeinflusst haben. Diese Lernfähigkeit ermöglicht es ihnen, aus Erfahrungen zu lernen und ihre Entscheidungsfindung zu verbessern (Europäische Kommission, 2019).

Ein wichtiger Aspekt des maschinellen Lernens besteht darin, dem KI-System eine ausreichende Menge an vielfältigen und umfassenden Daten zur Verfügung zu stellen, damit es diese verallgemeinern kann. Wenn der Lernalgorithmus ausreichend trainiert ist, kann das System auch bisher unbekannte Daten gut interpretieren, beispielsweise Bilder oder Informationen, die während des Trainings nicht vorhanden waren. Maschinelles Lernen wird oft mithilfe neuronaler Netze realisiert, die von der Funktionsweise des menschlichen Gehirns inspiriert sind. Diese Netzwerke bestehen aus vielen kleinen Verarbeitungseinheiten, die über gewichtete Verbindungen miteinander verbunden sind. Während der Trainingsphase werden die Gewichte dieser Verbindungen angepasst, um die Leistung des Netzwerks oder Modells zu optimieren. Es ist jedoch zu beachten, dass kein maschinelles Lernverfahren fehlerfrei ist. Es gibt immer einen gewissen Prozentsatz an Fehlern, die als Genauigkeitsmaß für die Leistung des Systems dienen. Unter den maschinellen Lernansätzen ist das Deep Learning derzeit besonders erfolgreich, da es durch die Verwendung mehrerer Schichten zwischen Eingabe und Ausgabe eine hohe Präzision ermöglicht und weniger menschliche Anleitung erfordert (Europäische Kommission, 2019; IKS-Fraunhofer, 2023).

Aufgrund der Bedeutung von Daten für KI-Systeme, insbesondere solche mit überwachtem maschinellem Lernen, ist es von entscheidender Bedeutung, die Qualität und Ausgewogenheit der Trainingsdaten zu gewährleisten. Verzerrte oder unausgewogene Daten können dazu führen, dass das KI-System nicht angemessen generalisiert und möglicherweise unfaire, falsche und schlechte Entscheidungen trifft, die bestimmte Gruppen oder Ergebnisse bevorzugen oder benachteiligen können. Daher sind die sorgfältige Überprüfung und Pflege der Daten von großer Bedeutung, um eine effektive KI-Entwicklung zu gewährleisten (Europäische Kommission, 2019; IKS-Fraunhofer, 2023). Computer Vision ist ein Bereich innerhalb der KI, der sich damit beschäftigt Computern zu ermöglichen, Informationen aus Bild- und Videodaten zu erhalten. Computern wird also das menschliche Sehen beigebracht. Hierfür eignen sich insbesondere Convolutional Neural Network (CNN) und Deep Learning Technologien (Schütz, 2023).

2.2.3.1 KI beim Rind

2.2.3.1.1 Gesundheitsüberwachung

Die Firma Connecterra stellt das KI-gestützte "The Intelligent Dairy Farmer's Assistant", kurz „Ida“, bereit, das Landwirten dabei hilft, Entscheidungen zur Verbesserung von Effizienz und Tiergesundheit zu treffen (BlesDairies, 2018; connecterra, 2023). „Ida“ überwacht in Verbindung von Halsbändern die Gesundheit von Kühen. Sie sammelt Daten von den mit dem

Internet verbundenen Systemen Ihres Betriebs, wie dem Betriebsmanagementsystem, den Sortiergittern und Melkrobotern sowie andere Informationen wie das Wetter. Sie stabilisiert die verschiedenen Datenquellen und analysiert sie mit den für sie typischen Algorithmen des maschinellen Lernens. Sie ist selbstlernend und wird kommerziell genutzt, zum Beispiel zur Früherkennung von Krankheiten. Dabei kann sie vor den meisten Menschen ein Problem, 24 bis 48 Stunden vorher bemerken und warnen. „Ida“ kann durch Sensorik Brunst erkennen und schickt 5 Stunden vor dem Beginn des optimalen Besamungsfensters eine Nachricht. Auch bei Abkalbungen und Fruchtbarkeitsproblemen sendet sie Daten. (Cordis, 2020; ida, 2023)

Mit KI-Systemen können große Datenmengen über die Herde gesammelt und analysiert werden. Diese Daten können Informationen über das Verhalten, die Gesundheit und die Leistung der Tiere enthalten. Zum Beispiel können Aktivitätsmonitore und Sensoren zur Früherkennung von Krankheiten wie Lahmheit via Kameras identifiziert werden. Eine Studie per Videoanalyse mit KI konnte zeigen, dass 93 % der lahmen Klauen korrekt erkannt wurden. Die mittlere durchschnittliche Präzision betrug dabei 87 % (Kang, Zhang, & Liu, 2020). Anhand von akustischen Signalen auf einer Trittschallplatte konnte in einem Versuch ebenfalls Lahmheit detektiert werden. Das dazu verwendete Modell erreichte eine Sensitivität von 0,81 und eine Spezifität von 0,97 (Volkman et al., 2021). Weiterhin können die Systeme für Brunstzyklen, Fütterungsmuster oder Informationen zum Allgemeinzustand der Tiere genutzt werden. Diese Systeme können automatisierte Warnungen ausgeben, wenn sie Auffälligkeiten detektieren, was eine frühzeitige Behandlung und bessere Produktivität ermöglichen würden. Scr dairy von Allflex und GEA sind dabei führende Anbieter von Sensoren und Überwachungssystemen zur Analyse von Verhaltensmustern und Gesundheitsindikatoren in der Rinderhaltung in Verbindung mit künstlicher Intelligenz (Allflex, 2020; Alreshidi, 2019; GEA, 2023).

Ein weiteres Unternehmen nutzt eine Kombination aus Ohrmarken und einer KI-gestützten App, um Daten über Rinder zu sammeln. Die App kann Bilder und Videos analysieren, um Informationen über die Gesundheit und das Verhalten der Tiere zu gewinnen (HerdDogg, 2023).

2.2.3.1.2 Futtermisch- und Fütterungsroboter

Diese Systeme verwenden KI, um die richtige Futtermischung basierend auf dem aktuellen Zustand und Bedarf der Tiergruppen zu berechnen und zu liefern. Fütterungsroboter nutzen die KI, um das Futter auf die spezifischen Bedürfnisse der Leistungsgruppen zuzuschneiden. Lely's Vector-System beispielsweise misst ständig die Menge und Qualität des Futters und passt die Futterzusammensetzung und -abgabe je nach Bedarf an (DeLaval, 2023; Lely, 2023).

2.2.3.1.3 Automatisierte Melksysteme

KI-gesteuerte Melkroboter wie der „Astronaut A5“ oder „MR-S1“ können das Melken von Kühen rund um die Uhr übernehmen, den Melkprozess effizienter gestalten, was deren Wohlbefinden verbessert und den Arbeitsaufwand für den Landwirt verringern kann. Sie können zudem mögliche gesundheitliche Probleme erkennen, indem sie zum Beispiel die Milch auf Anomalien prüfen. Unternehmen wie Lely und DeLaval sind bekannte Anbieter für automatisierte Melksysteme und Futtermischungsroboter (DeLaval, 2023; Lely, 2023; TarmstedterAusstellung, 2022).

2.2.3.1.4 Bild- oder Videoanalyse zur Überprüfung der Tiergesundheit

KI kann Bilder oder Videos interpretieren, um die Körperkondition der Tiere zu überprüfen, Brunst festzustellen oder Krankheiten wie Lahmheiten frühzeitig zu erkennen. Unternehmen Verbunde wie Cainthus und Cargill nutzen Bild- oder Videoanalyse, um Informationen über die Gesundheit und das Verhalten von Tieren zu ermitteln. Dabei werden Bilder verwendet, um einzelne Tiere durch versteckte Muster und Gesichtserkennung zu identifizieren. Die Identifikation dient zur Erlangung einzeltierbezogener Daten wie Nahrungs- und Wasseraufnahme, Brunsterkennung, aber auch um Verhaltensmuster zu verfolgen. Die dahinterstehende Software liefert Analysen, welche Entscheidungen auf dem Betrieb voranbringen sollen. Die Kühe können so innerhalb von wenigen Sekunden erkannt werden (Cainthus, 2023; Cargill, 2018). Valide Daten lassen sich dazu zwar nicht finden, jedoch zeigt eine ähnliche Studie, dass eine visuelle Verfolgung oder Tracking, sowie Erfassung der Körperkonditionsbeurteilung und mehr von einzelnen Kühen per Videoanalyse möglich ist (Zin et al., 2020). Ebenso die Identifikation von Tieren durch ein reines Kamerasystem mit Detektoren als nicht-invasive Möglichkeit, wurde in einem Versuch bewiesen. Hier konnten 89 verschiedene Kühe durch Gesichtserkennung bei einer Gesamtgenauigkeit von 84 % auseinandergelassen werden (Dac et al., 2022). Eine andere Untersuchung weist endgültige Erkennungsgenauigkeiten von 98,58 % bei Kühen auf (Fu et al., 2022). Auch anhand von Bildern des Flotzmauls, die sich mit einem menschlichen Fingerabdruck vergleichen lassen, konnten 269 Rinder mittels Objekterkennung und Kamerasystemen bei einer Präzision von 98,7 % identifiziert werden (Li, Erickson, & Xiong, 2022). QuantifiedAG, welches von Allflex übernommen wurde hat eine visuelle Überwachungstechnologie entwickelt, die Infrarotaufnahmen von Tieren analysiert, um Krankheiten frühzeitig zu erkennen. Mit seinen speziellen Ohrmarken für Rinder kann es Veränderungen im Verhalten und in den Vitalfunktionen der Tiere auswerten und so frühzeitig mögliche Gesundheitsprobleme identifizieren (IoTforAll, 2023). AgEagle nutzt zum Beispiel Drohnentechnologie und KI-gestützte Bildanalyse, mit der Gesundheitsinformationen von beispielsweise Weide- und Wildtieren gesammelt und ausgewertet werden können (AgEagle, 2019). Ein Start-up hat eine automatisierte KI-Plattform entwickelt, die Webcams und andere Kameras nutzt, um das Verhalten und die Körperkondition von Rindern zu überwachen. Dabei wird die

Fortbewegung der Kühe überwacht und einzelne markiert, bei denen eventuell ein Eingriff erforderlich ist. Bei dieser Methode ist die Kamera über dem Ausgangslauf eines Melkstandes montiert. Es sind keine Sensoren direkt am Tier mehr erforderlich (cattleeye, 2023). In einer Studie erreichte CattleEye vergleichbare Ergebnisse, als wenn zwei erfahrene Tierärzte die Lahmheit von Kühen erfassen würden. Hinsichtlich der Erkennung von Lahmheit war das KI-System sogar empfindlicher. Die Sensitivität des Modells betrug 0,52 und die Spezifität 0,81; während der menschliche Erfasser eine Sensitivität von 0,29 und eine Spezifität von 0,89 aufwies (Anagnostopoulos et al., 2023). Ebenso ist es möglich, die Wiederkäuaktivität von Kühen mittels Videotechnik und Computer Vision zu überwachen. In der Studie wurde einmal die Wiederkäuzeit und die Anzahl der Kauvorgänge berechnet. Die Rinderköpfe wurden zunächst im Video durch ein Multi-Objekt-Tracking-Algorithmus verfolgt, der YOLOv4 mit dem KCF (Kernelized Correlation Filter) zusammen kombinierte. Die Ergebnisse wurden mit den Ergebnissen menschlicher Beobachtungen verglichen. Die experimentellen Ergebnisse wiesen durchschnittliche Fehler bei der Wiederkäuzeit von 5,9 % und für die Anzahl der Kauvorgänge 8,1 % auf. Dementsprechend lag die Genauigkeit für die Wiederkäuzeit bei 94,1 %, die für die Kauvorgänge bei 91,9 % (Y. Wang, Chen, Li, & Li, 2023).

Um das Verhalten und die sozialen Interaktionen von Tieren innerhalb der Herden besser untersuchen zu können wurde in einer Studie ein kamerabasiertes System genutzt, welches die Tiere automatisch erkennt. Der Grund für diese Überwachung lag in der Annahme, dass Tiere anders interagieren, wenn menschliche Beobachter anwesend sind. Das trainierte Modell zur automatischen Erkennung von Kühen erreichte eine durchschnittliche Genauigkeit von 91 % und stellte somit eine Grundlage für eine automatisierte Untersuchung der Herdenaktivität in Laufställen dar (Salau & Krieter, 2020). In einer weiteren Studie wurde das Verhalten und die Körperhaltungen von Rotfüchsen in Videos durch Computer Vision untersucht, da das Verhalten mit dem Gesundheitszustand und Wohlergehen zusammenhängt. Der Detektor erfasste die Objekteigenschaften des Erkennens des Tieres und der Körperhaltungen „liegend“, „stehend“ und „sitzend“. Das trainierte Modell hat eine durchschnittliche Präzision von 99,91 %. Da auch die Aktivität überwacht wurde, konnte eine kontinuierliche Überwachung des Tierverhaltens realisiert werden (Schütz et al., 2022).

Es ist auch möglich eine Körperkonditionsbeurteilung mittels 3D-Kamera durchzuführen, die das Tier scannt, während es nach dem Melken im Rücktrieb ist (Büscher et al., 2021). Genauigkeitstests in einer Studie ergaben ein Bestimmtheitsmaß von 0,75 mit 100 % korrekter Klassifizierung innerhalb eines ganzen Schrittes der BCS-Klassen und eine 91 %ige korrekte Klassifizierung innerhalb eines halben Schrittes für die BCS-Klassen (Spoliansky, Edan, Parmet, & Halachmi, 2016).

2.2.3.2 Schwein

Kameras in Verbindung mit künstlicher Intelligenz können Schweine und Körperpartien automatisiert erkennen. Daraus lassen sich Körper- und Schwanzhaltung und letztlich das Wohlbefinden der Schweine bewerten. Die aktuell dazu noch laufenden Studien sollen vielversprechend sein, da sie die Tierüberwachung vereinfachen und im Gesamten für alle Tiere eher ermöglichen (Lieboldt, 2023).

Die Firma Fancom entwickelte den Pig Cough Monitor. Dieser kann hustende Geräusche erfassen und auswerten, um Atemwegserkrankungen frühzeitig zu erkennen. Die Leistung des Modells konnte hinsichtlich der Genauigkeit mehr als 97 % erreichen (Lagua et al., 2023). Außerdem ist der Algorithmus in der Lage zwischen unproduktiven, meist staubbedingten und produktiven Husten durch Krankheitserreger verursacht zu unterscheiden. Das System besteht aus einer Steuerung mit Analysesoftware und zwei Mikrofonen (WFI, 2023).

Mittels „WeightCheck“ lässt sich das Durchschnittsgewicht von Mastschweinen bei einer Gruppengröße von maximal 25 Tieren ermitteln. Die optische Gewichtserfassung kann mit einer Kamera und einer selbstlernenden künstlichen Intelligenz eine Genauigkeit von 98,5 % erreichen (BigDutchman, 2021).

2.2.3.3 Geflügel

Um die Gehfähigkeit von Broilern zu beurteilen, wird der Gait Score und das Kamerasystem eYeNamic verwendet. Die aus dem Kamerasystem verwendeten Parameter waren Basisaktivität, Zeit der Aktivität bis zur Wiederaufnahme der Basisaktivität, die durchschnittliche Aktivität über einen bestimmten Zeitraum und die Differenz zwischen dem höchsten und geringsten Aktivitätspeak. Im Verlaufe einer Studie wurde mit dieser Methode herausgefunden, dass der Gang mit zunehmendem Alter schlechter wurde. Die Amplitude und Alter standen in einem signifikanten Zusammenhang. Da dies jedoch nicht marktfähig demonstriert diese Methode unter Verwendung von Bildanalysetechnik eine potenzielle automatisierte Bewertung des Lahmheitsgrads in Broilerherden (Silvera et al., 2017)

Die rechtzeitige Erkennung von toten Hühnern in großen Herden trägt dazu bei, Kreuzinfektionen, Krankheitsübertragungen und wirtschaftliche Einbußen zu verhindern. Bisher wurde die Erkennung toter Hühner immer noch manuell vollzogen und kostet viel Arbeitszeit in den Betrieben. In einer Studie wurde eine neue Methode zur Erkennung toter Hühner durch Bilder und Anwendung von YOLOv8n erprobt. Das beste Ergebnis erzielte ein Objekterkennungsmodell mit NIR-Tiefenbildern (Nah-Infrarot) mit einer durchschnittlichen Präzision von 99,7 % bei einem Recall von 99 % und einer IoU (Intersection over Union) von 0,5 (Luo et al., 2023).

3 Material

3.1 Computer-Hardware

Für die Arbeiten an Video- und Bildmaterial, die das Erarbeiten von Bildern und das Klassifizieren von Kühen umfassten, wurde ein x-64-basierter Prozessor Intel(R) Core (TM) i5-6500 CPU @ 3.20 GHz mit 16GB RAM genutzt.

Für die rechenintensiveren Schritte wurde ein Server mit Intel Xeon E5-2667 v4 mit 3.20 GHz Prozessoren (377GB RAM), und einer NVIDIA K80 mit zwei GPUs genutzt.

3.2 Computer-Software

Die Programme VLC media player und Labelling (Tzutalin, 2015) wurden auf einem Windows 10 Enterprise 64-Bit-Betriebssystem angewendet.

Das Server Betriebssystem war Linux CentOS 7, auf dem die Softwares Jupyter notebook (Kluyver et al., 2016) und Phyton 3.6.8 (van Rossum & Drake, 2014) liefen. Durch sie konnte der Algorithmus entwickelt werden.

3.3 Experimenteller Aufbau

Die Grundlage des Versuchs bildeten Videosequenzen von drei Stallabteilen aus den Tierversuchsställen des Friedrich-Loeffler-Instituts auf der Insel Riems bei Greifswald.

3.3.1 Tiere und Haltungsbedingungen

Für den Tierversuch 7221.3-1-047/17 wurden trockenstehende Rinder mit Mykoplasmen (*Mycoplasma mycoides*) infiziert und per Videosystem überwacht. Entgegen den Erwartungen blieben die Rinder gesund und waren klinisch unauffällig, sodass die dort entstandenen Videos für die in dieser Arbeit durchgeführten Auswertungen genutzt werden konnten. In drei Laufboxen wurden jeweils fünf Holstein Friesian mit Fressfanggittern gehalten

Die weiblichen Rinder wurden einmal täglich gefüttert und tierärztlich betreut. Die Laufboxen wurden während des Fütterns jeden Tag durch das Personal gereinigt. Die Boxengröße konnte abhängig von der Anzahl gehaltener Tiere durch verstellbare Seitenwände variabel angepasst werden.

3.3.2 Verwendete Kamertechnik

Zwei Stallabteile waren jeweils mit einer Kamera des Typs Digitus DN-16081-1 versehen. Das dritte Stallabteil mit einer HiWatch IR Network Camera DS-I111. Die Kameras befanden sich an den jeweiligen Enden der Box an der Decke über dem Fressfanggitter und konnten so von beiden Seiten die Sicht abdecken. Die dritte Kamera (HiWatch) war außerhalb der Box vor dem Fressfanggitter angebracht, sodass eine frontale Ansicht zur Box entstand.

Die nachstehende Skizze soll einen Überblick verschaffen und im Folgenden kurz erklärt werden.




Abbildung 1 Eigene Darstellung einer Laufbox aus der Vogelperspektive. Hier werden die Positionen und toten Winkel aller Kameras der Einfachheit halber in einer Grafik zusammengefasst dargestellt. Rot markierte Bereiche zeigen die toten Winkel der Kameras auf.

Die Grafik zeigt eine Laufbox aus der Vogelperspektive und soll die anderen mitrepräsentieren. Der untere Teil setzt sich aus dem Futtergang und den Futtertrögen zusammen. Sie sind durch das Fressfanggitter mit der Laufbox voneinander getrennt. Die blauen Punkte markieren die Positionen der Kameras. Kamera 1 und 3 sind vom Typ HiWatch, Kamera 2 stammt von Digi-tus. Das rot markierte Dreieck bei Kamera 1 zeigt den Bereich, der nicht im Sichtbereich der Kamera liegt. Gleiches gilt für die Kamera 3 mit einem ähnlichen toten Sichtfeld. Beide dieser Kameras haben die horizontalen roten Linien, also das Fressfanggitter und das Metallrohr, im Sichtfeld und können die Bereiche des Stalles, die dahinter liegen, nicht darstellen. Alle anderen Bereiche der Box konnten abgedeckt werden. Die Kamera 2 hatte das Sichtfeld durch das Fressfanggitter, welches eben dadurch vermindert war. Außerdem erfasste die Kamera nur den weißen Bereich, der rosafarben markierte Teil wurde nicht miterfasst. Die Lichtstärke in der Laufbox lässt sich durch fehlende Daten nicht exakt beschreiben. Dennoch war das Lichtangebot homogen auf die Laufbox und den restlichen Teil des Stalls, sowohl tags als auch nachts verteilt. Die Laufbox hatte einen schwarzen Untergrund als Boden und weiße Wände.

3.4 Verwendete Bild- und Videodaten

3.4.1 Videomaterial aus den Tierversuchsställen des Friedrich-Loeffler-Instituts

Ein Teil der aus vergangenen Studien entstandenen Videoaufnahmen beider Laufboxen wurden für den vorliegenden Versuch als Rohmaterial verwendet. Jedes Video der Digituskameras besaß eine Länge von etwa zwei Minuten (117 Sekunden), die der HiWatch 45 Minuten. Die Videokameras hatten für einen bestimmten Zeitraum (71011: 28.09.2017 – 01.11.2017; 71010: 01.10.2017 – 15.10.2017; 71009: 28.09.2017 – 01.10.2017) durchgängig aufgezeichnet, wodurch sowohl Tag- als auch Nachtaufnahmen vorlagen. Das permanent aufgezeichnete Videomaterial wurde in einzelne Teile abgespeichert. Von diesen Videodaten wurden fünf verschiedene Tage innerhalb eines Monats herausgesucht und für die Analysen genutzt. Insgesamt ergab sich eine Anzahl von 134 Videos bei einer Datenmenge von 7,85 GB. Die Auflösung der Videodaten der Digitus Kameras belief sich auf 2688 (horizontal) x 1512 (vertikal) Pixel bei 25 fps, die der HiWatch auf 1280 x 720 Pixel.

3.4.2 Weiteres Videomaterial

Zur weiteren Evaluierung des durch die Versuche erhaltenen Detektors wurde weiteres Videomaterial genutzt, welches allerdings nicht vom Versuchsstandort Riems stammte. Hierbei handelte es sich um Videoaufnahmen aus einem Laufstall mit vier genutzten Infrarotkameras. In dem Stall waren auf zwei Seiten Kameras installiert. Auf jeder Seite zwei Stück. Jedoch waren sie von der Höhe und dem Blickwinkel auf den Stall verschieden positioniert. Einfachheitshalber wurden die zwei verschiedenen Perspektiven mit je zwei Kameras als einzelne Laufställe, nämlich Laufstall 1 und Laufstall 2 behandelt. Die Aufnahmen des Laufstalls 1 stammen aus dem Jahr 2022, die des Laufstalls 2 aus dem Jahr 2016. Die Anzahl der Tiere in den Laufställen variierte zwischen fünf bis etwa sieben Holstein Friesian Kühen, zu denen keine weiteren tierbezogenen Angaben gemacht werden können, da hierzu keine Daten vorlagen. Auch hier gab es sowohl Tag- als auch Nachtaufnahmen.

Die Videos des ersten Laufstalls, im folgenden Laufstall 1 genannt, besaßen eine Bildgröße von 1920 x 1080 Pixel bei 30 fps. Die Aufnahmen des zweiten Laufstalls, im folgenden Laufstall 2 genannt, hatten eine Bildgröße von 704 x 576 Pixel bei 25 fps. Die Länge der Videos beider Laufställe wichen stark voneinander ab. So waren die Videos des Laufstalls 2 mit etwa einer Dauer von einer Stunde länger als die des Laufstalls 1 mit 15 Minuten. Insgesamt wurden aus beiden Laufställen zusammen 8 Videos mit einer Datenmenge von 4,59 GB verwendet.

