

Entwicklung maschineller Lernmodelle für die automatisierte  
Verhaltens Erfassung und die Untersuchung einer beginnenden  
Hitzebelastung bei Fleckviehkühen mit einem Monitoringsystem

von Lara Schmeling

Inaugural-Dissertation zur Erlangung der Doktorwürde  
der Tierärztlichen Fakultät der Ludwig-Maximilians-Universität  
München

Entwicklung maschineller Lernmodelle für die automatisierte  
Verhaltens Erfassung und die Untersuchung einer beginnenden  
Hitzebelastung bei Fleckviehkühen mit einem Monitoringsystem

von Lara Schmeling  
aus Ratingen

München 2022



Aus dem Veterinärwissenschaftlichen Department  
der Tierärztlichen Fakultät  
der Ludwig-Maximilians-Universität München

Lehrstuhl für Tierschutz, Verhaltenskunde, Tierhygiene und Tierhaltung

Arbeit angefertigt unter der Leitung von:  
PD Dr. Elke Rauch

Angefertigt an der Bayerischen Landesanstalt für Landwirtschaft  
am Institut für Landtechnik und Tierhaltung  
Mentor: Stefan Thurner



Gedruckt mit Genehmigung der Tierärztlichen Fakultät  
der Ludwig-Maximilians-Universität München

Dekan: Univ.-Prof. Dr. Reinhard K. Straubinger, Ph.D.

Berichterstatter: Priv.-Doz. Dr. Elke Rauch

Korreferent: Priv.-Doz. Dr. Ivica Međugorac

Tag der Promotion: 12.02.2022



*Meiner Familie*

„Nicht weil es schwer ist, wagen wir es nicht,  
sondern weil wir es nicht wagen, ist es schwer.“

Seneca



## INHALTSVERZEICHNIS

I.	<b>EINLEITUNG</b> .....	1
II.	<b>VORABVERÖFFENTLICHUNGEN</b> .....	3
III.	<b>ERWEITERTE LITERATURÜBERSICHT</b> .....	4
1.	<b>Verhalten von Milchkühen</b> .....	4
1.1.	Normalverhalten in Abhängigkeit vom Haltungssystem .....	4
1.1.1.	Ruheverhalten.....	4
1.1.2.	Stehen .....	7
1