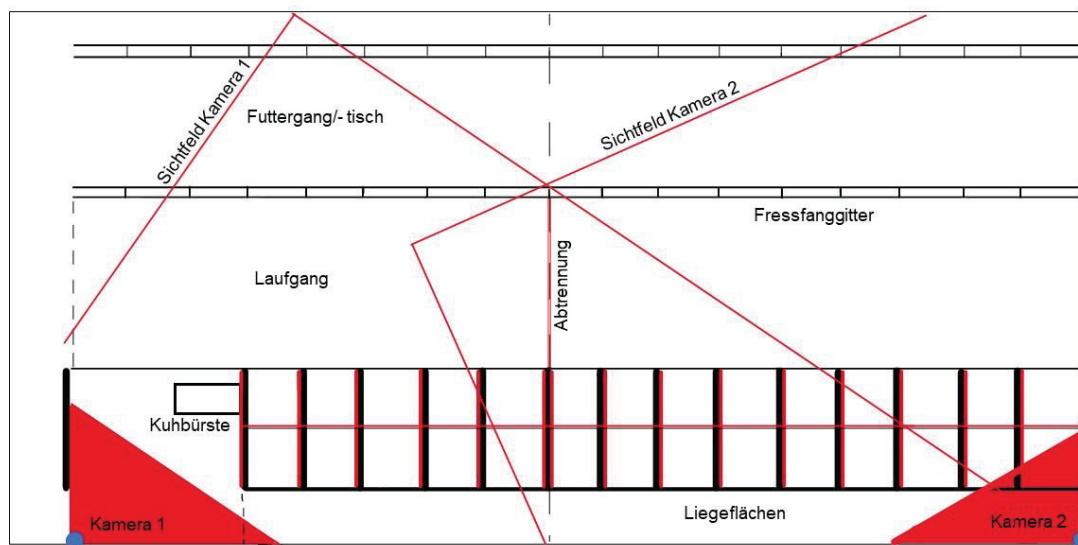


Abbildung 2 Eigene Darstellung des Laufstalls aus der Vogelperspektive mit Sichtfeldern der Kameras und Bereichen die nicht eingesehen werden können.

Die obige Abbildung zeigt den verwendeten Laufstall als einfache Skizze aus der Vogelperspektive. Der Stall ist aufgliedert in einen Laufgang mit Liegeflächen, die durch ein Fressfanggitter vom Futtergang getrennt werden. Auf der anderen Seite befindet sich erneut ein Fressfanggitter. Die blauen Punkte markieren die etwaige Lage der beiden Kameras. Die rot gefärbten Flächen an den Kameras weisen auf einen toten Winkel hin, den die Kameras nicht erfassen können. Beispielhafte Bilder, welche folgende Beschreibungen verdeutlichen, sind in den Unterkapiteln 4.5.1.1 und 5.2.1.1 zu finden. So gibt es beim Übergang, an dem die Kuhbürste installiert ist und auf der rechten Seite, wo ein Teil der Liegeflächen nicht einsehbar ist, tote Winkel. An den Liegeflächen sind die Boxenbügel ebenfalls rot markiert, da sie ein freies Blickfeld blockieren. Je weiter die Liegeflächen von den Kameras entfernt und damit mehr Boxenbügel dazwischen sind, desto weniger können die Liegeboxen durch die Kameras eingesehen werden. Auch verdeckt die Nackenbegrenzung, welche quer über die Liegeflächen verläuft, die freie Sicht auf die Liegeflächen. Das Sichtfeld der Kameras ist in der Abbildung eingezeichnet und zeigt, dass die Sicht über die von den Tieren genutzte Fläche hinausgeht. Dementsprechend sind Stalleinrichtungsgegenstände Teil des Sichtfelds der Kameras. Wichtig zu erwähnen ist, dass vom Blickfeld der Kamera 1 die erste Liegefläche durch eine Betonwand zum meisten Teil verdeckt wird.

Durch eine offene Stallbauweise waren die Lichtverhältnisse tagsüber ausgeglichen. Bei starker Sonneneinstrahlung erhöhte sich der Schattenwurf von Gegenständen und Tieren. Nachts bot eine Lichtquelle in der Nähe der Kamera 2 etwas Helligkeit. Die linke Seite bei Kamera 1 war nicht beleuchtet. Die andere Seite des Futtertisches hingegen, also die gegenüberliegende Stallseite war nachts sehr hell ausgeleuchtet. Zwar besaßen die Kameras Infrarot, dennoch entstand eine mittige Lichtkegelbildung, ohne dass der Rest ausgeleuchtet wurde.

Im Laufstall 1 befand sich die Kamera 2 auf der rechten Seite niedriger als im Laufstall 2. Das hatte zur Folge, dass beispielsweise die erste Liegebox nur zur Hälfte sichtbar war, während im Laufstall 2 die Kamera diese Box miterfasste. Auch die Neigung der Kamera des Laufstalls 2 zum Boden war so gewinkelt, dass man die Kühe mehr von oben betrachten konnte und die Boxenbügel die Sicht auf die Kühe nicht so sehr beeinträchtigte. Die Kamera aus Laufstall 1 erfasste auch die andere Seite der Abgrenzung hinaus die Fläche, während die Kamera aus Laufstall 2 nur den rechten Teil erfasste.

Anders war es auf der linken Seite des Stalls bei Kamera 1. Hier war die Kamera des Laufstalls 1 zwar wieder etwas niedriger, aber die Neigung der Kamera zum Boden war stärker als im Laufstall 2. Im Laufstall 2 hatte dies zur Folge, dass weite Teile des Stalls und dessen Einrichtung in die Aufnahmen miteinbezogen worden sind, sogar über die Abgrenzung des Laufgangs und dem gegenüberliegenden Fressfanggitter hinaus.

Insgesamt betrachtet sind die Kühe auf den Aufnahmen des Laufstalls 1 näher zur Kamera als im Laufstall 2.

3.4.3 Bildmaterial

3.4.3.1 Bildmaterial des FLI

Die entstandenen Bildmengen beim Extrahieren aus den Videos besaßen eine Bildgröße von 2688 x 1512 Pixel bei einer Auflösung von 96 dpi. Für die drei Versuche der Objekteigenschaften „stehen“ und „liegen“ wurden insgesamt 860 Bilder genutzt. Diese teilten sich auf die ersten beiden Versuche auf. Im ersten Versuch wurden 584 Bilder verwendet, im zweiten Versuch wurden weitere 276 Bilder hinzugefügt. Der dritte Versuch nutzte das gesamte Bildmaterial.

200 Bilder wurden für die Individualisierung der einzelnen Kühe extrahiert und genutzt. Die Bilder zur Individualisierung stammen aus lediglich einem der Ställe des FLI. Über die ganze Arbeit betrachtet wurden aus dem Videomaterial insgesamt 1220 Bilder extrahiert und weiterverwendet.

3.4.3.2 Bildmaterial der Laufställe

Für jedes Video, das für die Versuche in den Laufställen verwendet werden sollte, wurden 20 Bilder extrahiert, was zu einer Summe von 160 Bildern führte. Für jeden Laufstall ergaben sich somit 80 Bilder. Diese teilten sich folgend in Tag- und Nachtaufnahmen auf. Der Laufstall 1 beinhaltete 47 Tag- und 33 Nachtaufnahmen. Der Laufstall 2 umfasste 38 Tag- und 42 Nachtaufnahmen. Zwischen den weiteren Versuchen änderte sich das Bildmaterial nicht. Die Bilder aus dem Laufstall 1 hatten eine Bildgröße von 1920 x 1080 Pixel und die des Laufstalls 2 lag bei 704 x 576 Pixel.

4 Methoden

4.1.1 Auswahl der Videodateien

Die Auswahl der Videos beruhte auf der Absicht möglichst viele verschiedene Momente und Blickwinkel zu erhalten, in denen sich die Tiere in unterschiedlichsten Positionen bewegten oder ruhten.

4.1.2 Software-basierte Sichtung der ausgewählten Videosequenzen

Nachdem die Auswahl des Videomaterials feststand, wurde jedes einzelne Video gesichtet. Hierfür wurde das Programm VLC media player genutzt, welches ohne Einschränkungen kostenlos nutzbar und allgemein zugänglich ist. Mithilfe dieser Anwendung wurden währenddessen aus den Videos einzelne Momente in Form von Screenshots festgehalten und separat abgespeichert. Das Ziel glich dem wie für die Auswahl der Videos, so viel verschiedene Körperhaltungen („stehend“ / „liegend“) sowie möglichst viele unterschiedliche Blickwinkel der individuellen Tiere zu erhalten. Hier lag der Fokus schon insbesondere auf den einzelnen Tieren, sodass jedes Tier möglichst von allen Seiten in Form von Bildern festgehalten werden sollte. Das teils gegenseitige Verdecken der Tiere vor der Kamera war kein Ausschlusskriterium für eine Aufnahme. Die entstandenen Bildmengen wurden im jpg-Format gespeichert.

4.2 Klassifizieren von Bildern

Um die Bildmengen für eine Objekterkennungssoftware nutzen zu können, müssen sie vorher klassifiziert werden. In diesem Fall sollten die auf den Bildern zu sehenden Kühen in Klassen eingeteilt werden.

4.2.1 Klassifizierung Objekteigenschaft

Im ersten Schritt wurden die Kühe aller Bilder in zwei Klassen eingeteilt, nämlich in (1) „stehende“ und (2) „liegende“ Tiere. Hierfür wurde die Software Labellmg (Tzutalin, 2015) genutzt. Labellmg ist ein freies, quelloffenes Programm, mit dem die Lokalisation und Objekteigenschaft eines Objekts innerhalb eines Bildes beschrieben und separat in einer Textdatei gespeichert wird. Für die sogenannten Label wurden mit Hilfe von Rechtecken die einzelnen Objekte händisch eng umrahmt und anschließend klassifiziert. Das bedeutet, dass den Boxen, in denen die Rinder sichtbar sind, manuell entweder die Eigenschaft des „Stehens“ oder die des „Liegens“ zugeordnet wurden. Für jedes Bild erzeugte Labellmg eine separate Textdatei, in denen die Positionen der erstellten Boxen durch fünf Werte (n = Nummer der Objektklasse, x - und y -Wert des Boxenmittelpunkts, w und h = Breite und Höhe der Box) dargestellt sind. Die fünf Angaben sind in Werte zwischen 0 und 1 normiert, was den Vorteil hat, dass die Größe des Bildes beliebig geändert werden kann und die Label trotzdem immer passen.

Es entstehen pro Bild so viele Rechtecke, wie Tiere auf dem Bild zu sehen sind.



Abbildung 3 Manuelles Labeln der Objekteigenschaften mithilfe von Labellmg. Die Rechtecke umrahmen die Körperflächen der Kühe und werden separat als Koordinaten gespeichert und weiterverwendet.

4.2.2 Klassifizierung Objekteigenschaft der Kühe aus dem Laufstall

Um die Ergebnisse des Detektors auf die Bilder in den Laufställen evaluieren zu können, mussten auch hier Bilder klassifiziert werden. Dafür wurden die Rinder ebenfalls in „stehend“ und „liegend“ klassifiziert. Es wurden, wie während des Antrainierens in den ersten drei Versuchen, Tag- und Nachtaufnahmen in Form von Videos genutzt. 4,5 Std. Videomaterial aus insgesamt 8 Videos bildeten dafür die Grundlage. Jeweils vier Videos von einem Laufstall mit zwei Kameraperspektiven wurden ausgewählt. Die Klassifizierung der Bilder entsprach genau dem gleichen Ablauf wie im Unterkapitel 4.2.1.

4.2.3 Klassifizierung Objekterkennung

Im zweiten Schritt wurden ausschließlich Bilder einer Gruppe von fünf Kühen klassifiziert. Statt der zwei Klassen „stehend“ oder „liegend“ sollten diese Tiere nun individualisiert werden. Das bedeutet, dass jede einzelne Kuh eine Klasse darstellt, wodurch sich fünf Klassen ergaben. Um die einzelnen Tiere auseinanderhalten zu können, wurden von jeder einzelnen Kuh optische Besonderheiten in der Fellmusterung notiert, um Fehler bei der Klassifizierung so gering wie möglich zu halten. Wenn das Bildmaterial eine sichere Entscheidung nicht zuließ, wurde das ursprüngliche Videomaterial parallel gesichtet, um Verwechslungen oder Fehlentscheidungen zu verhindern. Durch vorhandene Zeitstempel sowohl im Video- als auch im Bildmaterial war dies möglich. Für diesen Schritt wurden insgesamt 88 Videodateien mit einer Datenmenge von 5,03 GB genutzt.

4.2.4 Verwendung klassifizierter Bilder

Durch das Klassifizieren oder Labeln wurden auf den zu den Bildern gehörenden Textdateien unterschiedliche Datenpunkte mit Informationen gekennzeichnet. Diese dienten später dazu, Algorithmen beizubringen, was in einem bestimmten Bereich eines Bildes zu sehen ist. Im ersten Schritt war es die Eigenschaft, ob eine Kuh in der rechteckigen Box „liegt“ oder „steht“. Im zweiten Schritt wurde die Information gegeben welche Kuh in der jeweiligen Box ist. Diese Daten ermöglichen es, Modelle so zu trainieren, dass sie Objekte auf Bildern genau lokalisieren und identifizieren können. Das Labeln von Bildern hilft also Algorithmen beim computer-gestützten Sehen dabei, die gewünschten Objekte zuverlässig zu erkennen.

Während des Extrahierens der Bilder wurde darauf geachtet, dass sowohl Tag- als auch Nachtaufnahmen verwendet wurden, damit unterschiedliche Lichtverhältnisse in den Datensätzen für das manuelle Klassifizieren vorhanden sind. Das Vorhandensein von mehreren Perspektiven durch verschiedene Kameras ermöglichte außerdem einen variablen Hintergrund, ohne durchgängig derselbe zu sein. Zudem sollte darauf geachtet werden, dass die Anzahl „stehender“ und „liegender“ Kühe in etwa gleich verteilt ist.

4.3 Anlernen von YOLOv4

4.3.1 YOLOv4: Ein leistungsstarker Algorithmus für Echtzeit-Objekterkennung mit CNN

Zum Aufbau einer Objekterkennung wurde der YOLOv4 Algorithmus gewählt. Er ist ein einstufiger Objekterkennungsalgorithmus, der in Echtzeit arbeitet und auf einem CNN basiert (J. Redmon, Divvala, Girshick, & Farhadi, 2016; Joseph Redmon & Farhadi, 2018). Ein CNN ist ein künstliches neuronales Netz, welches besonders gut für die Bilderkennung und deren Verarbeitung geeignet und insbesondere für die Verarbeitung von Pixeldaten ausgelegt ist. Der Objekterkennungsalgorithmus lässt sich auch als eine leistungsstarke, bildverarbeitende künstliche Intelligenz (KI) beschreiben, die sich für das maschinelle Lernen eignet. Für den ganzen Prozess einer Objektklassifizierung und -lokalisierung wird nur ein neuronales Netz verwendet, das für ein Bild durchlaufen wird. Das Bild wird lediglich einmal betrachtet, deshalb der Name „You Only Look Once“ (Daglioglu, 2021).

4.3.2 Lernen aus klassifizierten Bildern für präzise Klassifizierung und Lokalisierung

Objekterkennungssysteme mit maschinellem Lernen sind in der Lage, aus gesammelten Daten, hier klassifizierten Bildern, zu lernen. Die dazu notwendigen Datensätze sind jene Bilder, die im Vorfeld manuell klassifiziert wurden. Die auf den Bildern erstellten Rechtecke mit Klassenbeschreibung, auch Ground-Truth-Labels genannt, geben dem Algorithmus zu verstehen, was er lernen soll. Durch sie ist es möglich, die auf den Beispielbildern vorhandenen Informationen zu abstrahieren und daraus Entscheidungskriterien abzuleiten.

Entscheidungskriterien können beispielsweise die Lokalisierung und die Klassifizierung von Objekten auf den Bildern sein. Ist eine Ableitung dieser Kriterien erfolgreich, sollte ein Objekterkennungsmodell fähig sein, neue und dem Modell unbekannte Bilder zu verarbeiten und die gewünschten Objekte darauf sowohl zu lokalisieren als auch zu klassifizieren (Daglioglu, 2021).

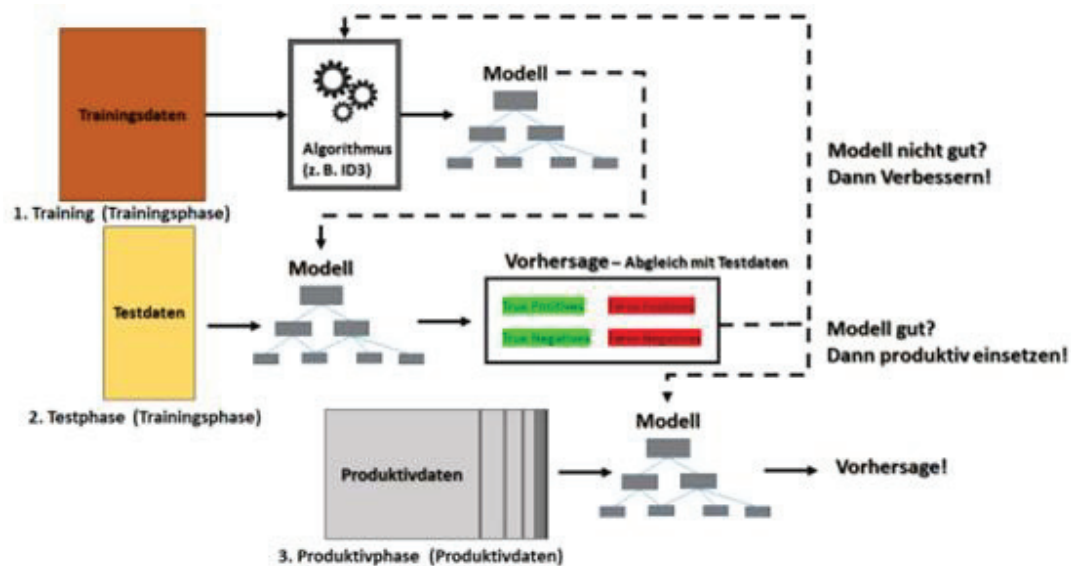


Abbildung 4 Ablauf und Entstehung eines Objekterkennungsmodells und die einzelnen Schritte bis ein Modell anwendbar ist (Daglioglu, 2021).

4.3.3 Training und Evaluierung von Objekterkennung mit Trainings- und Testgruppen

Um dies zu erreichen, wurde das gesamte Bildmaterial bei allen Durchläufen in eine Trainings- und eine Testgruppe aufgeteilt, wobei die Trainingsgruppe 80 % und die Testgruppe 20 % der Bilder ausmachte. Die dafür verwendeten Daten wurden in den jeweiligen Versuchen im Einzelnen dargestellt. Die Trainingsgruppe wurde genutzt, um den YOLOv4 Objekterkennungsalgorithmus zu trainieren, während die Testgruppe der Evaluierung für das trainierte Modell von „stehenden“ oder „liegenden“ Kühen und der Individualisierung der Kühe diente. Das Ziel war, dass aus den Inputs in Form von Bildern aus der Trainingsgruppe der richtige Output in Form von Vorhersagen gemacht werden konnte. Die Outputs setzen sich aus den ermittelten Bounding Boxes, Klassen und Wahrscheinlichkeiten, dass das die Klasse innerhalb der Box ist, zusammen. Im Idealfall stimmen sie mit den Ground-Truth-Labels überein. Bounding Boxes sind die Rechtecke, welche durch ein Objekterkennungssystem selbst generiert werden und beschreiben, in welchem Bereich eines Bildes ein relevantes Objekt lokalisiert wurde. Neben der Lokalisation wird auch ermittelt, um was für ein Objekt es sich handelt und mit welcher Wahrscheinlichkeit es als solches erkannt wird. Nach jedem Trainingsschritt konnte der Erfolg mithilfe der Testgruppe von Bildern überprüft werden, da diese nicht Teil des Trainings waren.

Für das Training und Evaluieren der Objekteigenschaften „stehend“ und „liegend“ wurden insgesamt drei Versuche unternommen. Jedes Training und Evaluieren, das dem ersten Versuch

folgte, diente zur Verbesserung der Präzision des Objekterkennungsmodells. Dafür sollten Label einer bestimmten Objekteigenschaft an die Anzahl der anderen angepasst werden.

4.3.4 YOLOv4-Parameter zur Objekterkennung von „stehenden“ / „liegenden“ Kühen und deren Individualisierung

Das Trainieren des Detektors von „stehenden“ oder „liegenden“ Kühen, sowie die Individualisierung wurden mit den Parametern der folgenden Tabelle durchgeführt. Die gleichen Trainings nur mit anderen Klassen und Werten wurden auch in anderen Studien angewendet. In diesen ging es um die Objekterkennung mittels YOLOv4 an Füchsen. Der Aufbau und Ablauf dieser Trainings ist derselbe und entsprechen der gleichen Logik (Schütz et al., 2022; Schütz et al., 2021). Die Trainingsdauer für ein einziges neuronales Netz betrug zumeist 8 Stunden.

Tabelle 2 YOLOv4-Parameter zur Objekterkennung von „stehenden“ / „liegenden“ Kühen und deren Individualisierung

Parameter	Werte	
Input size	416 x 416	416 x 416
classes	2	5
Maxbatches	4.000 Anzahl der Klassen*2000	10.000 Anzahl der Klassen*2000
Filters	21 (Anzahl der Klassen+5)*3	30 (Anzahl der Klassen+5)*3
Steps	3.200, 3.600 (links 80 %, rechts 90 % der maxbatches)	8.000, 9.000 (links 80 %, rechts 90 % der maxbatches)
Learning rate	0.001	
Batch size	64	

Die Werte auf der linken Seite beziehen sich auf die Detektion von „liegenden“ und „stehenden“ Kühen, daher zwei Klassen. Auf der rechten Seite lassen sich die fünf Klassen finden, die für die Individualisierung der einzelnen Kühe diente.

4.3.5 Wichtige Parameter zur Bewertung der Leistung eines Modells

Um die Leistung und Qualität eines Modells zu prüfen und zu messen, wurden folgende Indikatoren genutzt: Intersection over Union, Precision, Recall und die Mean average precision.

4.3.5.1 Intersection over Union (IoU)

Die IoU beschreibt die Überschneidung der vom Objekterkennungsmodell ermittelten Bounding Box und der Ground-Truth Bounding Box, welche manuell mit Labelling erstellt wurde. Sie errechnet sich aus deren Überlappungsfläche geteilt durch die Fläche, welche beide Boxen miteinander vereint (Everingham, Van Gool, Williams, Winn, & Zisserman, 2010).

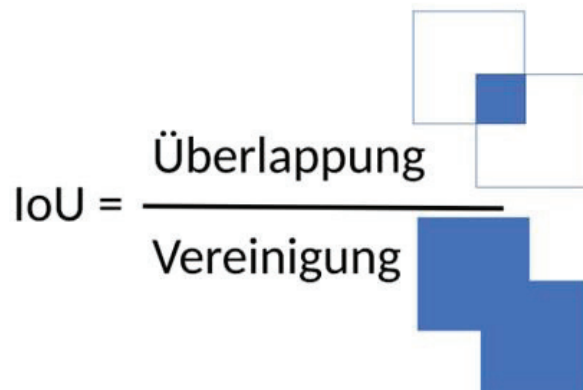


Abbildung 5 Berechnung der IoU (Daglioglu, 2021)

Das sich aus dem Ergebnis ergebene Verhältnis wie sehr sich die Boxen überschneiden, wurde genutzt um zu bestimmen, ob eine Detektion „richtig positiv“ (RP) oder „falsch positiv“ (FP) erkannt wurde. Dazu wurde ein sogenannter IoU Threshold definiert, also ein Schwellenwert, bei dem entschieden wird, ob eine Detektion als richtig oder falsch positiv erkannt wurde.

Der IoU Threshold lag bei 0,5 oder 50 %. Wenn der Wert der IoU bei 0,5 oder höher lag, war die Detektion richtig positiv. Lag der Wert darunter war die Detektion falsch positiv. Sind auf einem Bild gelabelte Ground-Truth Bounding Boxes vorhanden, doch der Detektor detektiert keiner dieser Boxen, ist das Ergebnis „falsch negativ“ (FN). Als letzte Möglichkeit gibt es das Ergebnis „richtig falsch“ (RF). Hier ermittelt das Modell kein Objekt, auch in den Ground-Truth Bounding Boxes ist kein Objekt beschrieben.

4.3.5.2 Precision

Die Precision sagt aus, wie oft das Objekterkennungsmodell richtig liegt, wenn es ein Objekt erkannt hat. Um sie zu berechnen, wird die Anzahl der „richtig positiv“ durch die Summe von „richtig positiv“ und „falsch positiv“ dividiert (Zeng, 2018).

$$precision = \frac{RP}{RP + FP}$$

4.3.5.3 Recall

Das Gegenstück zur Precision ist der Recall, der beschreibt, ob das Objekterkennungsmodell jedes Objekt identifiziert hat, welches es identifizieren sollte. Er berechnet sich aus der Anzahl der True Positives geteilt durch die Anzahl von „richtig positiv“ und „falsch positiv“. Alternativ lässt sich auch sagen, dass die Anzahl der „richtig positiv“ durch die Anzahl an Ground-Truth

Labels insgesamt dividiert werden (Zeng, 2018).

$$recall = \frac{RP}{RP + FN} = \frac{RP}{n_{labels}}$$

4.3.5.4 Mean Average Precision

Der Wert der zuvor erklärten Average Precision berücksichtigt nur eine Klasse, wobei wie auch in diesem Versuch bei Objekterkennungsproblemen meist mehrere Klassen identifiziert werden müssen. Die Mean Average Precision (mAP) errechnet den Mittelwert aller Average Precision aller Klassen und ist damit eine der zentralen Metriken die hier und beim Vergleichen von Objekterkennungsmodellen Anwendung findet (Zeng, 2018).

$$mAP = \frac{\sum_{i=1}^K AP_i}{K}$$

Schlussendlich sollte aus den verschiedenen Modellen oder neuronalen Netzen das Beste ausgewählt und angewendet werden. Somit ergaben sich zwei Modelle, da einerseits das „stehend“ oder „liegend“ detektiert und auf der anderen Seite eine Identifikation von fünf verschiedenen Kühen erreicht werden sollte.

4.4 Training Objekteigenschaft „stehend“ bzw. „liegend“

Um die Detektoren für die Unterscheidung in „stehende“ und „liegende“ Kühe zu trainieren, wurden klassifizierte Bilder aus drei verschiedenen Stallabteilungen mit drei unterschiedlichen Kuhgruppen und je drei Kameraperspektiven gewählt. In allen Versuchen betrug die Trainingsgruppe 80 % der Bilder, in den Testgruppen wurden die verbleibenden 20 % genutzt. Jedoch wurden die Trainingsgruppen in aufbauende Stufen unterteilt, um bei den Ergebnissen etwaige Entwicklungen der Genauigkeiten beobachten zu können. Die Bilder blieben in den Unterteilungen immer in den jeweilig zugewiesenen Gruppen, sodass sie stets getrennt blieben. In den verschiedenen Versuchen wurden die Bilder meist wieder neu zugewiesen, weil für jedes Training ein Detektor trainiert worden ist. Ein Trainingsdurchlauf bis 80 % der Bilder dauerte in etwa 8 Stunden.

4.4.1 Versuch 1

Die Aufteilung der Bilder im ersten Versuch in eine Trainings- und Testgruppe entstand zufällig und ist wie folgt dargestellt.

Tabelle 3 Aufteilung der Bilder in Trainings- und Testgruppe mit Anzahlen der Label der jeweiligen Objekteigenschaften im ersten Versuch.

	Bilder	Label Liegend	Label Stehend
Trainingsgruppe (80 %)	465	640	1637
Testgruppe (20 %)	119	164	424

Die Anzahl klassifizierter „liegender“ Kühe insgesamt, also zusammen aus beiden Gruppen ergab 804, für „stehende“ Kühe 2061. Für die weitere Unterteilung der Trainingsgruppen entstanden folgende Werte.

Tabelle 4 Aufteilung der Bilder und Label auf die unterschiedlichen Trainingsgruppen im ersten Versuch.

Trainingsgruppe	Anzahl von Bildern	Label liegender Kühe	Label stehender Kühe
1	27	31	102
2	56	71	204
3	115	169	398
4	173	251	599
5	291	408	1019
6	465	640	1637

4.4.2 Versuch 2

Die Differenz der Labelanzahl von „stehenden“ und „liegenden“ Kühen aus dem ersten Versuch sollte im Versuch 2 verringert werden. Dafür wurden wie in Kapitel 3.4.3 beschrieben, neue Bilder extrahiert, in denen vermehrt „liegende“ Kühe gelabelt werden sollten. Es ergab sich dadurch eine höhere Anzahl von gelabelten Bildern, die folgendermaßen aufgeteilt wurden.

Tabelle 5 Aufteilung der Bilder in Trainings- und Testgruppe mit Anzahlen der Label der jeweiligen Objekteigenschaften im zweiten Versuch.

	Bilder	Label Liegend	Label Stehend
Trainingsgruppe (80 %)	686	1569	1715
Testgruppe (20 %)	174	393	445

Die Anzahl klassifizierter liegender Kühe lag in Summe bei 1962 Label, die Anzahl „stehender“ Kühe bei 2160 Label. In diesem Versuch wurden zwei weitere Trainingsgruppen, nämlich 7 und 8 hinzugefügt, damit untersucht werden konnte, wie sich der Verlauf der Präzision zwischen den Trainingsstufen entwickelt. Wenn es in den verschiedenen Trainingsgruppen unterschiedliche Ergebnisse gab, konnte eine Trainingsgruppe als Objekterkennungsmodell genutzt werden. Es muss also nicht zwingend die Trainingsstufe mit den der höchsten Menge an Bildern sein.

Die Bilder, welche neu dazukamen, wurden allerdings nur auf die letzten beiden Stufen, also 7 und 8, sowie die Testmenge verteilt. Lediglich diese zwei Trainingsgruppen sind auch neu trainiert worden, während die anderen unberührt blieben. Die ursprüngliche Testgruppe in Versuch 2 wurde nicht geändert, nur mit 55 neu klassifizierten Bilder ergänzt, damit die Testmenge 20 % der Gesamtbildmenge entsprach. Der Detektor für diesen Versuch war der aus Versuch 1.

Tabelle 6 Aufteilung der Bilder und Label auf die unterschiedlichen Trainingsgruppen im zweiten Versuch.

Trainingsgruppen	Anzahl von Bildern	Label liegender Kühe	Label stehender Kühe
1	27	31	102
2	56	71	204
3	115	169	398
4	173	251	599
5	291	408	1019
6	465	640	1637
7	576	1112	1673
8	686	1569	1715

4.4.3 Versuch 3

Der dritte Versuch war eine Wiederholung des zweiten Versuchs, jedoch wurde hier ein neuer Detektor trainiert. Hierbei wurden, wie im vorangegangenen Versuch insgesamt gesehen, die gleichen Bilder verwendet. Der Unterschied war, dass die Bilder zufällig auf die Trainingsgruppen und Testgruppe neu verteilt wurden. Somit enthielten beide Gruppen „neue Bilder“. Man kann auch von einem Durchmischen sprechen. Dennoch bleibt die Anzahl der Bilder für jede Trainingsgruppe in etwa gleich, nur die Anzahl der auf den Bildern vorhandenen Label wichen geringfügig voneinander ab. Das Ziel war es, durch den dritten Versuch herauszufinden, ob sich die Ergebnisse im Vergleich zum zweiten Versuch voneinander unterscheiden oder

ähneln. Zusätzlich wurde eine weitere Trainingsstufe, nämlich Trainingsgruppe 9, hinzugefügt. Es wurden keine neuen Bilder gelabelt oder klassifiziert und das Verhältnis von Trainings- und Testmenge blieb dabei gewahrt.

Tabelle 7 Aufteilung der Bilder in Trainings- und Testgruppe mit Anzahlen der Label der jeweiligen Objekteigenschaften im dritten Versuch.

	Bilder	Label liegend	Label stehend
Trainingsgruppe (80 %)	685	1553	1728
Testgruppe (20 %)	175	409	432

Insgesamt wurden für den dritten Versuch die höchste Anzahl gelabelter Bilder verwendet, die in der obigen Tabelle in Trainings- und Testgruppe aufgeteilt sind. Damit ergab sich eine Anzahl von 2367 als „liegend“ klassifizierter und 2597 als „stehend“ klassifizierter Kühe im Gesamten. Die untere Tabelle zeigt die Aufteilung der Bilder in den einzelnen Trainingsstufen.

Tabelle 8 Aufteilung der Bilder und Label auf die unterschiedlichen Trainingsgruppen im dritten Versuch.

Trainingsgruppen	Anzahl von Bildern	Label liegender Kühe	Label stehender Kühe
1	40	102	91
2	83	201	200
3	170	397	425
4	255	586	644
5	341	781	861
6	429	974	1087
7	514	1173	1298
8	600	1366	1513
9	685	1553	1728

4.5 Anwendung des Detektors/neuronalen Netzes auf fremde Umgebungen

Das nun aus den vorherigen Versuchen entstandene genaueste neuronale Netz sollte ausgewählt werden, um es in einer fremden Umgebung zu testen. Die Umgebung und die Tiere entsprachen nun nicht mehr dem, auf die der Detektor trainiert worden war.

Um einen möglichen Unterschied der Genauigkeit der Detektion zwischen den Tag- und Nachtaufnahmen zu erhalten, wurden die klassifizierten Bilder in Tag- und Nachtaufnahmen sortiert und getrennt getestet. Die zwei verschiedenen Umgebungen waren ebenso stets voneinander getrennt bearbeitet und getestet worden. Es ergaben sich zwei Versuche von jedem Laufstall, wobei zwar die Anzahl der Bilder gleich blieb, die Anzahl der Label jedoch im zweiten Versuch sank. Im ersten Versuch wurden alle Kühe gelabelt, welche auf den Bildern sichtbar waren. Im zweiten Versuch wurden nur die Kühe betrachtet, welche sich im Nahbereich der Kamera befanden. Dieser reichte bis in etwa zum Tor, das den Laufgang trennte, siehe Unterkapitel 3.4.2. Die Kamera auf der gegenüberliegenden Seite hatte ebenfalls das Sichtfeld bis zum Tor. Die Reduktion der Label, also aller Kühe die „hinter“ dem Tor stehen, im zweiten Versuch wurde manuell vorgenommen und sollte darstellen, ob sich die Ergebnisse des Detektors dadurch verändern.

4.5.1 Laufstall 1

Für den Laufstall 1 setzten sich die Versuche wie folgt zusammen.

4.5.1.1 Versuch 1

Die Bilder des ersten Versuchs im Laufstall 1 setzen sich wie im Unterkapitel 3.4.3 näher erläutert aus Tagaufnahmen und Nachtaufnahmen zusammen. Die Anzahlen der Label sind folgenderweise in der Tabelle dargestellt.

Tabelle 9 Aufteilung der Label von "stehenden" und "liegenden" Tieren in Tag- und Nachtaufnahmen im ersten Versuch des Laufstalls 1.

	Tag	Nacht
Gelabelte Kühe liegend	282	201
Gelabelte Kühe stehend	118	54



Abbildung 6 Klassifizieren der Kühe im Laufstall in „stehend“ und „liegend“ mit gelabelten Kühen im ersten Versuch.

4.5.1.2 Versuch 2

Im Versuch 2 bleibt die Anzahl der Bilder gleich dem ersten Versuch. Lediglich die Menge der Label hat sich, wie bereits beschrieben, reduziert.

Tabelle 10 Aufteilung der Label von "stehenden" und "liegenden" Tieren in Tag- und Nachtaufnahmen im zweiten Versuch des Laufstalls 1.

	Tag	Nacht
Gelabelte Kühe liegend	146	154
Gelabelte Kühe stehend	99	21



Abbildung 7 Klassifizieren der Kühe im Laufstall in „stehend“ und „liegend“ mit weniger gelabelten Kühen im zweiten Versuch. Hier wurden nur Label aus dem Nahbereich der Kamera verwendet.

4.5.2 Laufstall 2

Für den Laufstall 2 ergeben sich folgende Werte aus den zwei Versuchen.

4.5.2.1 Versuch 1

Im ersten Versuch des Laufstalls 2 wurden wie im Unterkapitel 3.4.3 näher beschrieben Tag- und Nachtaufnahmen verwendet. Die Anzahlen der Label von „liegenden“ oder „stehenden“ Kühen in Bezug auf Tag und Nacht sind der Tabelle zu entnehmen.

Tabelle 11 Aufteilung der Label von "stehenden" und "liegenden" Tieren in Tag- und Nachtaufnahmen im ersten Versuch des Laufstalls 2.

	Tag	Nacht
Gelabelte Kühe liegend	110	126
Gelabelte Kühe stehend	208	198



Abbildung 8 Klassifizieren der Kühe im Laufstall in „stehend“ und „liegend“ aus Sicht einer anderen Kamera im ersten Versuch des Laufstalls 2.

4.5.2.2 Versuch 2

Im zweiten Versuch wurden dieselben Bilder wie im ersten Versuch genutzt. Auch hier wurden wie im Laufstall 1 im zweiten Versuch die Menge der Label manuell reduziert.

Tabelle 12 Aufteilung der Label von "stehenden" und "liegenden" Tieren in Tag- und Nachtaufnahmen im zweiten Versuch des Laufstalls 2.

	Tag	Nacht
Gelabelte Kühe liegend	73	109
Gelabelte Kühe stehend	133	126



Abbildung 9 Klassifizieren der Kühe im Laufstall in „stehend“ und „liegend“ mit weniger gelabelten Kühen aus Sicht einer anderen Kamera im zweiten Versuch. Auch hier wurden die Kühe nur im Nahbereich der Kamera klassifiziert, die verwendeten Bilder blieben dieselben.

4.6 Training Individualisierung der Kühe

Statt den bisher zwei Klassen als „stehend“ oder „liegend“ klassifizierter Kühe, sollte in einer Gruppe von fünf Kühen die Individuen erkannt werden. In diesem Fall stellt ein einzelnes Tier eine Klasse dar, dementsprechend sind fünf Klassen vorhanden. Wie schon im Kapitel 4.2.3 erläutert, wurde für jede einzelne Kuh im Vorfeld bestimmte Merkmale, die sie anhand der unterschiedlichen Musterung des Fellkleids aufwiesen, notiert. Dadurch konnten sie leichter auseinandergehalten werden. Nicht immer waren alle Tiere gleichzeitig auf den Bildern sichtbar, weshalb die Anzahl der Label einzelner Kühe variierte. Für das Klassifizieren wurden Videos von drei unterschiedlichen Tagen genutzt, die bereits in den ersten Versuchen für das Klassifizieren in „stehend oder liegend“ verwendet wurden.

Das gesichtete Videomaterial hatte eine Länge von etwa drei Stunden. In der nachfolgenden Tabelle sind die Bilder der einzelnen Kühe in das übliche Verhältnis von Trainings- und Testgruppe aufgeteilt.

Tabelle 13 Aufteilung der Bilder der einzelnen Kühe in Test- und Trainingsgruppe.

	Bilder gesamt	Testgruppe	Trainingsgruppe
Anzahl der Bilder	200	40	160
Label Kuh_1	192	40	152
Label Kuh_2	200	40	160
Label Kuh_3	200	40	160
Label Kuh_4	182	35	147
Label Kuh_5	200	40	160

Auf den klassifizierten Bildern konnten die meisten Kühe auf jedem Bild gelabelt werden. Lediglich Kuh 1 und Kuh 2 hatten etwas weniger Label als die anderen.

4.7 Manuelle Messung der Steh- und Liegezeiten der individualisierten Kühe

Die Detektoren die einerseits das Stehen und Liegen der Tiere, andererseits das Tier als ein Individuum erkennen sollen, können Aussagen über ein einzelnes Tier oder Gruppen ermöglichen, die wieder auf die Gesamtheit der Tiere bezogen, getroffen werden können. Der Ansatz für die Messung der Steh- und Liegezeiten der einzelnen Kühe begründete sich zu Beginn in der Festlegung der Daten. Aus dem rohen Videomaterial wurden zwei aufeinanderfolgende Tage ausgesucht. Die erste Methode sollte eine manuelle Erfassung der Steh- und Liegezeiten der einzelnen Kühe sein, um sie später mit einer automatisierten Auswertung vergleichen zu können. Aus zeitlichen und arbeitsintensiven Gründen wurden aus jeder Stunde eines Tages jeweils 3 Videos herausgesucht. Sie hatten einen zeitlichen Abstand von 20 Minuten zueinander und eine jeweilige Dauer von 117 Sekunden, fast zwei Minuten. In einer erstellten Tabelle wurde für jede Kuh in Sekunden festgehalten, wie lange sie steht oder liegt. Für jede Kuh gab es aus 48 Stunden jeweils pro Stunde sechs Werte (drei Mal „stehend“ und drei Mal „liegend“), insgesamt also 288 Zeitwerte mit Angabe, ob sie steht oder liegt. Nachfolgend ein Beispiel für die Datenerfassung für alle fünf Tiere innerhalb einer Stunde mit drei Videos. Im Beispiel zu sehen sind alle fünf Kühe um die Stunde 0 und liegen.

Die jeweiligen Steh- und Liegezeiten für jede Kuh wurden getrennt voneinander zusammenaddiert und konnten so verglichen werden. Mit der manuellen Methode gab es je Video 585 Sekunden für „stehend“ oder „liegend“ zu verteilen. Das begründet sich in der Länge eines Videos von 117 Sekunden, die mit der Anzahl der Kühe multipliziert wird. Die manuelle Methode wurde bei der Darstellung der Differenzen zwischen beiden Möglichkeiten als Standard gewählt.

Tabelle 14 Manuell erfasste Steh- und Liegezeiten der einzelnen Kühe in Sekunden für jedes einzelne Video zur Stunde 0.

Tag 13	Kuh 1		Kuh 2		Kuh 3		Kuh 4		Kuh 5		Video in Sek.
Stunde und Videoname	stehend in Sek.	liegend in Sek.	stehend in Sek.	liegend in Sek.	stehend in Sek.	liegend in Sek.	stehend in Sek.	liegend in Sek.	stehend in Sek.	liegend in Sek.	
0											
R_20171013_000021	0	117	0	117	0	117	0	117	0	117	117
R_20171013_002001	0	117	0	117	0	117	0	117	0	117	117
R_20171013_004139	0	117	0	117	0	117	0	117	0	117	117

4.8 Automatisierte Messung der Steh- und Liegezeiten der Kühe als Gruppe anhand eines Tages

4.8.1 Vergleich zur manuellen Methode

Um im ersten Schritt einen Vergleich zu der manuellen Methode zu erhalten, wurden exakt die gleichen Videos für die automatische Auswertung benutzt, da man aus zeitlichen und arbeitsintensiven Gründen bei der manuellen Auswertung aus zwei Tagen jeweils drei Videos pro Stunde verwendete.

Für die automatisierte Messung der Steh- und Liegezeiten wurde der Detektor für die Objekteigenschaften „stehend“ und „liegend“ genutzt. Aus jedem Video wurde ein Bild pro Sekunde vom Algorithmus extrahiert. Dabei identifizierte der Detektor für jedes Bild wie viele Tiere „stehen“ oder „liegen“. Aufgrund der Länge von 117 Sekunden wurden folglich 117 Bilder ausgewertet. Dementsprechend gilt für ein Bild die Zeiteinheit von einer Sekunde. Je nachdem wie viele Detektionen der Objekteigenschaften von den fünf Kühen erfasst wurden, konnten die Daten gesammelt werden. Im Idealfall sollten für jedes Rind 117 Werte pro Video vorhanden sein.

Für die Auswertung wurden in einer Exceltabelle sowohl im manuellen als auch im automatisierten Verfahren die erfassten Steh- und Liegezeiten der Kühe innerhalb einer Stunde zusammenaddiert. Daneben wurden auch die einzelnen Zeitdifferenzen der „stehenden“ und „liegenden“ Kühe zwischen der manuellen und automatisierten Methode mittels Excel errechnet. Da die Messung der Steh- und Liegezeiten der einzelnen Kühe wie im vorigen Kapitel 4.7 für

einzelne Kühe dargestellt werden sollte, konnte anhand der gleichen Daten auch eine Darstellung für eine Gruppe durch das Addieren der Werte von den einzelnen Kühen für die Gruppe erzeugt werden.

Aus der Summe der Sekunden von „stehenden“ und „liegenden“ Kühen aus einer Stunde, sowohl im manuellen als auch im automatisierten Verfahren, sollte mit Hilfe von Excel wieder eine Differenz gebildet werden, um so die Unterschiede hinsichtlich der Genauigkeit und Zuverlässigkeit der automatischen Auswertung zu validieren. Für das Extrahieren der Bilder und das Sammeln der Daten musste ein eigenes Programm geschrieben werden, um die Steh- und Liegezeiten zu erfassen (Schütz, 2023).

Das Auswerten eines zweiten Tages sollte die Möglichkeit geben, Unterschiede oder Ähnlichkeiten in der Aktivität der Tiere an anderen Tagen festzustellen. Zudem sollte dadurch auch dargestellt werden können, wie sich eine Gruppe im Verlaufe eines Tages verhält. Auch das Verhalten einzelner Tiere in Relation zur Gruppe oder dem Rest der Tiere sollte so dargestellt werden können.

Tabelle 15 Manuelle und automatisierte Gruppenauswertung der ersten zwei Stunden mit 6 Videos in Excel im Vergleich. Alle Zahlenangaben sind in Sekunden.

Tag 12GRUPPE	manuell		automatisiert		Differenz „Stehend“	Differenz „Liegend“	Summe manuell	Summe automati- siert	Differenz
	„Ste- hend“	„Lie- gend“	„Stehend“	„Liegend“					
R_2017101 2_000125	117	468	157	415	40	-53	585	572	-13
R_2017101 2_001905	468	117	450	36	-18	-81	585	486	-99
R_2017101 2_004043	351	234	346	120	-5	-114	585	466	-119
R_2017101 2_010023	234	351	230	363	-4	12	585	593	8
R_2017101 2_012003	117	468	117	402	0	-66	585	519	-66
R_2017101 2_014141	117	468	117	400	0	-68	585	517	-68

4.8.2 Automatisierte Auswertung eines gesamten Tages

Anhand der Validierung des automatisierten Systems im Vergleich zur manuellen Auswertung war es nun möglich auch einen gesamten Tag zu analysieren. Dafür wurden die durchgängigen Aufzeichnungen eines Tages, statt drei Videos aus einer Stunde, verwendet. Die Abfolge der Arbeitsschritte blieben dabei gleich. Aus allen Videos eines gesamten Tages wurden durch den Algorithmus ein Bild pro Sekunde extrahiert, welches durch den Detektor auf „stehende“ und „liegende“ Rinder getestet wurde. Anschließend erfolgte die Auswertung für die Gruppe von Kühen, die tabellarisch darstellte, wie viel zu welcher Tages- oder Nachtzeit „gestanden“ oder „gelegen“ wurde. Die Werte der einzelnen Kühe und Zeitstunden wurden abhängig von der Objekteigenschaft zusammenaddiert. Diese Methode ermöglichte eine Betrachtung der Gruppe über 24 Stunden hinweg und konnte dadurch das Steh- und Liegeverhalten der Rinder im Verhältnis zur Gruppe darstellen.

5 Ergebnisse

5.1 Training „stehender“ / „liegender Kühe“

5.1.1 Versuch 1

Die Leistung des trainierten Modells wurde durch das Vergleichen der manuell klassifizierten Label aus der Testgruppe mit den Ergebnissen des automatisierten Objekterkennungsmodells geprüft. Die aus den sechs Trainingsgruppen erreichten Ergebnisse sind in der folgenden Tabelle dargestellt.

Tabelle 16 Darstellung der Präzisionen der einzelnen Trainingsgruppen von "stehenden" und "liegenden" Kühen in Abhängigkeit von der Anzahl der Bilder und Label im ersten Versuch.

Trainingsgruppe	1	2	3	4	5	6
Anzahl der Bilder	27	56	115	173	291	465
Label Kühe liegend	31	71	169	251	408	640
Label Kühe stehend	102	204	398	599	1019	1637
Präzision liegender Kühe	92,83 %	94,89 %	95,92 %	97,2 %	97,44 %	97,52 %
Präzision stehender Kühe	96,18 %	97,84 %	99 %	99,1 %	99,25 %	99,26 %
mAP	94,51 %	96,36 %	97,46 %	98,1 %	98,35 %	98,39 %

Die höchste Präzision erreichte die sechste Trainingsgruppe. Hier lag die Präzision der als „liegend“ klassifizierten Kühe bei 97,52 % und der als „stehend“ klassifizierten bei 99,26 %. Der Durchschnitt beider Präzisionen ergibt die mAP, welche bei 98,39 % lag. Es gab einen Unterschied zwischen der Präzision von „liegenden“ und „stehenden“ Kühen. Die Genauigkeit der „liegend“ gelabelten Kühe ist um 1,74 % niedriger als die der „stehend“ gelabelten Kühe. Die nachstehend abgebildete Grafik zeigt die Präzision in Abhängigkeit von der Anzahl der Label der jeweiligen Klassen.

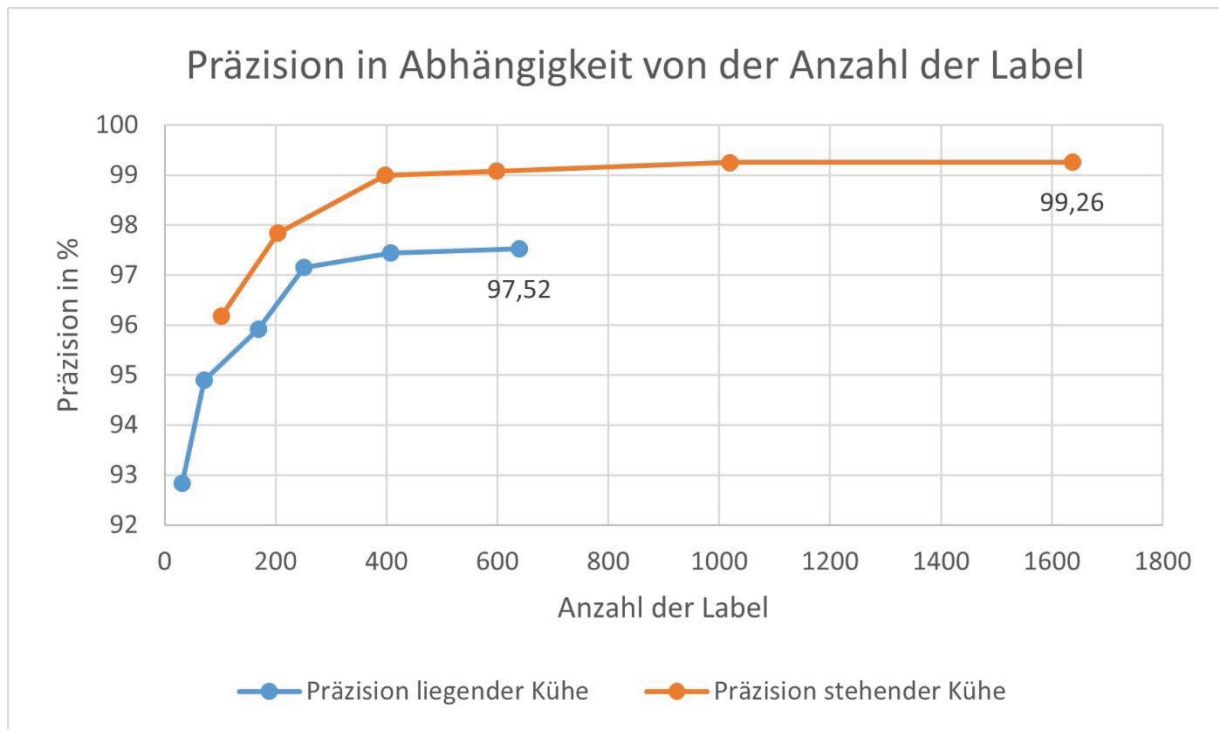


Abbildung 10 Präzisionen der Trainingsgruppe von „stehenden“ und „liegenden“ Kühen in Abhängigkeit von der Anzahl der jeweilig erstellten Label im ersten Versuch.

5.1.2 Versuch 2

Im zweiten Versuch wurden die 276 neu klassifizierten Bilder miteinbezogen. Diese wurden allerdings nur in den letzten beiden Trainingsgruppen eingesetzt, alle anderen Stufen blieben gleich und wurden nicht trainiert. Durch das Hinzufügen der Trainingsgruppen 7 und 8 sollte veranschaulicht werden, wie sich der Verlauf der Präzision zwischen den Trainingsgruppen entwickelt. Insgesamt gab es also 8 Trainingsgruppen, wobei nur die letzten zwei mit den neuen Bildern trainiert wurden. Die Differenz zwischen den Label von „stehenden“ und „liegenden“ Kühe konnte in den letzten beiden Stufen verringert werden. Wie in der Tabelle ersichtlich wird, ist die Anzahl der Label für „liegende“ Kühe gestiegen und die Differenz zu den „stehenden“ Kühen auf 146 Label gesunken.

Die Genauigkeiten im zweiten Versuch wurden verbessert. Die höchsten Präzisionen hatte die achte Trainingsgruppe. Die Präzision der „liegenden“ Kühe lag mit 98,86 % bei 1559 gelabelten Kühen, die der „stehenden“ Kühe bei 99,65 % mit 1715 gelabelten Kühen. Die mAP betrug 99,26 %.

Tabelle 17 Darstellung der Präzisionen der einzelnen Trainingsgruppen von "stehenden" und "liegenden" Kühen in Abhängigkeit von der Anzahl der Bilder und Label im zweiten Versuch.

Trainingsgruppe	1	2	3	4	5	6	7	8
Anzahl der Bilder	27	56	115	173	291	465	576	686
Label Kühe liegend	31	71	169	251	408	640	1112	1569
Label Kühe stehend	102	204	398	599	1019	1637	1673	1715
Präzision liegender Kühe	94,31 %	95,44 %	96,37 %	97,66 %	98,3 %	98,06 %	98,6 %	98,86 %
Präzision stehender Kühe	95,25 %	96,8 %	97,21 %	97,47 %	99,13 %	98,48 %	99,25 %	99,65 %
mAP	94,78 %	96,12 %	96,79 %	97,57 %	98,72 %	98,45 %	98,93 %	99,26 %

Bis zu der Menge von 640 Label „liegender“ Kühe ähneln die Graphen der Grafik sehr dem ersten Versuch. Anschließend verändern sich die Präzisionen der Klassen durch die neu eingefügten Bilder, die jedoch nur in den letzten beiden Trainingsgruppen verwendet wurden. Auch in der obigen Tabelle wird ersichtlich, dass die Anzahlen der Label beider Klassen sich erst in der siebten Trainingsstufe angleichen und sich in der Grafik dann die Graphen annähern und fast linear verbleiben.

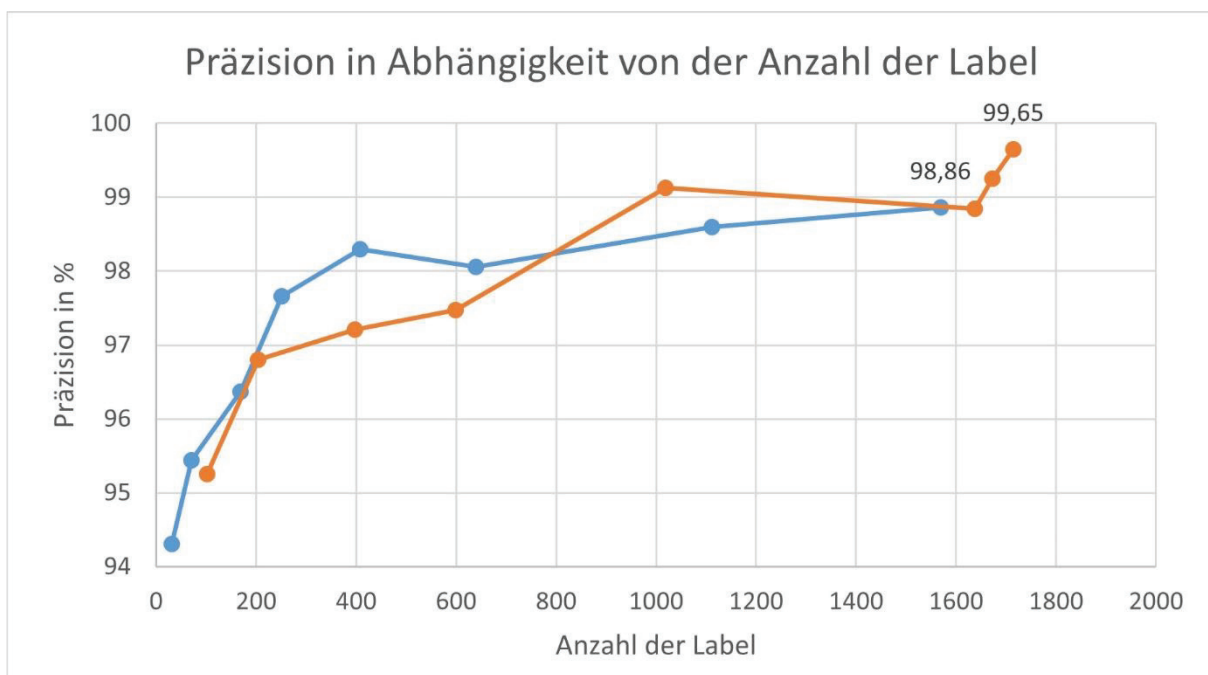


Abbildung 11 Präzisionen der Trainingsgruppe von „stehenden“ und „liegenden“ Kühen in Abhängigkeit von der Anzahl der jeweilig erstellten Label im zweiten Versuch.

5.1.3 Versuch 3

Im dritten Versuch wurde, wie bereits beschrieben, die gleiche Bildmenge genutzt wie im Versuch 2. Allerdings wurden die Bilder durchmischt und den Trainingsgruppen und der Testgruppe zufällig neu zugeordnet. In diesem Versuch wurde eine Trainingsstufe bei 70 % der genutzten Bildmenge hinzugefügt, um noch weitere Trends beobachten zu können. Die nachfolgende Tabelle zeigt die Ergebnisse der einzelnen Trainingsdurchläufe.

Tabelle 18 Darstellung der Präzisionen der einzelnen Trainingsgruppen von "stehenden" und "liegenden" Kühen in Abhängigkeit von der Anzahl der Bilder und Label im dritten Versuch.

Trainings- gruppe	1	2	3	4	5	6	7	8	9
Anzahl der Bilder	40	83	170	255	341	429	514	600	685
Label Kühe liegend	102	201	397	586	781	974	1173	1366	1553
Label Kühe stehend	91	200	425	644	861	1087	1298	1513	1728
Präzision liegender Kühe	96,18 %	97,89 %	98,29 %	98,42 %	98,77 %	99 %	98,74 %	98,82 %	99,13 %
Präzision stehender Kühe	96,12 %	97,75 %	98,52 %	98,48 %	99,2 %	99,13 %	99,17 %	99,04 %	99,26 %
mAP	96,15 %	97,82 %	98,40 %	98,45 %	98,98 %	99,06 %	98,96 %	98,93 %	99,21 %

Die höchsten Präzisionen sind aus der neunten Trainingsgruppe hervorgegangen und sind in der obigen Tabelle hervorgehoben. Die Präzision der „liegenden“ Kühe lag bei 99,13 % mit 1553 Label, der „stehenden“ Kühe bei 99,26 % mit 1728 Label. Der Durchschnitt beider Klassen lag bei 99,21 %. Die Verteilung der Label in den jeweiligen Stufen der „liegenden“ und „stehenden“ Kühe hat sich in diesem Versuch verändert. Die Präzision der „liegenden“ Kühe hat sich im Vergleich zu den anderen Versuchen gesteigert, nämlich um 1,61 % aus dem ersten und 0,27 % aus dem zweiten Versuch.




Abbildung 12 Präzisionen der Trainingsgruppe von „stehenden“ und „liegenden“ Kühen in Abhängigkeit von der Anzahl der jeweilig erstellten Label im dritten Versuch.

An der unteren Grafik für den dritten Versuch kann man erkennen, dass die Graphen beider Klassen fast linear zueinander ansteigen, da die Menge der Label für die Klassen ausgeglichen wurde und sich die durchschnittliche Präzision der liegenden Kühe durch mehr Label verbessert hat. Gleichzeitig zeigt die obige Grafik für die Präzision aber auch, dass die Genauigkeiten ab ungefähr 900 Label nicht mehr steigen, wie es beispielsweise innerhalb der ersten 400 Label der Fall ist. Dennoch sind die Graphen der Präzisionen beider Klassen dicht beieinander und unterscheiden sich nicht mehr so, wie die in den bisherigen Versuchen.




Abbildung 13 Das Verhältnis zwischen der Anzahl der Label und Bilder von den Kühen und ihren Objekteigenschaften zeigt die einzelnen Graphenpunkte der Trainingsgruppen 1 bis 9 aus Versuch 3.

Nachdem das Objekterkennungsmodell mittels der Trainingsdaten trainiert und anschließend mit den Testdaten validiert wurde, wurde es auf neue, nicht bekannte Bilder angewendet. Dafür wurde das trainierte Objekterkennungsmodell mit der höchsten mAP aus Versuch 3 gewählt (Trainingsgruppe 9).

Tabelle 19 Darstellung der Ergebnisse des dritten Versuchs mit den wichtigsten Parametern zur Bewertung der Leistung eines Modells.

Trainingsgruppe	Precision	Recall	Average IoU	mAP	TP	FP	FN
1	93,53 %	94,53 %	0,79	96,15 %	795	55	46
2	97,02 %	96,67 %	0,83	97,82 %	813	25	28
3	94,80 %	97,50 %	0,96	98,40 %	820	45	21
4	97,27 %	97,38 %	0,83	98,45 %	819	23	22
5	99,04 %	98,34 %	0,89	98,98 %	827	8	14
6	98,81 %	98,69 %	0,89	99,06 %	830	10	11
7	98,34 %	98,57 %	0,86	98,96 %	829	14	12
8	98,69 %	98,45 %	0,87	98,93 %	828	11	13
9	98,57 %	98,34 %	0,88	99,21 %	827	12	14

An dieser Stelle soll kurz auf die weiteren Ergebniswerte aus der besten Trainingsgruppe eingegangen werden. Sie sind in der obigen Tabelle für jede Trainingsgruppe zusammengefasst und bilden den Durchschnitt oder die Summe der zwei verschiedenen Klassen. Folgend sind nur die Werte für die höchste Trainingsgruppe für beide Objekteigenschaften dargestellt.

Tabelle 20 Aufgliederung der präzisesten Trainingsgruppe in die Objekteigenschaften mit den wichtigsten Parametern zur Bewertung eines Modells.

Trainingsgruppe	Eigenschaft	Precision	Recall	Average IoU	AP	TP	FP	FN
9	Liegend	99,50 %	98,04 %	0,9	99,13 %	401	2	8
	Stehend	97,71 %	98,61 %	0,86	99,26 %	426	10	6

Die average precision oder durchschnittliche Genauigkeit welche als Metrik der Precision vorgezogen wird, da sie von allen Tieren einer Klasse den Durchschnitt berücksichtigt, lag für die liegenden Tiere bei 99,13 %. Das bedeutet, dass die Tiere, welche vom Modell erkannt wurden, zu 99,13 % richtig klassifiziert sind. Der Recall, der beschreibt, ob das Objekterkennungsmodell jedes Objekt identifiziert hat, welches er detektieren sollte, lag bei 98,04 %. Somit wurden 98,04 % der Tiere die liegen, auch als solche erkannt. Die durchschnittliche IoU, also die Überlappungsfläche der Bounding Boxes und der Ground Truth Label lag bei 90 %. Hinsichtlich von Falschklassifizierungen wurden lediglich zwei liegende Tiere als solche identifiziert und 8 liegende Tiere wurden nicht erkannt. Im Gegensatz dazu wurden 401 liegende Kühe, die erkannt wurden, als richtig und vorhanden ermittelt.

Bei den „stehenden“ Kühen wurden hinsichtlich der durchschnittlichen Präzision 99,26 % der Tiere korrekt in die Klasse eingeteilt. Das Modell war in der Lage 98,61 % der „stehenden“ Kühe zu identifizieren. Die durchschnittliche IoU von 86 % zeigt auch, dass das Modell die Position der Kühe mit höherer Sicherheit bestimmen kann.

Das Modell ist insgesamt in der Lage die meisten Kühe als richtig zu klassifizieren. Auch die Werte des Recalls beschreiben eine Leistung, dass die meisten Kühe vom Modell detektiert werden. Die Ergebnisse der FP und FN zeigen auf, dass das neuronale Netz gelegentlich falsche Ergebnisse liefert.



Abbildung 14 Eigenständige Erkennung der Objekteigenschaft durch den Detektor. Die über den Boxen stehenden Informationen sind die Objekteigenschaft und die jeweilige Präzision, mit der sie detektiert wurde.



Abbildung 15 Auch auf dieser Grafik identifiziert der Detektor eine zum größten Teil verdeckte Kuh und ist fähig zwei weitere Kühe zu klassifizieren, die durch das Fressfanggitter unregelmäßig verdeckt werden.




Abbildung 16 Hier wird eine Kuh korrekt klassifiziert, die zum größten Teil durch eine andere Kuh verdeckt wird.

5.2 Anwendung des Detektors/ neuronalen Netzes auf fremde Umgebungen

Die Anwendung des trainierten Modells sollte nun auf fremde Umgebungen angewendet werden. Im Folgenden werden die Ergebnisse der Laufställe einzeln dargestellt, wobei im ersten Versuch alle Rinder betrachtet wurden und im zweiten Versuch die Rinder, welche sich im Nahbereich der Kamera aufhielten.

5.2.1 Laufstall 1

5.2.1.1 Versuch 1

Im ersten Versuch war die Anzahl der Label zwischen „stehenden“ und „liegenden“ Kühen unterschiedlich. Die Bilderaufteilung zwischen Tag- und Nachtaufnahmen hingegen ähnlich. In der unteren Tabelle sind die Ergebnisse des ersten Durchgangs dargestellt.

Tabelle 21 Durchschnittliche Präzisionen der Objekteigenschaften in Abhängigkeit von der Anzahl der Bilder, Label, sowie Tag- und Nachtaufnahmen im ersten Versuch des Laufstalls 1.

	Tag	Nacht
Anzahl der Bilder	47	33
Label Kühe liegend	282	201
Label Kühe stehend	118	54
Durchschnittliche Präzision Kühe liegend	21,08 %	15,88 %
Durchschnittliche Präzision Kühe stehend	66,92 %	26,15 %

Die Genauigkeiten der „stehenden“ Kühe sind höher als die der „liegenden“ Kühe. Auch im Vergleich zwischen Tag und Nacht ist dasselbe bei den Objekteigenschaften feststellen. Während „stehende“ Kühe am Tage zu fast 67 % korrekt identifiziert werden, erreicht die Genauigkeit der „liegenden“ Kühe bei Nacht 15,88 %. Beide Klassen haben jedoch gemeinsam höhere Werte am Tag als in der Nacht. Für die „liegenden“ Kühe waren mehr Label vorhanden als für die „stehenden“, doch die Ergebnisse waren unterschiedlich. Die folgende Grafik veranschaulicht die durchschnittliche Genauigkeit beider Klassen im Vergleich der Tag- und Nachtaufnahmen.




Abbildung 17 Gegenüberstellung „liegender“ und „stehender“ Kühe mit Angabe der durchschnittlichen Präzision für die Detektion während des Tages und der Nacht im ersten Versuch mit mehr Label.

Im ersten Versuch wurden alle Kühe klassifiziert, welche beim Bearbeiten der Bilder identifiziert werden konnten. Folgend zu sehen ist das Ergebnis, wie der Detektor die Identifikationen tätigt und mit welcher Präzision er sie bewertet.

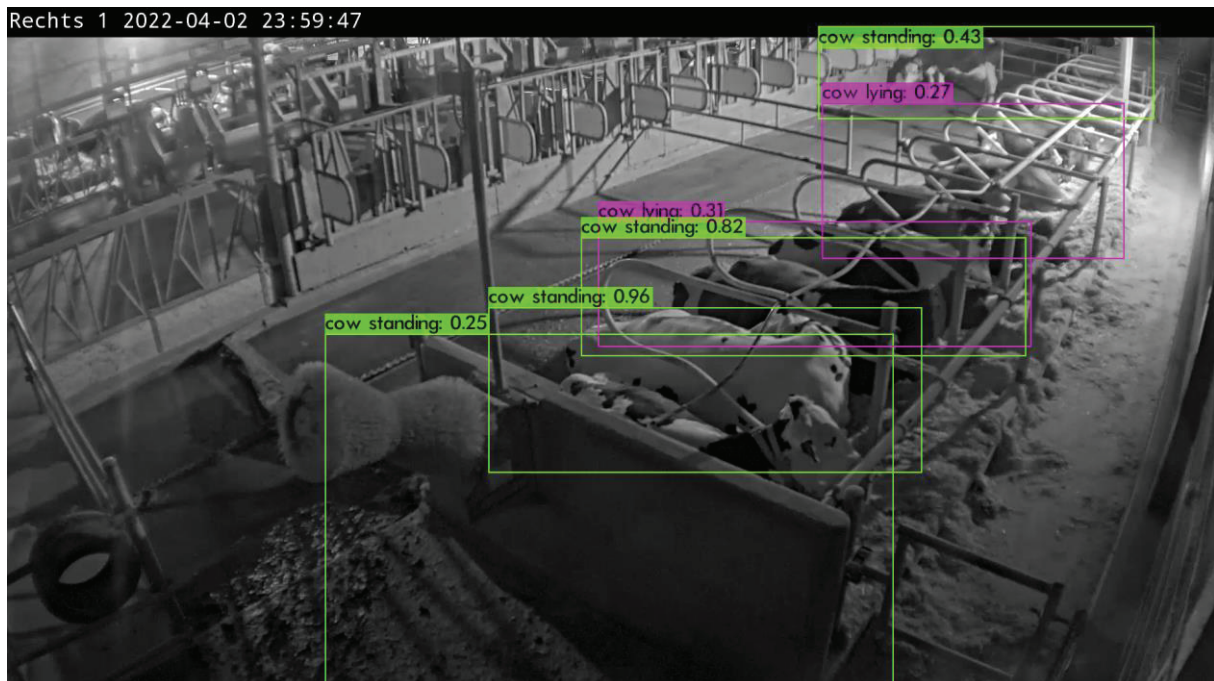


Abbildung 18 Darstellung von falschen Ergebnissen vom Objekterkennungsmodell bei drei „stehenden“ Kühen die offensichtlich „liegen“.

In der obigen Nachtaufnahme ist zu sehen, dass bis auf eine einzelne Kuh alle anderen liegen. Jedoch wurden insgesamt vier Bounding Boxes für „stehende“ Kühe erstellt. Die Kuh, die im Hintergrund steht, wird mit einer Genauigkeit von 43 % als „stehend“ beschrieben. Die Bounding Box um sie herum ist zu beiden Seiten nach links und rechts weit gefasst und schließt Stalleinbauten mit ein. Die zwei als liegend markierten Kühe werden mit einer sehr Präzision von maximal 31 % als solche bewertet. Die Kuh im hinteren Bereich liegt im Sichtfeld der Kamera bis auf die Stalleinbauten frei und wurde erkannt. Auch die vordere liegende Kuh, die als liegend erkannt wurde, hebt sich geringfügig von den anderen ab und wird erkannt. Doch eine ganze weitere Anzahl von Kühen wird entweder nicht erkannt oder falsch identifiziert.



Abbildung 19 Kameraperspektive von der anderen Stallseite. Nähere Kühe werden hinsichtlich der Objekteigenschaft erkannt. Weiter entfernte Kühe werden nicht sicher oder falsch detektiert.

Von der anderen Perspektive, siehe obige Abbildung, werden die Kühe, welche näher zur Kamera sind, präzise identifiziert. Die anderen, welche weiter von der Kamera entfernt sind, haben geringere Genauigkeiten. Die einzelne Kuh, die allein auf dem Laufgang steht, wird präzise und richtig erkannt. Auch die ersten beiden liegenden Kühe, von denen nicht viel verdeckt ist, werden korrekt als liegend erkannt. Die dritte liegende Kuh von vorne wird als „stehend“ identifiziert, obwohl sie liegt. Eine weitere „stehende“ Kuh wurde korrekt identifiziert, von ihrer Körperfläche ist viel zu sehen. Dagegen wird hinter dieser Kuh eine weitere identifiziert, fälschlicherweise jedoch als „stehend“.

5.2.1.2 Versuch 2

Der zweite Versuch mit der gleichen Anzahl an Bildern, aber weniger Label, reduzierte nicht den Unterschied der Anzahl von „stehenden“ und „liegenden“ Kühen wie in der folgenden Tabelle ersichtlich wird. Allerdings wurden nicht wie im ersten Versuch alle sichtbaren Rinder betrachtet, sondern die, welche sich im Nahbereich der Kamera befanden. Dies galt für beide Kameraperspektiven, sodass damit alle Rinder erfasst werden konnten.

Tabelle 22 Durchschnittliche Präzisionen der Objekteigenschaften in Abhängigkeit von der Anzahl der Bilder, Label, sowie Tag- und Nachtaufnahmen im zweiten Versuch des Laufstalls 1.

	Tag	Nacht
Anzahl der Bilder	47	33
Label Kühe liegend	146	154
Label Kühe stehend	99	21
Durchschnittliche Präzision Kühe liegend	39,8 %	20,42 %
Durchschnittliche Präzision Kühe stehend	79,32 %	58,68 %

Dennoch erhöhte sich in beiden Klassen die Präzision, sowohl in den Tag- als auch Nachtaufnahmen. Die „stehenden“ Kühe wurden mit höheren Genauigkeiten identifiziert als die „liegenden“. Auch der bisherige Unterschied, dass die Tagaufnahmen präziser in der Genauigkeit sind als die der Nachtaufnahmen bleibt bestehen. Die untere Grafik zeigt wiederholt den Kontrast, wie „stehende“ Kühe am Tag identifiziert werden und wie „liegende“ Kühe in der Nacht detektiert werden.




Abbildung 20 Gegenüberstellung „liegender“ und „stehender“ Kühe mit Angabe der durchschnittlichen Präzision für die Detektion während des Tages und der

Die untere Grafik zeigt das Ergebnis des Detektors nach dem Reduzieren der Label. Hier ist die Gruppe der zu klassifizierenden Kühe am Tage zu sehen. Deutlich zu sehen ist auch die Abtrennung des Laufganges, der auch die Grenze für die Label darstellt. Hier wurden alle Kühe bis auf eine liegende Kuh präzise erkannt.




Abbildung 21 Bis auf eine Kuh, werden alle anderen richtig detektiert und korrekt klassifiziert.

Im nächsten Bild, einige Minuten später, wird auch die dahinter liegende Kuh identifiziert. Sie wird zwar nicht mit einer hohen Präzision beschrieben, aber sie liegt etwas freier da, weil die vordere liegende Kuh eine andere Schlafposition eingenommen hat und dadurch mehr von der hinteren Kuh sichtbar wird.




Abbildung 22 Bis zu der Absperrung auf dem Laufgang werden alle Kühe detektiert und korrekt klassifiziert.

5.2.2 Laufstall 2

Im Laufstall 2 sind die Kameras auf den gleichen Seiten montiert wie im Laufstall 1. Jedoch müssen sie höher gesetzt worden sein, da sich der Blickwinkel verändert hat. Auch in diesen beiden Versuchen ist die Anzahl der Label für „stehende“ Kühe höher als die der „liegenden“.

5.2.2.1 Versuch 1

Die Ergebnisse zeigen, dass die Präzision der „liegenden“ Kühe am Tage höher ist als die der „stehenden“ Kühe am Tag. In der Nacht sind die „liegenden“ Kühe geringer identifizierbar als die „Stehenden“. Wie im ersten Laufstall bleibt der Trend in diesem Versuch aber gleich, dass „liegende“ Kühe am Tag mit höherer Präzision identifiziert werden als in der Nacht. Die höchsten Genauigkeiten der Reihenfolge nach waren „liegende“ Kühe am Tag, gefolgt von „stehenden“ Kühen in der Nacht und „liegende“ Kühe in der Nacht. „Stehende“ Kühe wurden am Tag selten identifiziert.

Tabelle 23 Durchschnittliche Präzisionen der Objekteigenschaften in Abhängigkeit von der Anzahl der Bilder, Label, sowie Tag- und Nachtaufnahmen im ersten Versuch des Laufstalls 2.

	Tag	Nacht
Anzahl der Bilder	38	42
Label Kühe liegend	110	126
Label Kühe stehend	208	198
Durchschnittliche Präzision Kühe liegend	26,87 %	18,12 %
Durchschnittliche Präzision Kühe stehend	6,97 %	21,72 %

In diesem Versuch werden „stehende“ Kühe mit höherer Präzision in der Nacht als am Tag detektiert werden. Ein Unterschied zwischen 6,97 % und 21,72 % Genauigkeit der „stehenden“ Kühe am Tag und in der Nacht ist vorhanden. Die Ergebnisse sind innerhalb der Klassen und den Faktoren Tag und Nacht sehr unterschiedlich.




Abbildung 23 Gegenüberstellung „liegender“ und „stehender“ Kühe des Laufstalls 2 mit Angabe der durchschnittlichen Präzision für die Detektion während des Tages und der Nacht im ersten Versuch mit mehr Label.

In der folgenden Nachtaufnahme des Laufstalls 2 ist erkennbar, dass das Modell Einrichtungsgegenstände des Stalls als „stehende“ Kuh klassifiziert. In zwei Fällen finden außerdem Falschklassifizierungen statt. Eine Kuh wird als „stehend“ klassifiziert, obwohl sie liegt und andersherum steht eine Kuh und wird als „liegend“ klassifiziert.



Abbildung 24 Das Objekterkennungsmodell detektiert Stalleinbauten als „stehende“ Kuh.

Auch im nächsten Bild werden zwei „stehende“ Kühe im Hintergrund gleichzeitig als „liegend“ identifiziert, obwohl sie am Fressgitter stehen. Tiere, welche näher zur Kamera stehen, werden mit einer höheren Sicherheit als richtig klassifiziert. Verdeckt stehende Kühe werden allerdings auch hier wieder fälschlicherweise als „liegend“ detektiert.




Abbildung 25 Stalleneinrichtung und Tiere werden falsch identifiziert und klassifiziert.

5.2.2.2 Versuch 2

Wie im zweiten Versuch des Laufstalls 1 wurde die Bildmenge nicht verändert. Auch hier wurden wieder nur die Rinder betrachtet, welche sich im Nahbereich der Kamera befanden. Dadurch reduzierte sich die Anzahl der Label und die Genauigkeiten erhöhten sich.

Tabelle 24 Durchschnittliche Präzisionen der Objekteigenschaften in Abhängigkeit von der Anzahl der Bilder, Label, sowie Tag- und Nachtaufnahmen im zweiten Versuch des Laufstalls 2.

	Tag	Nacht
Anzahl der Bilder	38	42
Label Kühe liegend	73	109
Label Kühe stehend	133	126
Durchschnittliche Präzision Kühe liegend	40,49 %	20,94 %
Durchschnittliche Präzision Kühe stehend	10,91 %	29,26 %

Wie in der unteren Grafik sichtbar wird, war die Genauigkeit bei liegenden Kühen am Tage fast doppelt so hoch wie in der Nacht. „Stehende“ Kühe wurden in der Nacht um das fast dreifache präziser detektiert als am Tage. Am genauesten wurden „liegende“ Kühe am Tage, gefolgt von „stehenden“ Kühen in der Nacht und „liegende“ Kühe in der Nacht identifiziert. Das Schlusslicht bildet die Gruppe der „stehenden“ Kühe am Tage. Liegende Kühe wurden tagsüber präziser identifiziert als nachts, während „stehende“ Kühe in der Nacht genauer klassifiziert werden konnten als am Tage.




Abbildung 26 Gegenüberstellung „liegender“ und „stehender“ Kühe des Laufstalls 2 mit Angabe der durchschnittlichen Präzision für die Detektion während des Tages und der Nacht im zweiten Versuch mit weniger Label.

Die nächste Grafik zeigt wieder eine Detektion nach Reduktion der Label. Auch hier wurde erneut ein Teil der Stalleinrichtung als eine „stehende“ Kuh identifiziert. Lediglich der Kopf einer Kuh befand sich innerhalb der Bounding Box. Während die liegende Kuh richtig erkannt wurde, sind im Hintergrund zwei „stehende“ Kühe als eine einzelne Kuh erkannt worden. Eine weitere „stehende“ Kuh am Fressgitter wurde nicht erkannt.



Abbildung 27 Kühe werden nicht oder teils detektiert. Stalleinbauten werden auch hier als „stehende“ Kuh klassifiziert.

5.3 Training Individualisierung der Kühe

Im Training für das weitere neuronale Netz, welches für die Identifikation einzelner Kühe aufgebaut werden sollte, entstanden folgende Ergebnisse. Die höchste durchschnittliche Genauigkeit betrug 100 %, die geringste 99,18 %. Der niedrigste Wert des Recalls lag bei 97,14 %, in drei weiteren Fällen bei 100 %. Die Genauigkeiten, ob eine Kuh richtig klassifiziert wurde, waren hoch. Auch der Recall hat zu einem hohen Prozentsatz in den meisten Fällen alle Objekte der Klassen identifiziert, welche er identifizieren sollte. Im gesamten Durchlauf wurden lediglich Kuh 2 und Kuh 4 zwei Mal nicht erkannt, wobei sie erkannt werden sollten. Jede Kuh wurde mindestens einmal identifiziert, obwohl sie als Objekt nicht vorhanden war. Im höchsten Fall war es fünf Mal bei Kuh 5.

Tabelle 25 Darstellung von Ergebnissen der Objekterkennung aller einzelnen Kühe mit den wichtigsten Parametern zur Bewertung der Leistung eines Modells.

Kuh-Nr.	Precision	Recall	Average IoU	AP	TP	FP	FN
1	97,56 %	100 %	0,86	99,88 %	40	1	0
2	95,12 %	97,5 %	0,82	99,88 %	39	2	1
3	97,56 %	100 %	0,86	100 %	40	1	0
4	94,44 %	97,14 %	0,84	99,18 %	34	2	1
5	88,89 %	100 %	0,79	100 %	40	5	0

Insgesamt gesehen lag die mAP, also der Durchschnitt aller Klassen bei einer Genauigkeit von 99,79 %. Bei gerade einmal 11 falsch positiven und zwei falsch negativen Objekterkennungen standen 193 richtige Erkennungen dagegen. In der folgenden Tabelle wird das Ergebnis nochmal für alle Klassen als Durchschnitt dargestellt.

Tabelle 26 Darstellung des Ergebnisses der Objekterkennung für alle Kühe als Durchschnitt mit den wichtigsten Parametern zur Bewertung der Leistung eines Modells.

	Precision	Recall	Average IoU	AP	TP	FP	FN
insgesamt	94,61 %	98,97 %	0,83	99,79 %	193	11	2



Abbildung 28 Ergebnis der Individualisierung der einzelnen Kühe mit der Kennzeichnung und der jeweiligen Präzision über der Box.

5.4 Manuelle Messung der Steh- und Liegezeiten der individualisierten Kühe

Für beide verglichene Tage im manuellen Versuch belief sich die Aufnahmedauer der Videos für eine Kuh auf 2,34 Stunden Videomaterial. Jede Kuh wurde also in den 2,34 Stunden entweder als „liegend“ oder „stehend“ festgehalten. In der folgenden Tabelle ist das Ergebnis des ersten Tages zu sehen, bei dem für jede Kuh die Steh- und Liegezeiten aufgelistet sind. Der Durchschnitt der jeweiligen Klasse lässt erkennen, inwieweit einige Kühe von ihrem Verhalten her gegenüber anderen abweichen.

Tabelle 27 Ergebnisse der manuellen Erfassung von Steh- und Liegezeiten der einzelnen Kühe am ersten Tag.

	Stehzeit in Stunden	Liegezeit in Stunden
Kuh 1	1,06	1,28
Kuh 2	1,02	1,32
Kuh 3	1,18	1,16
Kuh 4	1,33	1,01
Kuh 5	1,13	1,21
Durchschnitt	1,14	1,2

Auffallend am ersten Tag sind zwei Kühe. Die Kühe 2 und 4 heben sich vom Durchschnitt in beiden Klassen ab. Während Kuh 2 verhältnismäßig mehr liegt als steht, ist die Kuh 4 mehr am Stehen als liegen.

Am zweiten Tag, siehe untere Tabelle, ändern sich die Durchschnitte. Die Stehzeiten der Kühe werden im Durchschnitt mehr, die Liegezeit entsprechend kürzer. Kuh 2 und Kuh 5 bleiben von der Aktivität fast dem Vortag gleich. Bei den Kühen 1 und 3 ändern sich die Zeiten nur minimal, während bei der Kuh 4 sich die Zeiten sehr stark verändern. Am zweiten Tag steht sie mehr als am Vortag. Während der manuellen Erfassung der Steh- und Liegezeiten fiel Brunstverhalten der Kuh 4 auf. Die Bewegung war erhöht, die Kuh suchte mehr Kontakt zu anderen Kühen und versuchte gelegentlich auf andere Kühe aufzuspringen. Die Veränderungen im Verhalten lassen sich in den Tabellen bei der Kuh 4 wiederfinden.

Tabelle 28 Ergebnisse der manuellen Erfassung von Steh- und Liegezeiten der einzelnen Kühe am zweiten Tag.

	Stehzeit in Stunden	Liegezeit in Stunden
Kuh 1	1,16	1,18
Kuh 2	1,04	1,3
Kuh 3	1,25	1,16
Kuh 4	2,24	0,10
Kuh 5	1,13	1,21
Durchschnitt	1,36	0,99

5.5 Automatisierte Auswertung der Steh- und Liegezeiten auf Gruppenebene

5.5.1 Validierung der automatisierten Methode mit der manuellen Auswertung

Zur Validierung der Systeme wurden die manuelle und automatisierte Methode miteinander verglichen. Dazu wurden die Zeitdifferenzen zwischen „liegenden“ und „stehenden“ Kühen und den beiden Methoden betrachtet. Zwischen beiden Systemen gab es im Durchschnitt eine Abweichung von etwa 35 Sekunden. Die höchste Differenz betrug -119 Sekunden von liegenden Kühen in einem Video im automatisierten System. Die Differenz von „stehenden“ Kühen im automatisierten Verfahren lag bei 67 Sekunden. Abweichungen zwischen beiden Systemen sind vorhanden, das Ergebnis ist für die Nutzung der automatisierten Auswertung akzeptabel. Die automatisierte Auswertung ist repräsentativ für die manuelle Methode anwendbar.

5.5.2 Nutzung der automatisierten Methode auf Gruppenebene

Mithilfe des automatisierten Systems konnte man das Verhalten der Gruppe zusammenfassend darstellen. Es war möglich, die Videos eines gesamten Tages automatisiert auszuwerten, was bedeutet, dass das Steh- und Liegeverhalten einer Gruppe von Rindern mithilfe von Kamerasystemen in Verbindung mit künstlicher Intelligenz über einen ganzen Tag hinweg realisierbar ist. Außerdem ist es möglich verschiedene Gruppen anhand des Verhaltens miteinander zu vergleichen. Anhand einer Gruppe kann das durchschnittliche Verhalten eines Einzeltiers errechnet werden, indem die Steh- und Liegezeiten der gesamten Gruppe durch die Anzahl der beobachteten Tiere geteilt werden. Die folgende Grafik zeigt, wie sich die Gruppe je nach Tageszeit verhält.




Abbildung 29 Steh- und Liegeverhalten der Kuhgruppe über einen gesamten Tag hinweg.

Morgens um 01:00 Uhr liegen die meisten Kühe und fangen dann an, jede Stunde vermehrt zu stehen. Um 11:00 Uhr ist der maximale Peak erreicht. Ab dann sinkt das Stehverhalten drastisch bis 14:00 Uhr bis es um 17:00 wieder einen kleineren Peak erreicht und erneut abfällt. Mithilfe des Modells lässt sich offensichtlich das Verhalten der Gruppe über den ganzen Tag hinweg beobachten. Hat man über eine gewisse Beobachtungszeit einen Standard oder Mittelwert erreicht, lassen sich Abweichungen klarer erkennen und so Probleme erkennen.

6 Diskussion

Die Überwachung der Tiergesundheit und des Tierwohls setzt den Fokus direkt auf das Tier und muss durch objektivierbare Parameter erhoben werden können. Der Faktor Mensch hat dabei den größten Einfluss auf das Wohlergehen seiner Tiere, welches gleichzeitig auch den wirtschaftlichen Erfolg des Betriebes sichert. Durch den Wandel der Betriebsstrukturen hin zu immer weniger Betrieben aber gleichbleibenden bis wachsenden Tierzahlen, sinkt der Beobachtungsgrad den der Mensch pro Tier leisten kann. Dies hat nicht nur negative Auswirkungen auf die Tiergesundheit, sondern auch auf den Menschen. Mit zunehmender Größe der Betriebe hat sich die Nutzung der hier vorgestellten sensorgestützten Systeme verbreitet, um die Tiergesundheitsüberwachung zu gewährleisten und zu optimieren. Zahlreich vorhandene Systeme mit den unterschiedlichsten Sensoren können am oder im Tier angebracht werden und vielfältigste Daten sammeln, welche anschließend ausgewertet werden und dem Tierhalter als Informationen oder Warnungen herausgegeben werden. Diese invasiven Methoden erfordern das Anbringen von Sensoren an verschiedensten Körperstellen des Tieres. Immer mehr rücken KI-gesteuerte, nicht-invasive Systeme in den Vordergrund der Tierüberwachung und sind in zahlreichen Studien vielversprechend dargestellt. Insbesondere die Tierüberwachung mittels Kamerasystemen und Objekterkennung sind eine nicht-invasive Methode, bei der nichts am Tier angebracht werden, oder gar ein Mensch in der Nähe eines Tieres sein muss. In dieser Forschungsarbeit sollte ein Ansatz mittels Videokamera und Objekterkennung geschaffen werden, der es ermöglicht Tiere per Videosystem zu überwachen und einzeltierbezogene Aussagen zu treffen. Die Ergebnisse der Objekteigenschaften "stehend" und "liegend" bei einer mAP von 99,21 % und der Objektidentifizierung mit einer mAP von 99,79 % lassen sich mit Ergebnissen anderer Studien vergleichen.

6.1 Bewertung der Tiergesundheit in landwirtschaftlichen Betrieben

Angesichts der Tatsache, dass die Anzahl von Betrieben geringer wird, die Tierzahlen jedoch stagnieren oder gar steigen, wird die erfolgreiche Tierbeobachtung durch geschultes Personal immer schwieriger bis hin zu unmöglich zu bewerkstelligen zu sein. Obwohl die täglichen Tierkontrollen gesetzlich verankert sind, wird die Zeit pro Tier, welche der Tierhalter einsetzt, immer weniger, um alles überblicken zu können. Demzufolge sinkt auch die Qualität der Beobachtung. Denn wie im Beispiel in Unterkapitel 2.2.1.1 dargestellt, sind Häufigkeit und Länge der Beobachtung für eine erfolgreiche Brunstbeobachtung nötig. Ein weiteres Problem in der visuellen Tierbeobachtung ist die Anwesenheit des Menschen. Die Hausrinder stammen ursprünglich von Wildtieren ab, welche gejagt wurde, da sie Beutetiere sind. Ihre Überlebensstrategie ist beispielsweise diese, keine Schmerzen und Schwäche zu zeigen, um keine Aufmerksamkeit bei Raubtieren zu erwecken. Oft wird daher angenommen, dass Kühe wenig oder unempfindlich für Schmerzen sind, weil sie diese nicht zeigen (Traulsen, 2014). Dies hat den

Nachteil, dass der Mensch nicht das sieht, was er sehen sollte. Der Fakt, dass sich Tiere in der Anwesenheit von Menschen oft anders verhalten, beeinflusst die Einschätzung der Tiergesundheit (Hemsworth, Barnett, & Coleman, 1993; Hosey, 2013; Sorge et al., 2014; White et al., 2008).

6.2 Sensorgestützte Systeme zur Unterstützung der Tiergesundheitserkennung

Sensorsysteme haben den klaren Vorteil, dass sie die Einzeltierbeobachtung rund um die Uhr übernehmen können und bei Notwendigkeit dem Tierhalter Alarme sendet. Sie helfen die Tierbeobachtung zu verbessern, können die Probleme jedoch nicht lösen. Sie müssen vom Tierhalter als solche auch erkannt und gelöst werden. Zusätzlich muss der Tierhalter bei Nutzung solcher Systeme die Bereitschaft und das Wissen aufbringen, wie man mit ihnen umgeht und sie nutzt. Sensoren sind in der Lage viele Arten von Parametern zu erheben, die ein Mensch bedingt oder nur mit Aufwand erhält. Genannt werden können dabei akustische Geräusche, Bewegungen, Druck, Temperaturen und chemische Werte. Durch die Kombination von mehreren Sensoren ist es möglich, Krankheiten oder Brunsten früher zu entdecken als der Mensch. Jedoch sind die Sensorsysteme eine invasive Methode, die das Anbringen oder Einbringen von Sensoren am Tier voraussetzt. Die Implantation dieser kann Stress für die Tiere bedeuten und Einfluss auf ihr weiteres Verhalten haben (Nasirahmadi, Edwards, & Sturm, 2017).

6.3 Einsatz von künstlicher Intelligenz und Objekterkennungssoftware

Der Einsatz von künstlicher Intelligenz innerhalb von Objekterkennungssoftware und Kamerasystemen bietet einige Vorteile gegenüber den sensorgestützten Systemen. Bei Computer Vision wird einem System beigebracht zu sehen wie ein Mensch. Folglich kann das Kamerasystem in Verbindung mit Algorithmen alles das sehen, was ein Mensch auch sehen könnte. Die Anwendung von Videoüberwachung hat den Vorteil, dass keine Sensoren am oder im Tier angebracht werden müssen, was Stress beim Tier vermeidet (Schütz et al., 2022). Auch hier ist wieder der Vorteil vorhanden, dass die Tiergesundheitsüberwachung in Echtzeit Daten verarbeitet, ohne dass aber Sensoren verwendet oder sich Menschen im Stall zur Beobachtung befinden. Der Einsatz von Videoüberwachung kombiniert mit Computer Vision ist eine stressfreie, nicht-invasive, kosteneffektive und einfache Methode um Tiere zu überwachen (Nasirahmadi et al., 2017). Eine Studie konnte zeigen, dass lahme Klauen via Kamerasystem zu 93 % korrekt erkannt werden konnten, bei einer Präzision von 87 % (Kang et al., 2020). In einer weiteren Studie konnte gezeigt werden, dass ein Kamerasystem verbunden mit künstlicher Intelligenz Lahmheiten besser detektieren konnte als zwei erfahrene Tierärzte (Anagnostopoulos et al., 2023). Tieridentifizierungen können über Erkennung der Ohrmarken durch Kamera- und Objekterkennungssoftware mit einer sehr hohen Sicherheit erreicht

werden (Zin et al., 2020). Auch ohne Ohrmarken können Kühe per Gesichtserkennung mit einer Präzision von 84 % auseinandgehalten werden (Dac et al., 2022). Sogar Wiederkäuzeiten und Kauvorgänge konnten durch das Nutzen von Kamerasystemen und YOLOv4 mit sehr hohen Genauigkeiten beobachtet werden.

Der Einsatz von Kamerasystemen in Verbindung mit künstlicher Intelligenz deckt breite Bereiche der Tiergesundheitsüberwachung ab und demonstriert dabei sehr gute Ergebnisse. Aus den vielen einzelnen Möglichkeiten die vorhanden sind, müssten Systeme entstehen, die miteinander kombiniert werden, sodass die vorhandenen Systeme in einem arbeiten würden und so mehr Aussagen zu einzelnen Tieren machen könnten.

6.4 Kritik der Methoden

Die Nutzbarkeit der in dieser Arbeit verwendeten Methoden ist durch zahlreich vorhandene Publikationen gegeben. So nutzten Schütz et al. (2022) dasselbe Objekterkennungssystem zur Detektion von Körperhaltungen und Verhalten bei Füchsen. Unter anderem wurden in dieser Arbeit die Objekteigenschaften „liegend“ und „stehend“ erfolgreich angewendet. Zusätzlich wurde bei den Füchsen auch das Sitzverhalten untersucht. Die Software-basierte Sichtung der Videosequenzen, das Klassifizieren von Bildern, sowie das Training und die Evaluierung der Objekterkennung durch Trainings- und Testgruppen erfolgten nach demselben Muster. Shao, He, Fan, and Sun (2023) setzten YOLOv5 ein, um bestimmte Körperteile von Rindern detektieren zu können. Wiederum war es anderen möglich, mittels YOLOv4 Rinder und deren Rasse mit einer hohen Genauigkeit zu identifizieren (Yilmaz, Uzun, Gürbüz, & Kivrak, 2021). Jiang, Rao, Zhang, and Shen (2020) konnten mit YOLOv4 das Verhalten von Ziegen hinsichtlich der Objekteigenschaften „fressen“, „trinken“, „aktives Verhalten“ und „inaktives Verhalten“ automatisch erfassen. Auch bei Hühnern konnten mithilfe von YOLOv3 verschiedene Verhaltenskategorien in Echtzeit wie „trinken“, „fressen“ und „stehen“ vielversprechend detektiert werden (Wang, Wang, Li, & Ren, 2020). Yang et al. (2020) analysierten das Bewegungsverhalten von Sauen durch die Objekteigenschaften „Trinken“, „Fressen“ und „Säugen“ und erreichten hohe Genauigkeiten in der Verhaltensklassifizierung. Bei Schweinen konnten, wie in dieser Arbeit erarbeitet, ebenfalls die Objekteigenschaften „liegend“ und „stehend“ erfolgreich angewendet werden (Nasirahmadi et al., 2019).

6.5 Analyse und Diskussion der Versuchsergebnisse

6.5.1 Training der Objekteigenschaften „stehender“ und „liegender“ Kühe

6.5.1.1 Versuch 1

Im ersten Versuch erreichte die sechste Trainingsgruppe die höchsten Präzisionen, sowohl bei den „stehenden“ Kühen mit 99,26 % als auch die der „liegenden“ Kühe mit 97,52 %. Die mAP lag bei 98,39 %. Über alle Trainingsgruppen hinweg, verbesserten sich die Präzisionen

mit steigender Anzahl der Label in beiden Klassen. Die Differenz der Präzisionen beider Objekteigenschaften in der besten Trainingsgruppe lag bei 1,74 %. Dieser Unterschied in den Präzisionen begründet sich in der ungleichen Anzahl von Label innerhalb der Objekteigenschaften. Während für „stehende“ Kühe 1637 Label vorhanden waren, wiesen die „liegenden“ Kühe eine Anzahl von nur 640 Label auf. Durch die Differenz von 997 Label entstand folglich auch ein starker Unterschied in der Aufteilung in der Testgruppe. Diese verdeutlichen den Unterschied der Präzision zwischen den Objekteigenschaften. Da die Leistung des Modells durch das Vergleichen der Label aus der Testgruppe mit den Ergebnissen des Objekterkennungsmodells geprüft wird, sind eine ausreichende Anzahl von Label notwendig, um hohe Präzisionen zu erreichen. In der Testgruppe waren für die „liegenden“ Kühe lediglich 164 Label vorhanden, für die „stehenden“ Kühe jedoch 424 Label. Die Menge an Label für „liegende“ Kühe entspricht 39 % der Menge der Label, die für die „stehend“ klassifizierte Kühe erstellt wurden. Durch das zahlenmäßig geringere Vorhandensein der Label „liegender“ Kühe konnte der Detektor diese nicht so präzise erkennen wie die der „stehenden“ Kühe. Dementsprechend bedingt die vorhandene gelabelte Bildmenge die Genauigkeit der Objektdetektion. Auch die Qualität des Labels hinsichtlich ausreichend verschieden vorhandener Positionierung und Körperhaltungen der Kühe ist ausschlaggebend, um die Vielfältigkeit des Materials und damit die Präzision des Detektors zu erhöhen.

6.5.1.2 Versuch 2

Die starke Differenz der Labelanzahl und die schlechteren Präzisionen der „liegenden“ Kühe aus dem ersten Versuch wurden im zweiten Versuch ausgeglichen und verbessert. Die Differenz der Label zwischen „stehenden“ und „liegenden“ Kühen konnte auf 146 reduziert werden und die Testgruppe erhielt weitere 55 neu klassifizierte Bilder. Der enorme Unterschied der Anzahlen von Label zwischen „liegenden“ und „stehenden“ Kühen in der Testgruppe wurde durch die weiteren 55 klassifizierten Bilder deutlich verringert. Die Differenz der Label in der Testgruppe betrug lediglich 52 Label zwischen den beiden Objekteigenschaften, wobei die „stehenden“ Kühe Anzahlen mäßig mehr Label hatten. Nichtsdestotrotz zeigte sich der Ausgleich deutlich in den Ergebnissen wieder. Die beiden neu trainierten Gruppen waren besser als die vorherigen, wobei die achte Trainingsgruppe am besten abschnitt. Die „liegenden“ Kühe wurden mit einer Präzision von 98,86 % detektiert, 1,34 % höher als im ersten Versuch. Auch die „stehenden“ Kühe mit einer Präzision von 99,65 % wurden besser detektiert, nämlich um 0,39 % mehr als im ersten Versuch. Die mAP verbesserte sich somit auch, nämlich um 0,87 % auf insgesamt 99,26 %. Trotz des Ausgleichs der Label beider Objekteigenschaften gab es immer noch die Tendenz, dass „stehende“ Kühe besser als „liegende“ Kühe detektiert wurden. Grund dafür ist, dass der Detektor aus dem ersten Versuch verwendet wurde, der „liegende“ Kühe schlechter detektierte als „stehende“ Kühe. Allerdings zeigte der zweite Versuch aufgrund der neuen Bildmenge in den letzten zwei Trainingsgruppen und das Hinzufügen

von Bildern in der Testgruppe, dass die Detektion von „liegenden“ Kühen verbessert werden konnte.

Da sich die Präzisionen der letzten beiden Trainingsgruppen gesteigert hatten, die vorherigen Stufen im Training jedoch nicht miteinbezogen wurden, sollte die Anzahl der Label von „stehenden“ und „liegenden“ Kühen über das gesamte Training hinweg gleich verteilt werden. Dies sollte der dritte Versuch ermöglichen. Allerdings sollte der dritte Versuch auch zeigen, ob die Ergebnisse sich stark von den bisherigen Versuchen verändern oder in etwa gleichbleiben. An einer neuen Verteilung der Bilder in Trainingsgruppen und einer Testgruppe könnte man auch erkennen, ob die Qualität des Klassifizierens über die Bilder hinweg gleichbleibt. Dies zeigte die Grafik im zweiten Versuch in Unterkapitel 5.1.2 jedoch nicht, da nur zwei Gruppen trainiert worden sind. Es kann sich aber auch zeigen, ob das Training sich durch wiederholende, sehr ähnliche Bilder in der Testgruppe und den Trainingsgruppen selbst bestätigt und dadurch fälschlicherweise gute Ergebnisse generiert. Dieses Phänomen, dass sich Bilder in der Testgruppe und den Trainingsgruppen so sehr ähneln, dass stets richtige Detektionen getroffen werden, nennt man Overfitting. In der Ergebnistabelle in Unterkapitel 5.1.2 erkennt man, dass die Genauigkeiten der mAP bis zur fünften Trainingsgruppe steigen, in der sechsten jedoch fallen und ab der siebten Gruppe wieder besser werden. Hier ist es möglich, dass Overfitting vorlag.

6.5.1.3 Versuch 3

Aufgrund der besseren Ergebnisse der letzten beiden Trainingsgruppen im zweiten Versuch und der Absicht des Vermeidens von Overfitting wurde das gesamte Bildmaterial im dritten Versuch neu aufgeteilt. Praktisch ist es die gleiche Bildmenge wie im zweiten Versuch, jedoch haben die Testgruppe und die Trainingsgruppen neu zugeteilte Bilder erhalten.

Die Präzision der „stehenden“ Kühe durch die Durchmischung der Label ist im Vergleich zum zweiten Versuch um 0,44 % gesunken. Im Vergleich zum ersten Versuch nur um 0,13 %. Obwohl die mAP dadurch etwas gesunken ist, bedeutet dies nicht automatisch, dass der zweite Versuch oder das einzelne Training besser ist. Im dritten Versuch wurde das Problem behoben, dass sich mehrere, sehr ähnlich oder gleich klassifizierte Bilder wiederholen und das Training sich dadurch selbst bestätigt (Overfitting). Diese Label wurden nun in der Test- und den Trainingsgruppen ausgeglichen verteilt. Die neu gelabelten Bilder haben eine größere und bessere Vielfalt geboten. Zwar haben sie im zweiten Versuch die letzten beiden Stufen verbessert, aber in diesem Versuch einen Ausgleich geschaffen und eine höhere Sicherheit in Bezug auf Aussagen zu durchschnittlicher Präzision der einzelnen Klassen ermöglicht. Die neunte Trainingsgruppe hatte in diesem Versuch die besten Präzisionen. Interessanterweise war die sechste Trainingsgruppe die zweitbeste, obwohl sie weniger Bildmaterial und damit auch Label der Objekteigenschaften als die siebte und achte Gruppe beinhaltete. Je nach

dem, was für Bilder in den zwei schlechteren Trainingsgruppen waren, konnte der Detektor diese nicht so präzise bestimmen wie das sechste Training. Bis auf die letzte Trainingsgruppe 9, welche das gesamte Bildmaterial nutzte und sich schlussendlich als präziseste Gruppe erwies. Die mAP lag bei 99,21 %. Die beste Trainingsgruppe im zweiten Versuch hatte sogar eine bessere mAP von 99,26 %. Diese entstand durch die sehr gute Präzision bei den „stehenden“ Kühen von 99,65 %, während die „liegenden“ Kühe eine geringere Genauigkeit von 98,86 % aufwiesen. Im besten Training des Versuchs 3 sind jedoch die „liegenden“ Kühe mit 99,13 % bisher am besten detektiert worden, was in keinem der vorherigen Versuche und in den einzelnen Trainingsgruppen der Fall war. Die „stehenden“ Kühe sind über die gesamten Versuche hinweg meist sehr gut identifiziert worden, weshalb die Wahl der geeigneten Gruppe für einen Detektor auf die neunte Gruppe des dritten Versuchs fiel, bei der nun auch die „liegenden“ Kühe sehr gut detektiert werden konnten. Der Recall von 98,61 % bei „stehenden“ Kühen zeigt, dass das Modell die meisten Kühe auch als solche erfolgreich identifizieren kann. Bei den „liegenden“ Kühen lag der Recall bei 98,04 %, was vergleichbar mit den Ergebnissen der „stehenden“ Kühen ist. Die durchschnittliche IoU der „liegenden“ Kühe war mit 0,9 sogar etwas besser als die der „stehenden“ mit 0,86. Diese Werte bezeugen eine solide Leistung des Modells.

Die Objekteigenschaften der Kühe werden in der auf sie trainierten Umgebung dementsprechend mit einer sehr hohen Genauigkeit und Sicherheit erkannt, während Falschklassifizierungen selten vorkommen. Zwar gab es, wie bereits angesprochen, kleine Rückgänge in den Genauigkeiten der Trainingsgruppen, dennoch wurden keine sprunghaften Veränderungen in den Präzisionen ermittelt. Bezüglich der Falschklassifizierungen müsste man direkt in die Bilder schauen, um herausfinden zu können, ob Tiere tatsächlich falsch klassifiziert, oder gar nicht vorhanden waren, jedoch klassifiziert wurden. Da die Falschklassifizierungen jedoch nur minimal vorhanden waren, wurde in dieser Arbeit nicht weiter darauf eingegangen. Allerdings wäre dies ein Punkt, an dem das Modell noch weiter verbessert werden könnte, um die Genauigkeiten und Sicherheiten des Modells noch weiter zu erhöhen.

Im Vergleich zu anderen Studien schneidet das neu trainierte Modell sehr gut ab. Nasirahmadi et al. (2019) konnten bei Schweinen „liegende“ und „stehende“ Körperhaltungen mit Präzisionen von durchschnittlich 93 % für „liegende“ und 95 % für „stehende“ Schweine erreichen, wobei dies das beste Ergebnis aus drei verschiedenen Detektionsmethoden war. „Stehende“ Legehennen konnten mit einer Genauigkeit von 94,57 % mittels YOLOv3 detektiert werden (Wang et al., 2020). Schütz et al. (2022) konnten bei Füchsen die vergleichbaren Objekteigenschaften sogar noch weiter erhöhen. „Liegende“ Füchse konnten dabei mit einer Präzision von 99,79 % und „stehende“ Füchse mit 99,96 % identifiziert werden. Während in dem hier verwendeten Modell die Objekteigenschaften von fünf Tieren gleichzeitig innerhalb einer Laufbox

erfasst worden sind, hatte die Studie zu den Füchsen lediglich einen Fuchs in einem Käfig. Auch konnten tote Winkel bei der Einzeltierbeobachtung der Füchse ausgeschlossen werden, da diese mit zwei Kameras gleichzeitig beobachtet wurden, statt mit einer Kamera wie in diesen vorliegenden Versuchen. Weiterhin konnten sich die Kühe in diesem Versuch gegenseitig teils oder ganz verdecken und so eine Detektion erschweren oder gar nicht erst ermöglichen. Dennoch war es dem Detektor möglich, nur teils sichtbare Tiere und ihre Objekteigenschaft korrekt erkennen. Dies zeigen die Abbildungen in Unterkapitel 5.1.3 deutlich.

6.5.2 Anwendung des Detektors/ neuronalen Netzes auf fremde Umgebungen

6.5.2.1 Laufstall 1

6.5.2.1.1 Versuch 1

Wie in den ersten Versuchen ergab es sich, dass die Präzisionen der „stehenden“ Kühe besser waren als die der „liegenden“ Kühe. Jedoch waren die Unterschiede in der fremden Umgebung des Laufstalls auf die der Detektor nicht trainiert wurde viel gravierender. Und dass, obwohl viel mehr Label für „liegende“ Kühe als „stehende“ vorhanden waren. Durch die Aufteilung der Bilder in Tag- und Nachtaufnahmen ließ sich auch der Trend beobachten, dass die Präzisionen am Tag besser sind als in der Nacht. Gleichzeitig wurden die „stehenden“ Kühe sowohl am Tag als auch in der Nacht immer besser detektiert als die „liegenden“ Rinder. Am präzisesten waren also die „stehenden“ Kühe bei Tage, gefolgt von den „stehenden“ in der Nacht. Erst dann folgen die „liegenden“ Rinder am Tag und am Ende jene in der Nacht. Da sich die „liegenden“ Kühe immer in den Liegeboxen befanden, wurden sie durch die Begrenzungsrohre verdeckt. Der Grad der Verdeckung steigerte sich mit den von der Kamera 1 entfernteren Liegeplätzen, da sich mit jeder Liegefläche auch die Stalleinbauten summieren. Zudem befand sich vor dem ersten Liegeplatz eine Wand, die die Sicht auf die Liegefläche von der Kamera 1 gesehen zum größten Teil verdeckte. Beim Liegen der Tiere wird weniger Körperoberfläche sichtbar, was durch das Nebeneinanderliegen der Kühe in den Liegeboxen zusätzlich verstärkt wird. Die Sicht der Kamera 1 und 2 sind auf den Futtertisch ist zum größten Teil frei einsehbar, da der Laufgang im Stall über keine nennenswerten Einbauten verfügt. Dadurch sind „stehende“ Kühe, die sich im Bereich des Futtertisches aufhalten ohne Objekte, die sie verdecken, zu sehen. Dies kann ein Grund für die besseren Präzisionen bei „stehenden“ Kühen, verglichen mit den „liegenden“ sein, obwohl weniger Label vorhanden waren. Unabhängig von den Objekteigenschaften waren weniger Nachtaufnahmen vorhanden als Tagaufnahmen, was ebenfalls die schlechteren Ergebnisse für beide Objekteigenschaften in der Nacht erklären könnte. Ein wichtiger Punkt für die Nachtaufnahmen ist jedoch die schlechte Ausleuchtung des Stalls. Auf der gegenüberliegenden Seite des Futtertisches brannte nachts sehr helles Licht, das oft verhinderte, dass die Nachtaufnahme aktiv wurde. In den Nachtaufnahmen konnte man

eine Lichtkegelbildung beider Infrarotkameras bemerken, die einen mittigen Teil ausleuchteten, den Rest der Fläche jedoch nicht erhellte. In den vorherigen Versuchen wurden die Aufnahmen in der Nacht von der Helligkeit zwar auch undeutlicher, dennoch war eine gleichmäßige Helligkeit gegeben, die es in dem Laufstall nicht gab. Hier könnte durch eine Vergrößerung der Menge an Nachtaufnahmen für das Training der Detektor für Nachtaufnahmen verbessert werden. Auch die Kameras können hinsichtlich ihrer Positionierung eine entscheidende Rolle spielen. Denn je flacher sie die Liegeflächen einsehen, desto schwieriger sind die Tiere, bzw. die Objekteigenschaften zu detektieren. Wäre das Sichtfeld der Kamera 1 in einem stumpferen Winkel positioniert, könnten Stalleinbauten die Tiere weniger verdecken. Von der Perspektive der Kamera 2 konnten Tiere besser detektiert werden. Hier war das Sichtfeld auf lediglich den Bereich beschränkt, welcher auch beobachtet werden sollte, während Kamera 1 die gegenüberliegende Seite des Stalls und das helle Licht aufnahm. Zudem schien es so, als wäre die Kamera 2 niedriger angebracht und hatte ein näheres Sichtfeld zu den Tieren, bzw. die Tiere erscheinen auf den Bildern größer.

6.5.2.1.2 Versuch 2

Basierend auf den Ergebnissen des ersten Versuchs wurden für den Folgeversuch (Versuch 2) festgestellt, dass die weit entfernten Rinder von der Kamera durch die Auflösung nicht gut genug für die Detektion erfasst werden und zudem die zahlreichen Stalleinbauten die Tiere verdeckten, weshalb nur noch die Rinder im Nahbereich der Kamera betrachtet wurden. Die Rinder, welche von der Kamera 1 weiter weg standen, oder anders gesagt sich auf der anderen Seite der Laufgangabtrennung befanden, konnten durch die Kamera 2 abgedeckt werden. Bei gleicher Bildmenge, aber weniger Label verbesserten sich die Präzisionen sehr. „Liegende“ Kühe wurden nun am Tag 18,72 % und in der Nacht um 4,54 % besser detektiert. Auch „stehende“ Kühe konnten am Tage um 12,4 % und in der Nacht um 32,53 % besser identifiziert werden. Das lässt darauf schließen, dass der Sichtbereich der Kamera für eine erfolgreiche Detektion ein wichtiger Aspekt in der Objekterkennung ist. Nichtsdestotrotz sind die Unterschiede der Präzisionen zwischen den Objekteigenschaften, sowie der unterschiedlichen Tageszeiten präsent. Zwar haben sich die Genauigkeiten in allen Bereichen verbessert, doch die starken Unterschiede bleiben wie im ersten Versuch vorhanden. Insbesondere die „liegenden“ Kühe in der Nacht konnten hinsichtlich der Präzision nicht deutlich verbessert werden. Anders als im ersten Versuch ist die stark gestiegene Genauigkeit von 20,42 % auf 58,68 % der „stehenden“ Kühe in der Nacht. Diese starke Verbesserung ist offensichtlich durch die Betrachtung der Kühe im Nahbereich entstanden. Weiterhin bleiben die Stalleinbauten, die Beleuchtung des Stalles, das gegenseitige Verdecken der Tiere beim Liegen in den Liegeboxen, sowie die Sichtbereiche, Positionierung, Nachtaufnahmen und Abstände zu den Tieren der Kameras Hindernisse und Problemfelder für sehr gute Ergebnisse.

6.5.2.2 Laufstall 2

6.5.2.2.1 Versuch 1

In demselben Laufstall erfolgte die Detektion der Objekteigenschaften mit anderem Videomaterial und Kameras. Die Ergebnisse ähneln sich teils zu denen im Laufstall 1. So ist die Präzision der „liegenden“ Kühe mit 26,87 % am Tag auch wieder höher als die in der Nacht mit 18,12 %. Hier kann insbesondere die Beleuchtung eine Ursache sein. Interessanterweise sind die Genauigkeiten hier sogar höher als die des Laufstalls 1. Ein möglicher Grund dafür können die Kameras sein, welche höher positioniert worden sind als im Laufstall 1 und sich somit weniger Begrenzungsrohre und Stalleinbauten im Sichtfeld der Kameras befanden, weil sie in einem stumpferen Winkel zu den Kühen angeordnet sind. Bei den stehenden Kühen ist dieser Trend genau andersherum. Hier wurden die „stehenden“ Kühe in der Nacht mit 21,72 % besser detektiert als die am Tage mit nur 6,97 %. Ein denkbarer Grund dafür könnte sein, dass „stehende“ Kühe sich durch die sehr helle Beleuchtung vom Futtergang gegenüber kommend und der Lichtkegelbildung der Infrarotkamera besser von der Dunkelheit abgehoben haben als am Tage, bei dem keine Lichtquellen außer das Sonnenlicht zur Verfügung stand. Beim Klassifizieren der Bilder des Laufstalls 2 fiel auf, dass die Helligkeit im Stall selbst am Tag schlecht war und Bilder beim Bearbeiten häufig aufgehellt werden mussten, um die Kühe zu erkennen. Somit kann auch der Detektor Schwierigkeiten gehabt haben, diese Tiere zu identifizieren, wenn es beim Klassifizieren schon erheblich schwierig gewesen ist. Auch konnte beobachtet werden, dass sich „stehende“ Kühe am Tage oft im dunklen, hinteren Bereich des Sichtfelds der Kamera aufhielten und dadurch auch schwieriger zu detektieren waren. Die Aufteilung der Bildmengen bezüglich des Verhältnisses von Tag- und Nachtaufnahmen waren gleichmäßig verteilt. Auch innerhalb der Label beider Objekteigenschaften gab es keine nennenswerten Unterschiede, als dass sie in dem Versuch von der Verteilung her eine Rolle gespielt hätten. Der Detektor kann jedoch nur das erkennen, worauf er trainiert worden ist. Und in diesen Versuchen, waren die Lichtquellen kein Hindernis.

6.5.2.2.2 Versuch 2

Gleich demselben Prinzip in Versuch 2 des Laufstalls 1 wurden auch hier lediglich die Rinder im Nahbereich der Kameras betrachtet. Dies hatte ebenfalls zur Folge, dass sich alle Präzisionen verbessert haben, jedoch immer noch niedrig blieben im Verhältnis zu den Genauigkeiten auf den der Detektor trainiert worden ist. Die Präzisionen der „liegenden“ Kühe waren wie im ersten Versuch am Tage mit 40,49 % wieder deutlich höher als die „liegenden“ in der Nacht mit 20,94 % Genauigkeit. Dieser Trend hat sich in beiden Laufställen und in jedem dieser Versuche stets durchgezogen. Anders waren hier wieder die Genauigkeiten der „stehenden“ Kühe, die tagsüber mit nur 10,91 % detektiert wurden, in der Nacht jedoch mit einer Präzision von 29,26 %. Hier wird der gleiche Gedanke angenommen wie in Versuch 1, dass sich „stehende“ Kühe durch die Helligkeit der Beleuchtung in der Nacht optisch besser von anderen abgehoben

haben und dadurch besser detektiert werden konnten. Auch, dass sich die Kühe wieder im hinteren und dunkleren Sichtbereich der Kamera aufhielten, kann ein Grund dafür sein. Fraglich bleibt allerdings, weshalb Stalleinrichtungen teils als „liegende“ oder „stehende“ Kühe detektiert werden.

Die Unterschiede in den Präzisionen beider Laufställe können auch mitunter an der Auflösung gelegen haben. Die Videos des ersten Laufstalls besaßen eine Bildgröße von 1920 x 1080 Pixel bei 30 fps. Die Aufnahmen des zweiten Laufstalls hatten eine Auflösung von 704 x 576 Pixel bei 25 fps. Allerdings sind die Präzisionen der „liegenden“ Kühe sowohl tags als auch nachts in beiden Laufställen fast gleich und unterscheiden sich stark bei den „stehenden“ Kühen, wobei der Laufstall 1 mit Videos höherer Auflösung und anderer Kamerapositionierung der bessere war.

Folglich beschränkt sich der Anwendungsbereich des Detektors mit den zwei Objekteigenschaften bisher auf das Umfeld, auf das er trainiert worden ist, weil er dort hervorragend funktioniert und im Vergleich mit anderen Studien sehr hohe Präzisionen vorweisen kann. Um ihn universell einsetzbar zu gestalten, müsste vielfältigeres Bildmaterial in den Trainings genutzt werden, um in fremden Umgebungen ebenfalls gute Ergebnisse erzielen zu können. In fremden Umgebungen könnte der Detektor keine zuverlässigen und genauen Ergebnisse erzielen, weil die Genauigkeiten zu gering sind. Außerdem tragen Faktoren wie Stalleinbauten, Lichtqualität, Positionierung und Sichtbereich der Kameras erheblich dazu bei, ob ein reines Kamerasystem mit Detektoren erfolgreich sein kann oder nicht. Auch das korrekte Labeln der Bilder trägt zur Qualität des Detektors bei. Dies konnte man durch die Reduktion der Label von den Kühen bemerken, die sich nicht mehr im Nahbereich der Kamera befanden. Folglich steigerten sich die Präzisionen.

6.5.3 Bewertung der Individualisierung von Kühen

Für die Individualisierung einer Gruppe von fünf Kühen wurden lediglich 200 Bilder benötigt. Allerdings mussten auf jedem einzelnen Bild jede Kuh optisch vom Beobachter erkannt und klassifiziert werden, was eine sehr zeitintensive Aufgabe ist und etwaige Fehler große Auswirkungen auf die Ergebnisse haben können. Das dadurch entstandene neuronale Netz erreichte sehr gute Ergebnisse. Die beste durchschnittliche Genauigkeit zur Identifikation einer Kuh betrug 100 %. Die schlechteste durchschnittliche Genauigkeit einer Kuh über alle Bilder hinweg betrug 99,18 %. Die durchschnittlichen Genauigkeiten ob die Kühe identifiziert werden konnten, waren sehr hoch. Der schlechteste Recall einer Kuh lag bei 97,14 % während drei weitere sogar mit 100 % identifiziert wurden. Das Modell zur Individualisierung ist in der Lage fast alle Objekte zu identifizieren, welches es detektieren soll. Die Präzisionen lagen sehr hoch, wonach die meisten Entscheidungen des Modells richtig waren. Kuh 4 war auf den 200 Bildern 182-mal zu finden, während alle anderen öfter auf den Bildern zu detektieren waren. Deshalb

befanden sich auch weniger Bilder dieser Kuh in der Testgruppe, wonach sie die schlechtesten Genauigkeiten hatte. Nichtsdestotrotz lag ihre durchschnittliche Genauigkeit bei 99,18 %, was ein sehr gutes Ergebnis ist. Die mAP des Versuchs von 99,79 % kann mit anderen vorhandenen Studien verglichen werden. Yilmaz et al. (2021) konnten mittels YOLOv4 Rinder und deren Rasse mit einer Präzision von 92,85 % detektieren und klassifizieren. In einer weiteren Studie wurde für eine automatische Rinderidentifikation eine Genauigkeit von 93,66 % erreicht (Dulal et al., 2023). Für eine visuelle Verfolgung oder Tracking von Rindern sollte in einer Studie zuerst die Identifikation der einzelnen Tiere ermöglicht werden. Um die einzelnen Tiere identifizieren zu können wurde zunächst eine Kopferkennung mittels dem Objektdetektor YOLO durchgeführt, um die Position der Kuh in der zugehörigen Kameraansicht zu bestimmen. Anschließend folgte die Erkennung der Ohrmarken, die einen vierstelligen Zahlenbereich beinhalten. Die Zahlen wurden durch eine Bildverarbeitungstechnik segmentiert. Zudem wurde dabei ein Standortsuchsystem eingerichtet. Die Kopferkennung erreichte eine Genauigkeit von 100 %, die der Ohrmarkenerkennung 92,5 %. Dem vierstelligen Code zufolge können somit 9999 Kühe auf einem Betrieb gleichzeitig beobachtet werden (Zin et al., 2020).

Bei dem vorliegenden Versuch brauchten jedoch keine Ohrmarken identifiziert werden, um die Kühe an sich zu identifizieren. Es wurde lediglich mithilfe des Aussehens, bzw. der Fellmusterung gearbeitet. Fraglich ist, ob die genutzte Methode in der vorliegenden Arbeit auch für mehr Kühe möglich wäre, vor allem dann, wenn sich die Fellmusterung der Tiere sehr ähneln, kaum unterscheiden oder durch andere Rassen, welche eine durchgängige Farbe besitzen, unmöglich machen. Zudem besteht dann auch die Frage, wie das Individualisieren der einzelnen Rinder in der Praxis geschehen soll. In einem weiteren Versuch konnten Rinder durch ein reines Kamerasystem mit Detektoren identifiziert werden. Hier konnten 89 verschiedene Kühe durch Gesichtserkennung bei einer Gesamtgenauigkeit von 84 % auseinandergehalten werden (Dac et al., 2022).

Aus den Ergebnissen dieses Versuchs heraus entstand jedoch die Möglichkeit eine Basis für eine Einzeltierbeobachtung zu legen. Das alleinige Nutzen des Detektors der Objekteigenschaften „stehend“ und „liegend“ hätte für etwaige Gruppensaussagen genutzt werden können, nicht jedoch über Informationen über ein einzelnes Tier. Eine Kombination beider Detektoren, also die der Objekteigenschaften und -erkennung würden einzeltierbezogene Aussagen zulassen oder ermöglichen, wie es bei den Sensorsystemen ebenfalls möglich ist.

6.5.4 Manuelle Messung der Steh- und Liegezeiten der individualisierten Kühe

Die manuelle Methode wurde bei der Darstellung der Differenzen zwischen beiden Auswertungsmethoden als Standard gewählt. Sie war mit einer höheren Sicherheit verbunden, da jede Kuh manuell erfasst wurde. Falls eine Kuh nicht sichtbar oder nur teils sichtbar war und

nicht sofort erkannt werden konnte, wurde sie mittels Videos verifiziert, um Verwechslungen zu verhindern. Im Gegensatz dazu konnte das automatisierte System diesen Vorteil nicht nutzen, weshalb auch Unterschiede in der Zeitenerfassung entstanden und Fehler in der Erkennung der Klassen „stehend“ und „liegend“, aber auch bei der Individualisierung entstanden. Obwohl für die manuelle Messung aus zeit- und arbeitsintensiven Gründen kein gesamter, durchgängiger Tag untersucht werden konnte, zeigten die Ergebnisse klare Unterschiede zwischen den einzelnen Tieren. Ebenso konnte auch gezeigt werden, dass sich das Steh- und Liegeverhalten anhand der manuellen Messung eines zweiten Tages einzelner Kühe verändert und Auffälligkeiten aufgezeigt werden können. Als bestes Beispiel dient dafür die Kuh 4. Ihre Stehzeit von 1,33 Stunden waren am ersten Tag leicht über dem Durchschnitt der 1,14 Stunden betrug. Ihre Liegezeit von 1,01 Stunden in der Gruppe waren am geringsten und auch unter dem Durchschnitt der Gruppe, welcher bei 1,2 Stunden lag. Am Folgetag lag die Stehzeit der Kuh 4 bereits bei 2,24 Stunden, während der Durchschnitt der Gruppe bei 1,36 Stunden lag. Der gleiche Trend vom Vortag ließ sich in der Liegezeit beobachten. Während die Kuh 4 lediglich 10 Minuten lag, hatte die Gruppe eine viel höhere Liegezeit von 0,99 Stunden. Dabei muss erwähnt werden, dass die einzelne Kuh diesen Durchschnitt mit beeinflusst hat. Würde sie isoliert von dem Gruppendurchschnitt betrachtet werden, wären die Kontraste noch deutlicher zu erkennen. Auch würde eine größere Gruppe zu einem stabileren Durchschnitt führen, bei dem Auffälligkeiten früher detektiert werden könnten. Während der Bearbeitung der Bilder, die der Individualisierung der einzelnen Kühe diente, fiel die Kuh 4 auch durch Brunstverhalten auf, was die Unterschiede zu den anderen Kühen hinsichtlich ihrer Aktivität erklären kann. Ebenfalls auffällig war die Kuh 2, welche an beiden untersuchten Tagen im Durchschnitt weniger stand als alle anderen Kühe und über dem Durchschnitt der Gruppe gelegen hat. Derartiges Verhalten kann, wenn es weiterhin beobachtet wird, Anzeichen darauf geben, dass die Kuh nicht gesund ist. Ein Beispiel wäre an dieser Stelle Klauenprobleme, weshalb sie mehr liegt, um ihre Klauen zu entlasten. Die manuelle Messung hat gezeigt, dass Aussagen über einzelne Tiere bei der Einzeltierbeobachtung möglich ist, obwohl nur zwei Objekteigenschaften angewendet wurden. Eine Kombination der Detektoren von Objekteigenschaften und Objektfertifizierung könnte zukünftig also auch automatisch und in Echtzeit ablaufen.

6.5.5 Automatisierte Messung der Steh- und Liegezeiten der Kühe auf Gruppenebene

6.5.5.1 Bewertung zwischen der automatisierten Methode und der manuellen Auswertung

Die manuelle Auswertung galt wie mehrmals erwähnt als Vergleich zur automatisierten Auswertung der Steh- und Liegezeiten der Kühe. Sie konnte beim Bearbeiten stets sicher durch parallellaufende Videosequenzen kontrolliert werden, wodurch die Richtigkeit der Angaben gewährleistet werden konnte. Diese Aufgabe gestaltete sich zwar zeit- und arbeitsintensiv, bot

aber eine hohe Sicherheit und keine Alternative. Die durchschnittliche Abweichung von 35 Sekunden sind als akzeptabel einzustufen, da das Objekterkennungssystem hin und wieder Fehler aufweist oder Tiere nicht erkennen kann, weil sie verdeckt sind. Dieses Problem gab es in der manuellen Auswertung zwar auch, konnte aber durch das Anschauen von vorherigen oder späteren Sequenzen gelöst werden, wenn in manchen Momenten die Kühe nicht erkennbar gewesen sind. Da der Vergleich zwischen beiden Auswertungen die Summe der Sekunden der Objekteigenschaften der fünf Kühe war, gab es insgesamt 585 Sekunden zu verteilen (5 Kühe*117 Sekunden pro Video). Die automatisierte Methode erreichte nicht immer die gesamte Summe oder überstieg sie sogar, was darauf hinweist, dass manche Kühe entweder kurzweil gar nicht oder doppelt erkannt wurden und dadurch die Überschüsse oder Fehlzeiten aufkamen. Nichtsdestotrotz ist eine durchschnittliche Abweichung von 35 Sekunden bei 585 Sekunden insgesamt als tolerierbar einzustufen. Die höchste Differenz zur manuellen Auswertung betrug -119 Sekunden bei „liegenden“ Kühen, welche generell schwieriger zu erkennen sind, da sie in der Laufbox leichter von „stehenden“ Kühen verdeckt werden konnten. Dementsprechend lag die maximale Differenz bei „stehenden“ Kühen nur bei 67 Sekunden, was auf leichte Fehler des Systems hinweist. Trotz der vorhandenen Differenzen ist die automatisierte Auswertung repräsentativ für die manuelle Methode anwendbar.

6.5.5.2 Bewertung der automatisierten Methode auf Gruppenebene

Die automatisierte Methode konnte erfolgreich auf die Auswertung eines gesamten Tages angewendet werden. Anders als bei der Validierung beider Systeme, bei der drei Videos pro Stunde genutzt wurden, konnten durchgängige Aufzeichnungen von 24 Stunden genutzt werden. Somit kann eine Gruppe von Kühen sehr gut in Echtzeit auf die Objekteigenschaften „stehend“ und „liegend“ detektiert werden. Auch ist es möglich, verschiedene Gruppen von Tieren miteinander zu vergleichen. Das zeigt, dass eine reale Überwachung in Echtzeit möglich ist und auch auf andere Objekteigenschaften übertragen werden könnten. Denkbar wären hier Objekteigenschaften, die die Wasser- und Futteraufnahme und Wiederkäutätigkeit überwachen, Brunstverhalten detektieren, Körperkondition der Tiere erfassen, Verhaltensanomalien aufgrund von Krankheit identifizieren oder sogar Lahmheiten detektieren. Diese Punkte sind in anderen Studien erfolgreich untersucht und getestet worden und sind in Unterkapitel 2.2.3.1.4 beschrieben worden. Realisierbar ist vor allem die Identifizierung einzelner Kühe, wie sie in dieser Arbeit geschaffen wurde, um einzeltierspezifische Aussagen tätigen zu können.

7 Zusammenfassung und Ausblick

Die vorliegende Arbeit befasste sich mit der Tiergesundheitsüberwachung von Rindern via Videosystem und Objekterkennung. Dafür wurden aus Videodateien Bilder extrahiert, um die Rinder in Objekteigenschaften klassifizieren zu können. In drei Versuchen wurden die Objekteigenschaften „stehender“ und „liegender“ Kühe mit dem Objekterkennungsmodell YO-LOv4 trainiert, um einen zuverlässigen Detektor zu erhalten. Dabei mussten die Anzahlen der Bilder bzw. der Label von „liegenden“ Kühen angeglichen werden, um bessere Genauigkeiten zu erhalten. Die mAP des besten neuronalen Netzes betrug 99,21 %. Das Ergebnis lässt sich mit anderen Studien vergleichen.

Der Detektor wurde anschließend auf zwei fremde Umgebungen mit je zwei verschiedenen Kameraperspektiven angewendet, wofür ebenfalls Bilder klassifiziert werden mussten, um die Ergebnisse des Detektors zu evaluieren. Die Genauigkeiten konnten in Tag- und Nachtaufnahmen sowie für „stehende“ und „liegende“ Kühe unterteilt werden. In der ersten Umgebung war die Präzision für „stehende“ Kühe mit 66,92 % am höchsten, während die weiteren Genauigkeiten darunter lagen. In der zweiten Umgebung erreichten die „liegenden“ Kühe mit nur 26,87 % die höchsten Präzisionen. Für jede Umgebung gab es einen zweiten Versuch, in dem lediglich die Kühe im Nahbereich der Kamera betrachtet wurden. Die Genauigkeiten verbesserten sich dabei, sodass in der ersten Umgebung „stehende“ Kühe am Tag mit einer Präzision von 79,32 % und in der zweiten Umgebung die „liegenden“ Kühe am Tag mit einer Genauigkeit von 40,49 % detektiert wurden. Die Objekteigenschaften wurden in der ersten Umgebung am Tage immer besser detektiert als in der Nacht. In der zweiten Umgebung war dieser Trend genau andersherum. Die niedrigen Genauigkeiten in den fremden Umgebungen zeigten, dass der Detektor für fremde Umgebungen noch nicht tauglich ist, da er keine zuverlässigen Genauigkeiten aufweist. Aus den Versuchen der fremden Umgebungen heraus wurde erkenntlich, dass Faktoren wie Beleuchtung, Stalleinbauten, die Kamerapositionierung sowie die Bildgröße der Videos, der Nahbereich der Kamera und das gegenseitige Verdecken der Tiere eine erhebliche Bedeutung für die Qualität der Detektion besitzen.

Bei der Individualisierung einer Gruppe von fünf Kühen wurden wiederum Bilder aus Videos extrahiert und klassifiziert. Das Ziel war jede Kuh individualisiert zu detektieren. Die mAP für den Versuch lag bei 99,79 %, welche besser ist als vergleichbare Studien. Anhand der Ergebnisse bestand nun die Möglichkeit einzeltierbezogene Aussagen zu treffen, wenn man diese Kühe mit den Objekteigenschaften „stehend“ und „liegend“ testet. Um dafür eine Basis zu schaffen, wurde eine manuelle Messung der Steh- und Liegezeiten für die individualisierten Kühe anhand von zwei unterschiedlichen Tagen durchgeführt. Für jeden Tag wurden aus einer Tagesstunde drei kurze Videos herausgesucht und genutzt. Die Ergebnisse zeigten klare Unterschiede im Verhalten der Rinder untereinander auf. Die manuelle Auswertung sollte

anschließend mit einer automatisierten Auswertung auf Gruppenebene verglichen werden, um die Plausibilität und Anwendbarkeit der automatisierten Methode zu garantieren. Die zeitlichen Differenzen beider Systeme lagen sehr niedrig.

Die automatisierte Methode konnte erfolgreich auf die Auswertung eines gesamten Tages angewendet werden. Hierbei wurden nicht auszugsweise Videos ausgewählt, sondern ein gesamter Tag von 24 Stunden auf die Objekteigenschaften detektiert. Somit ist eine Überwachung in Echtzeit realisierbar und möglich.

Hinsichtlich auf mögliche zukünftige Forschungen und Verbesserungen lassen sich einige Punkte nennen. Der Detektor für die Objekteigenschaften müsste für bessere Ergebnisse in fremden Umgebungen vielfältigeres Bildmaterial in die Trainingsmenge aufnehmen, um keine gewohnte Umgebung zu haben. Lichtquellen sollten ausreichend vorhanden und so angebracht sein, dass keine Lichtkegelbildung stattfindet und das Licht gleichmäßig verteilt wird. Die Kamerapositionierung ist ein sehr wichtiger Faktor, der bedingen kann, ob viele Stalleinbauten die Kühe verdecken oder nicht. Auch, aus welchem Winkel und von welcher Höhe die Kamera das Sichtfeld auf die Tiere hat, ist entscheidend. Um die automatisierte Videoauswertung von der Gruppenebene auf eine automatisierte Erfassung der Steh- und Liegezeiten für individualisierte Tiere zu realisieren, müssten zukünftig die Detektoren zur Objektindividualisierung und Objekteigenschaften kombiniert werden. Das Ergebnis wäre das Verhalten einer einzelnen individualisierten Kuh. Die untere Grafik wäre ein beispielhafter Ablauf der automatischen Videoauswertung. Weiterhin wäre es denkbar und möglich noch weitere Objekteigenschaften mit einer Individualisierung zu kombinieren.

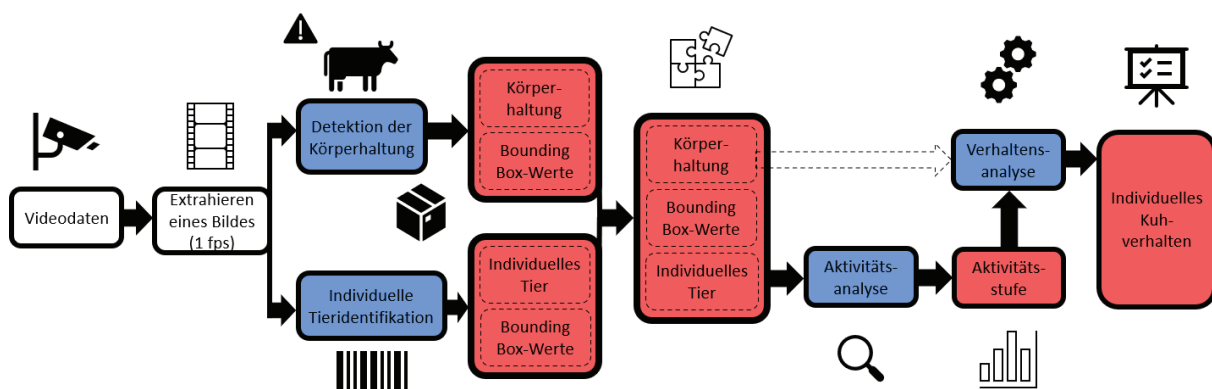


Abbildung 30 Ablauf einer möglichen automatischen Videoauswertung: Weiß: Rohmaterial, Blau: Detektion und Analyse, Rot: Ergebnisse, verändert nach Schütz (2023).

8 Literaturverzeichnis

- Adrion, F., Kapun, A., Eckert, F., Holland, E.-M., Staiger, M., Götz, S., & Gallmann, E. (2018). Monitoring trough visits of growing-finishing pigs with UHF-RFID. *Computers and Electronics in Agriculture*, 144, 144-153. doi:<https://doi.org/10.1016/j.compag.2017.11.036>
- AgEagle. (2019). Using mapping drones for wildlife monitoring and conservation. Retrieved from <https://ageagle.com/use-cases/using-mapping-drones-for-wildlife-monitoring-and-conservation/> (17.05.2023)
- Agilox. (2023). Automatische Erkennung der jeweiligen Eieder bei Freilandhühnern mit RFID. Retrieved from <https://www.agilox.com/de/fallstudien/rfid-huehnerzucht-management.php> (15.07.2023)
- Allflex. (2020). Allflex Heat Detection Technology Improves Heifer Fertility Scores on Crofthead Farm. Retrieved from https://www.allflex.global/cn/wp-content/uploads/sites/12/2021/06/Suc_EMEA5_A4_Eng_June-20_low-3.pdf (17.07.2023)
- Alreshidi, E. (2019). Smart Sustainable Agriculture (SSA) Solution Underpinned by Internet of Things (IoT) and Artificial Intelligence (AI). *International Journal of Advanced Computer Science and Applications (IJACSA)*, 10(5). doi:<http://dx.doi.org/10.14569/IJACSA.2019.0100513>
- Anagnostopoulos, A., Griffiths, B. E., Siachos, N., Neary, J., Smith, R. F., & Oikonomou, G. (2023). Initial validation of an intelligent video surveillance system for automatic detection of dairy cattle lameness. *Front Vet Sci*, 10, 1111057. doi:10.3389/fvets.2023.1111057
- Becker, F., Kanitz, W., & Heuwieser, W. (2005). Vor- und Nachteile einzelner Methoden der Brunsterkennung beim Rind. *Züchtungskunde. Eugen Ulmer Verlag GmbH & Co.*, 77, S. 140-150.
- Berckmans, D. (2014). Precision livestock farming technologies for welfare management in intensive livestock systems. *Rev Sci Tech*, 33(1), 189-196. doi:10.20506/rst.33.1.2273
- Berckmans, D. (2017). General introduction to precision livestock farming. *Animal Frontiers*, 7(1), 6-11. doi:10.2527/af.2017.0102
- BigDutchman. (2017). Stallklima: Neuartiger Messfühler ist ein Meilenstein in der Schweinehaltung. Retrieved from <https://www.bigdutchman.de/de/schweinehaltung/aktuelles/detail/stallklima-neuartiger-messfuehler-ist-ein-meilenstein-in-der-schweinehaltung/> (16.07.2023)
- BigDutchman. (2021). Schweinehaltung: Künstliche Intelligenz und Kamera „wiegen“ Schweine. Retrieved from <https://www.bigdutchman.de/de/schweinehaltung/aktuelles/detail/schweinehaltung-mit-kuenstlicher-intelligenz-und-kamera-wiegen/>, <https://www.bigdutchman.de/de/schweinehaltung/produkte/detail/weightcheck/> (31.07.2023)
- BLE. (2021, 11.01.2021). Burnout - Auch in der Landwirtschaft ein Problem. Retrieved from <https://www.praxis-agrar.de/betrieb/betriebsfuehrung/burnout> (28.02.2023)
- BlesDairies. (2018). Ida: The Intelligent Dairy Farmer's Assistant. Retrieved from <https://www.bles-dairies.nl/ida-the-intelligent-dairy-farmers-assistant/> (15.07.2023)
- BMEL. (2023). Tiergesundheit. Retrieved from https://www.bmel.de/DE/themen/tiere/tiergesundheit/tiergesundheit_node.html (24.07.2023)
- Brambell, F. W. R. (1965). *Report of the Technical Committee to Enquire Into the Welfare of Animals Kept Under Intensive Livestock Husbandry Systems* (OCLC number: 475844139). Retrieved from <https://books.google.de/books?id=KcbwPgAACAAJ> (13.06.2023)
- Buller, H., Blokhuis, H., Lokhorst, K., Silberberg, M., & Veissier, I. (2020). Animal Welfare Management in a Digital World. *Animals*, 10(10), 1779. Retrieved from <https://www.mdpi.com/2076-2615/10/10/1779> (20.06.2023) doi:10.3390/ani10101779

- Büscher, W., Haidn, B., Häuser, S., Klindtworth, K., Mohr, U., & Pfeiffer, J. (2021). *Digitale Anwendungen für das Herdenmanagement in der Milchviehhaltung*. Retrieved from Frankfurt am Main, Eschborner Straße: https://www.dlg.org/fileadmin/downloads/landwirtschaft/themen/publikationen/merkblaetter/dlg-merkblatt_466.pdf (16.06.2023)
- <https://www.dlg.org/de/landwirtschaft/themen/technik/technik-tierhaltung/dlg-merkblatt-466>
- Cainthus. (2023). Animal Nutrition and Welfare Insights for Your Dairy Farm. Retrieved from <https://www.ever.ag/dairy/software-solutions/cainthus/> (17.07.2023)
- Cargill. (2018). Cargill brings facial recognition capability to farmers through strategic equity investment in Cainthus. Retrieved from <https://www.cargill.com/2018/cargill-brings-facial-recognition-capability-to-farmers> (17.07.2023)
- cattleeye. (2023). How it works. Retrieved from <https://cattleeye.com/> (17.07.2023)
- connecterra. (2023). Increasing farm productivity. Retrieved from <https://connecterra.ai/> (17.07.2023)
- Cordis. (2020). The AI-based intelligent assistant for dairy farmers. Retrieved from <https://cordis.europa.eu/article/id/422608-efficient-greener-farming/de> (17.07.2023)
- Cowmanager. (2023). Erfassung der Ohrtemperatur. Retrieved from <https://www.cowmanager.de/> (13.07.2023)
- Dac, H. H., Gonzalez Viejo, C., Lipovetzky, N., Tongson, E., Dunshea, F. R., & Fuentes, S. (2022). Livestock Identification Using Deep Learning for Traceability. *Sensors (Basel)*, 22(21). doi:10.3390/s22218256
- Daglioglu, M. A. (2021). *Object-Detection mit You Only Look Once (YOLO) : Einführung in die Objekterkennung mit YOLO sowie die Weiterentwicklung in den Versionen v2-v4*. Retrieved from <https://opus4.kobv.de/opus4-hof/frontdoor/index/index/docId/117>
- <https://nbn-resolving.org/urn:nbn:de:bvb:1051-opus4-1175> (14.06.2023)
- Dahlhoff, K. P., A. (2020). CowsAndMore: Was uns die Kühe sagen. *Hof & Feld*, 22, 5. Retrieved from <https://proplant.de/wp-content/uploads/CowsAndMore-2-Beitr%c3%a4ge-LZ-Rheinland-22-2020.pdf>
- DeLaval. (2023). Artificial intelligence enhances farmer insight. Retrieved from <https://corporate.delaval.com/2023/05/artificial-intelligence-enhances-farmer-insight/> (17.07.2023)
- Destatis. (2018). Arbeitszeiten 2018: Längste Arbeitszeiten in der Land- und Forstwirtschaft, kürzeste im Verarbeitenden Gewerbe. *Pressemitteilung Nr. 071*. Retrieved from https://www.destatis.de/DE/Presse/Pressemitteilungen/2020/03/PD20_071_133.html#:~:text=WIESBADEN%20%E2%80%93%20Im%20Jahr%202018%20hatten,4%20Wochenstunden%20die%20k%C3%BCrzensten%20Arbeitszeiten.
- Destatis. (2020). Trend zu Großbetrieben in der Landwirtschaft - Schweinehaltung besonders betroffen. *Pressemitteilung Nr. N 001*. Retrieved from https://www.destatis.de/DE/Presse/Pressemitteilungen/2020/01/PD20_N001_413.html (28.02.2023)
- Diskin, M. G., & Sreenan, J. M. (2000). Expression and detection of oestrus in cattle. *Reprod Nutr Dev*, 40(5), 481-491. doi:10.1051/rnd:2000112
- dlg. (2018). Sensoren in der Nutztierhaltung. Retrieved from <https://www.dlg.org/de/landwirtschaft/presse/aktuell#!/news/sensoren-in-der-nutztierhaltung-5b4ed760> (11.07.2023)
- dlg. (2022). Bedeutung digitaler Systeme für die Tiergesundheit. Retrieved from <https://www.dlg.org/de/mitgliedschaft/newsletter-archiv/2022/09/bedeutung-digitaler-systeme-fuer-die-tiergesundheit> (16.07.2023)
- Dulal, R., Zheng, L., Kabir, A., McGrath, S., Medway, J., Swain, D., & Swain, W. (2023). *Automatic cattle identification using YOLOv5 and Mosaic Augmentation: A comparative analysis*. Paper presented at the International Conference on Digital Image Computing: Techniques and Applications 2022, Sydney, New South Wales, Australia., <http://arxiv.org/abs/2210.11939>

- Eilers, U. (2012). *Anforderungen und Steuerung des Klimas in Rinderställen*. Retrieved from https://www.landwirtschaft-bw.de/site/pbs-bw-new/get/documents/MLR.LEL/PB5Documents/lazbw_rh/pdf/a/Anforderungen%20und%20Steuerung%20des%20Klimas%20in%20Rinderst%C3%A4llen.pdf?attachment=true (16.05.2023)
- Europäische Kommission. (2019, 08-03-2021). A definition of Artificial Intelligence: main capabilities and scientific disciplines. Retrieved from <https://digital-strategy.ec.europa.eu/de/node/2226>, https://ec.europa.eu/newsroom/dae/document.cfm?doc_id=56341 (31.07.2023)
- europarl. (2020, 20-06-2023). Was ist künstliche Intelligenz und wie wird sie genutzt? Retrieved from <https://www.europarl.europa.eu/news/de/headlines/society/20200827STO85804/was-ist-kunstliche-intelligenz-und-wie-wird-sie-genutzt#:~:text=KI%20erm%C3%B6glicht%20es%20technischen%20Systemen,%20C%20verarbeitet%20sie%20und%20reagiert>. (31.07.2023)
- Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J., & Zisserman, A. (2010). The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*, 88(2), 303-338. doi:10.1007/s11263-009-0275-4
- Fasching, C. (2016). *Precision Livestock Farming - Überblick über Systeme in der Rinderhaltung und ihre Bedeutung für Tierwohl und Tiergesundheit* (ISBN 978-3-902849-26-7). Retrieved from
- Fasching, C., & Gasteiner, J. (2021). Wie Sensoren die Tierbeobachtung revolutionieren. Retrieved from <https://noe.lko.at/wie-sensoren-die-tierbeobachtung-revolutionieren+2400+3512727> (12.07.2023)
- Fasching, C., Ofner-Schröck, E., Huber, G., Taferner, K., & Gasteiner, J. (2018). Sensortechnik im Herdenmanagement. Retrieved from https://www.lkv-stmk.at/files/leistungspruefung/leistungspruefung_milch/Sensortechnik.pdf (15.07.2023)
- FAWC. (2012, 16.04.2009). Five Freedoms. Retrieved from <https://webarchive.nationalarchives.gov.uk/ukgwa/20121010012427/http://www.fawc.org.uk/freedoms.htm> (04.03.2023)
- Feldner, S., & Donicht, S. (2016). Die tägliche Rinderkontrolle - der gesetzliche Rahmen und das "Auge" für das Tier. 6. Retrieved from https://www.proteinmarkt.de/fileadmin/bilder/fachartikel/2016/FA_Rind_Nr._8_Tierschutzindikatoren_Fachartikel.pdf (24.07.2023)
- Firk, R., Stamer, E., Junge, W., & Krieter, J. (2002). Automation of oestrus detection in dairy cows: A review. *Livestock Production Science*, 75, 219-232. doi:10.1016/S0301-6226(01)00323-2
- Fraser, D. (2008). Understanding animal welfare. *Acta Veterinaria Scandinavica*, 50(S1), S1. doi:10.1186/1751-0147-50-s1-s1
- Fraser, D., Weary, D. M., Pajor, E. A., & Milligan, B. N. (1997). A Scientific Conception of Animal Welfare that Reflects Ethical Concerns. *Animal Welfare*, 6(3), 187-205. doi:10.1017/S0962728600019795
- Fröhlich, G., Böck, S., Thurner, S., Weinfurtner, S., & Wendl, G. (2004). Elektronisches Identifikationssystem zur Erfassung des Verhaltens von Legehennen (Referat). Retrieved from <https://www.lfl.bayern.de/ilt/mechatronik/019218/index.php> (15.07.2023)
- Fu, L., Li, S., Kong, S., Ni, R., Pang, H., Sun, Y., . . . Gong, H. (2022). Lightweight individual cow identification based on Ghost combined with attention mechanism. *PLoS One*, 17(10), e0275435. doi:10.1371/journal.pone.0275435
- GEA. (2023). Detect Disease faster with camera and artificial intelligence. Retrieved from <https://www.gea.com/en/news/trade-press/2023/gea-farm-technologies-cattleeye-partnership.jsp> (17.07.2023)
- Gries, A., & Gassmann, E. (2009). *Elektronische Druckmesstechnik, Grundlagen, Anwendungen und Geräteauswahl* (Vol. 323). München: Süddeutscher Verlag onpact GmbH (ISBN 978-3-937889-95-5).

- Hemsworth, P. H., Barnett, J. L., & Coleman, G. J. (1993). The Human-Animal Relationship in Agriculture and Its Consequences for the Animal. *Animal Welfare*, 2(1), 33-51. doi:10.1017/S096272860001544X
- HerdDogg. (2023). The Complete Data Capture System. Retrieved from <https://www.herddogg.com/> (17.07.2023)
- Heuwieser, W., & Mansfeld, R. (1995). Brunstbeobachtung beim Rind. *Milchpraxis*, 33, 75-79.
- Hoffmann, V. (2020). Burnout: Wer kann helfen? Retrieved from https://www.bildungsserveragrar.de/fileadmin/Redaktion/Fachzeitschrift/2020-3/BB_Agrar_03_2020_Burnout_Wer_kann_helfen.pdf (20.04.2023)
- Holman, A., Thompson, J., Routly, J. E., Cameron, J., Jones, D. N., Grove-White, D., . . . Dobson, H. (2011). Comparison of oestrus detection methods in dairy cattle. *Vet Rec*, 169(2), 47. doi:10.1136/vr.d2344
- Hosey, G. (2013). Hediger revisited: how do zoo animals see us? *J Appl Anim Welf Sci*, 16(4), 338-359. doi:10.1080/10888705.2013.827916
- HotracoAgri. (2023a). Automatische Futtersteuerung reduziert Futterkosten. Retrieved from <https://www.hotraco-agri.com/de/l%C3%B6sungen-f%C3%BCr-gefl%C3%BCgel-futter-und-wassersteuerung/> (17.07.2023)
- HotracoAgri. (2023b). Optimale Bedingungen für Geflügelställe. Retrieved from <https://www.hotraco-agri.com/de/l%C3%B6sungen-f%C3%BCr-gefl%C3%BCgel/> (17.07.2023)
- Hulsen, J. (2021). *Kuhsignale - Krankheiten und Störungen früher erkennen* (L. Giuanna Egger-Maissen, Trans.). Niederlande: Root Bont, CowSignals, Vetvice - ISBN 978-3-7843-3342-7.
- ida. (2023). Smart assistance, simply delivered. Retrieved from <https://de.ida.io/en/> (17.07.2023)
- IKS-Fraunhofer. (2023). Künstliche Intelligenz (KI) und maschinelles Lernen. Retrieved from <https://www.iks.fraunhofer.de/de/themen/kuenstliche-intelligenz.html> (31.07.2023)
- IoTforAll. (2023). Quantified Ag Cattle Management System. Retrieved from <https://www.ietfforall.com/solution/quantified-ag-cattle-management-system> (17.07.2023)
- Jiang, M., Rao, Y., Zhang, J., & Shen, Y. (2020). Automatic behavior recognition of group-housed goats using deep learning. *Computers and Electronics in Agriculture*, 177, 105706. doi:<https://doi.org/10.1016/j.compag.2020.105706>
- Jilg, T., Gerster, E., Hertel-Böhnke, P., & Pries, M. (2018). *Nutzung von Sensoren - Datenüberblick, Erfahrungen und Ergebnisse*. Retrieved from Aulendorf: https://www.lfl.bayern.de/mam/cms07/publikationen/daten/schriftenreihe/verbundprojekt-optikuh-abschluss-2018_lfl-schriftenreihe.pdf (29.07.2023)
- Kamphuis, C., Pietersma, D., van der Tol, R., Wiedemann, M., & Hogeveen, H. (2008). Using sensor data patterns from an automatic milking system to develop predictive variables for classifying clinical mastitis and abnormal milk. *Computers and Electronics in Agriculture*, 62(2), 169-181. doi:<https://doi.org/10.1016/j.compag.2007.12.009>
- Kang, X., Zhang, X. D., & Liu, G. (2020). Accurate detection of lameness in dairy cattle with computer vision: A new and individualized detection strategy based on the analysis of the supporting phase. *J Dairy Sci*, 103(11), 10628-10638. doi:10.3168/jds.2020-18288
- Kapun, A., Adrion, F., & Gallmann, E. (2020). Case Study on Recording Pigs' Daily Activity Patterns with a UHF-RFID System. *Agriculture*, 10(11), 542. doi:10.3390/agriculture10110542
- Kehl, C., Meyer, R., & Steiger, S. (2021). Digitalisierung der Landwirtschaft: technologischer Stand und Perspektiven. Teil I des Endberichts zum TA-Projekt. doi:10.5445/ir/1000142950
- Kluyver, T., Ragan-Kelley, B., Pérez, F., Granger, B. E., Bussonnier, M., Frederic, J., . . . Team, J. D. (2016). Jupyter Notebooks - a publishing format for reproducible computational workflows. *International Conference on Electronic Publishing*. doi: 10.3233/978-1-61499-649-1-87
- KTBL. (2016). Tierschutzindikatoren: Leitfaden für die Praxis - Rind. Retrieved from ISBN 978-3-945088-26-5

- KTBL. (2020a). Tierschutzindikatoren: Leitfaden für die Praxis - Schwein Mastschwein. 2.Auflage. 2. Retrieved from https://www.ktbl.de/fileadmin/user_upload/Allgemeines/Download/Tierwohl/Leitfaden2020_Aufzuchtferkel_Mastschweine.pdf (20.06.2023)
- KTBL. (2020b). Tierschutzindikatoren: Leitfaden für die Praxis – Geflügel. Retrieved from ISBN ISBN 978-3-945088-77-7
- KTBL. (2021). Betriebliche Eigenkontrolle Tierwohl. Retrieved from https://www.ktbl.de/fileadmin/user_upload/Allgemeines/Download/Tierwohl/Eigenkontrolle_Tierwohl.pdf (03.07.2023)
- Kunzmann, P. (2015). Die moralische Rahmenhandlung. Geflügelhaltung in gewandelter Gesellschaft. In K. Damme & F. Muth (Eds.), *Geflügeljahrbuch 2016: Schwerpunkt: Tierwohl. Jahrbuch des Zentralverbandes der Deutschen Geflügelwirtschaft u. seiner Mitgliederverbände*. Stuttgart: Ulmer - ISBN 978-3-8001-1276-0.
- Lagua, E. B., Mun, H.-S., Ampode, K. M. B., Chem, V., Kim, Y.-H., & Yang, C.-J. (2023). Artificial Intelligence for Automatic Monitoring of Respiratory Health Conditions in Smart Swine Farming. *Animals*, 13(11), 1860. doi:10.3390/ani13111860
- Lely. (2023). There is an untapped potential in data. Retrieved from <https://www.lely.com/solutions/farming-with-data/> (17.07.2023)
- LfL. (2023). Sensorik am Rind - Die Fitness-Uhr für die Kuh. Retrieved from <https://www.lfl.bayern.de/ilt/digitalisierung/252250/index.php> (11.07.2023)
- LfULG. (2013). Aufgabe und Chance Tierwohl. Retrieved from https://www.landwirtschaft.sachsen.de/download/ZusammenfassungMeyer_Schweine_tag2013korrigiert.pdf (25.07.2023)
- Li, G., Erickson, G. E., & Xiong, Y. (2022). Individual Beef Cattle Identification Using Muzzle Images and Deep Learning Techniques. *Animals (Basel)*, 12(11). doi:10.3390/ani12111453
- Lieboldt, M.-A. (2023). Landwirte setzen auf KI: Projekt DigiSchwein soll bei Tierwohl helfen. Retrieved from <https://www.wochenblatt-dlv.de/feld-stall/tierhaltung/landwirte-setzen-ki-projekt-digischwein-tierwohl-helfen-573530> (31.07.2023)
- Liu, X., & Spahr, S. L. (1993). Automated electronic activity measurement for detection of estrus in dairy cattle. *J Dairy Sci*, 76(10), 2906-2912. doi:10.3168/jds.S0022-0302(93)77630-4
- Luo, S., Ma, Y., Jiang, F., Wang, H., Tong, Q., & Wang, L. (2023). Dead Laying Hens Detection Using TIR-NIR-Depth Images and Deep Learning on a Commercial Farm. *Animals*, 13(11), 1861. doi:10.3390/ani13111861
- Maselyne, J., Adriaens, I., Huybrechts, T., De Ketelaere, B., Millet, S., Vangeyte, J., . . . Saeys, W. (2016). Measuring the drinking behaviour of individual pigs housed in group using radio frequency identification (RFID). *Animal*, 10(9), 1557-1566. doi:10.1017/s1751731115000774
- Nasirahmadi, A., Edwards, S., & Sturm, B. (2017). Implementation of machine vision for detecting behaviour of cattle and pigs. *Livestock Science*, 202, 25-38. doi:<https://doi.org/10.1016/j.livsci.2017.05.014>
- Nasirahmadi, A., Sturm, B., Edwards, S., Jeppsson, K. H., Olsson, A. C., Müller, S., & Hensel, O. (2019). Deep Learning and Machine Vision Approaches for Posture Detection of Individual Pigs. *Sensors (Basel)*, 19(17). doi:10.3390/s19173738
- Nebel, R. L., Dransfield, M. G., Jobst, S. M., & Bame, J. H. (2000). Automated electronic systems for the detection of oestrus and timing of AI in cattle. *Anim Reprod Sci*, 60-61, 713-723. doi:10.1016/s0378-4320(00)00090-7
- Neethirajan, S., Tuteja, S. K., Huang, S.-T., & Kelton, D. (2017). Recent advancement in biosensors technology for animal and livestock health management. *Biosensors and Bioelectronics*, 98, 398-407. doi:10.1016/j.bios.2017.07.015
- Norton, T., Chen, C., Larsen, M. L. V., & Berckmans, D. (2019). Review: Precision livestock farming: building 'digital representations' to bring the animals closer to the farmer. *Animal*, 13(12), 3009-3017. doi:<https://doi.org/10.1017/S175173111900199X>

- Pennington, J. A., Albright, J. L., & Callahan, C. J. (1986). Relationships of sexual activities in estrous cows to different frequencies of observation and pedometer measurements. *J Dairy Sci*, 69(11), 2925-2934. doi:10.3168/jds.S0022-0302(86)80748-2
- Pfeiffer, J., Gandorfer, M., & Ettema, J. F. (2020). Evaluation of activity meters for estrus detection: A stochastic bioeconomic modeling approach. *Journal of Dairy Science*, 103(1), 492-506. doi:<https://doi.org/10.3168/jds.2019-17063>
- Pfeiffer, J., Gandorfer, M., & Wendl, G. (2018). Bewertung automatischer Brunsterkennung in der Milchviehhaltung. *Digitale Marktplätze und Plattformen*, 183, 4. Retrieved from https://gil-net.de/Publicationen/30_183.pdf (25.07.2023)
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788. doi:10.1109/CVPR.2016.91
- Redmon, J., & Farhadi, A. (2018). Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*. Retrieved from <https://arxiv.org/abs/1804.02767> (26.04.2023)
- Reiter, S., Sattlecker, G., Lidauer, L., Kickinger, F., Öhlschuster, M., Auer, W., . . . Iwersen, M. (2018). Evaluation of an ear-tag-based accelerometer for monitoring rumination in dairy cows. *J Dairy Sci*, 101(4), 3398-3411. doi:10.3168/jds.2017-12686
- Roelofs, J. B., van Eerdenburg, F. J., Soede, N. M., & Kemp, B. (2005). Various behavioral signs of estrous and their relationship with time of ovulation in dairy cattle. *Theriogenology*, 63(5), 1366-1377. doi:10.1016/j.theriogenology.2004.07.009
- Rohleder, B., Krüsken, B., & Reinhardt, H. (2020). Digitalisierung in der Landwirtschaft 2020. Retrieved from https://www.bitkom-research.de/system/files/document/200427_PK_Digitalisierung_der_Landwirtschaft.pdf (28.02.2023)
- Roxell. (2020). Markttrend: RFID-Chip verändert den Schweinesektor. Retrieved from <https://www.roxell.com/de/nachrichten/markttrend-rfid-chip-veraendert-den-schweinesektor> 15.07.2023
- Ruuska, S., Kajava, S., Mughal, M., Zehner, N., & Mononen, J. (2015). Validation of a pressure sensor-based system for measuring eating, rumination and drinking behaviour of dairy cattle. *Applied Animal Behaviour Science*, 174. doi:10.1016/j.applanim.2015.11.005
- Salau, J., & Krieter, J. (2020). Instance Segmentation with Mask R-CNN Applied to Loose-Housed Dairy Cows in a Multi-Camera Setting. *Animals (Basel)*, 10(12). doi:10.3390/ani10122402
- Schultheiß, U., Zapf, R., Martini, D., Gund, S., Rauterberg, S., Schubbert, A., . . . March, S. (2021). *Praxistauglichkeit von Tierschutzindikatoren bei der betrieblichen Eigenkontrolle, Erarbeitung eines Orientierungsrahmens sowie technische Umsetzung in digitalen Anwendungen ("Eigenkontrolle Tiergerechtigkeit" "EiKoTiGer")*. Retrieved from Darmstadt, Celle, Witzenhausen, Trenthorst: https://literatur.thuenen.de/digbib_extern/dn063986.pdf (24.07.2023)
- Schütz, A. (2023). [Persönliche Arbeit und Übergabe der Ergebnisse von Anne Schütz an mich].
- Schütz, A., Krause, E. T., Fischer, M., Müller, T., Freuling, C. M., Conraths, F. J., . . . Lentz, H. H. K. (2022). Computer Vision for Detection of Body Posture and Behavior of Red Foxes. *Animals (Basel)*, 12(3). doi:10.3390/ani12030233
- Schütz, A., Schöler, V., Krause, T. E., Fischer, M., Müller, T., Freuling, C. M., . . . Lentz, H. H. K. (2021). Application of YOLOv4 for Detection and Motion Monitoring of Red Foxes. *Animals*, 11(6), 1723. doi:10.3390/ani11061723
- Shao, D., He, Z., Fan, H., & Sun, K. (2023). Detection of Cattle Key Parts Based on the Improved Yolov5 Algorithm. *Agriculture*, 13(6), 1110. doi:10.3390/agriculture13061110
- Siegford, J. M., Berezowski, J., Biswas, S. K., Daigle, C. L., Gebhardt-Henrich, S. G., Hernandez, C. E., . . . Toscano, M. J. (2016). Assessing Activity and Location of Individual Laying Hens in Large Groups Using Modern Technology. *Animals (Basel)*, 6(2). doi:10.3390/ani6020010

- Silvera, A. M., Knowles, T. G., Butterworth, A., Berckmans, D., Vranken, E., & Blokhuis, H. J. (2017). Lameness assessment with automatic monitoring of activity in commercial broiler flocks. *Poult Sci*, *96*(7), 2013-2017. doi:10.3382/ps/pex023
- smaXtec. (2020). Ein guter Start für Kalb und Kuh: Abkalbungen bei Milchkühen. Retrieved from <https://smaxtec.com/de/blog/abkalbungen-erkennen/> (30.07.2023)
- Sorge, R. E., Martin, L. J., Isbester, K. A., Sotocinal, S. G., Rosen, S., Tuttle, A. H., . . . Mogil, J. S. (2014). Olfactory exposure to males, including men, causes stress and related analgesia in rodents. *Nature Methods*, *11*(6), 629-632. doi:10.1038/nmeth.2935
- Spoliansky, R., Edan, Y., Parmet, Y., & Halachmi, I. (2016). Development of automatic body condition scoring using a low-cost 3-dimensional Kinect camera. *J Dairy Sci*, *99*(9), 7714-7725. doi:10.3168/jds.2015-10607
- Sveberg, G., Refsdal, A. O., Erhard, H. W., Kommisrud, E., Aldrin, M., Tvette, I. F., . . . Ropstad, E. (2011). Behavior of lactating Holstein-Friesian cows during spontaneous cycles of estrus. *Journal of Dairy Science*, *94*(3), 1289-1301. doi:<https://doi.org/10.3168/jds.2010-3570>
- TarmstedterAusstellung. (2022). Künstliche Intelligenz im Kuhstall. Retrieved from <https://www.tarmstedter-ausstellung.de/news/kuenstliche-intelligenz-im-kuhstall/> (17.07.2023)
- TierSchG, B. f. J. (2020). Tierschutzgesetz. 2020. Retrieved from <https://www.gesetze-im-internet.de/tierschg/BJNR012770972.html> (24.02.2023)
- TierSchNutzTV, B. f. J. (2021). Verordnung zum Schutz landwirtschaftlicher Nutztiere und anderer zur Erzeugung tierischer Produkte gehaltener Tiere bei ihrer Haltung (Tierschutz-Nutztierhaltungsverordnung - TierSchNutzTV). 2021. Retrieved from <https://www.gesetze-im-internet.de/tierschnutztv/> (24.02.2023)
- Toppel, K., & Kaufmann, F. (2023). Digitales Herdenmanagement in der Geflügelhaltung. Retrieved from <https://www.dgs-magazin.de/themen/stallbau-ausruestung/article-7405073-175624/digitales-herdenmanagement-in-der-gefuegelhaltung-.html> (17.07.2023)
- Traulsen, K. (2014, 13.06.2023). Die Kuh brüllt unhörbar vor Schmerz. Retrieved from <https://www.milchpraxis.com/schmerz/> (20.08.2023)
- Tzutalin, D. (2015). Labellmg. Git code. Retrieved from <https://github.com/tzutalin/labellmg> (24.04.2023)
- Van Eerdenburg, F. J., Karthaus, D., Taverne, M. A., Merics, I., & Szenci, O. (2002). The relationship between estrous behavioral score and time of ovulation in dairy cattle. *J Dairy Sci*, *85*(5), 1150-1156. doi:10.3168/jds.s0022-0302(02)74177-5
- van Rossum, G., & Drake, F. L., Jr. (2014). *The Python Language Reference; Python Software Foundation: Wilmington, DE, USA*.
- Van Vliet, J. H., & Van Eerdenburg, F. J. C. M. (1996). Sexual activities and oestrus detection in lactating Holstein cows. *Applied Animal Behaviour Science*, *50*(1), 57-69. doi:[https://doi.org/10.1016/0168-1591\(96\)01068-4](https://doi.org/10.1016/0168-1591(96)01068-4)
- Volkman, N., Kulig, B., Hoppe, S., Stracke, J., Hensel, O., & Kemper, N. (2021). On-farm detection of claw lesions in dairy cows based on acoustic analyses and machine learning. *J Dairy Sci*, *104*(5), 5921-5931. doi:10.3168/jds.2020-19206
- Wagner, M. (2017, 2021 June). Was man über Melkroboter wissen muss. Retrieved from <https://www.melkroboter.net/> (15.07.2023)
- Wang, Wang, N., Li, L., & Ren, Z. (2020). Real-time behavior detection and judgment of egg breeders based on YOLO v3. *Neural Computing and Applications*, *32*(10), 5471-5481. doi:10.1007/s00521-019-04645-4
- Wang, Y., Chen, T., Li, B., & Li, Q. (2023). Automatic identification and analysis of multi-object cattle rumination based on computer vision. *J Anim Sci Technol*, *65*(3), 519-534. doi:10.5187/jast.2022.e87
- Weiß, J., Pabst, W., Strack, K. E., & Granz, S. (2005). Tierproduktion. *13. überarbeitete Auflage*, 579. doi:10.1055/b-0034-34002
- Werner, J., Leso, L., Umstatter, C., Niederhauser, J., Kennedy, E., Geoghegan, A., . . . O'Brien, B. (2018). Evaluation of the RumiWatchSystem for measuring grazing behaviour of

- cows. *Journal of Neuroscience Methods*, 300, 138-146. doi:<https://doi.org/10.1016/j.jneumeth.2017.08.022>
- WFI. (2023). Pig-Cough Monitor. Retrieved from <https://www.worldfoodinnovations.com/innovation/pig-cough-monitor> (31.07.2023)
- White, B. J., Coetzee, J. F., Renter, D. G., Babcock, A. H., Thomson, D. U., & Andresen, D. (2008). Evaluation of two-dimensional accelerometers to monitor behavior of beef calves after castration. *Am J Vet Res*, 69(8), 1005-1012. doi:10.2460/ajvr.69.8.1005
- Yang, A., Huang, H., Zheng, B., Li, S., Gan, H., Chen, C., . . . Xue, Y. (2020). An automatic recognition framework for sow daily behaviours based on motion and image analyses. *Biosystems Engineering*, 192, 56-71. doi:<https://doi.org/10.1016/j.biosystemseng.2020.01.016>
- Yılmaz, A., Uzun, G. N., Gürbüz, M. Z., & Kıvrak, O. (2021). Detection and Breed Classification of Cattle Using YOLO v4 Algorithm. *2021 International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*, 1-4. doi:10.1109/INISTA52262.2021.9548440
- Zeng, N. (2018, 16.12.2018). An Introduction to Evaluation Metrics for Object Detection. Retrieved from <https://blog.zenggyu.com/en/post/2018-12-16/an-introduction-to-evaluation-metrics-for-object-detection/> (28.04.2023)
- Zieger, P. (2004). Brunsterkennung optimieren. *Milchrind*, 2, 48-50.
- Zin, T. T., Pwint, M. Z., Seint, P. T., Thant, S., Misawa, S., Sumi, K., & Yoshida, K. (2020). Automatic Cow Location Tracking System using Ear Tag Visual Analysis. *Sensors (Basel)*, 20(12). doi:10.3390/s20123564
- Zinke, O. (2019). Tabu-Thema: Selbstmorde von Landwirten. Retrieved from <https://www.agrarheute.com/land-leben/tabu-thema-selbstmorde-landwirten-554007> (28.02.2023)

A Eidesstattliche Erklärung

Hiermit erkläre ich an Eides statt, dass ich die vorliegende Arbeit selbstständig und ohne Benutzung anderer als der angegebenen Hilfsmittel angefertigt habe. Die aus fremden Quellen direkt oder indirekt übernommenen Gedanken sind als solche kenntlich gemacht. Die Arbeit wurde bisher in gleicher oder ähnlicher Form keiner anderen Prüfungsbehörde vorgelegt.

Neubrandenburg, 30.08.3023

Gabriel Schmidt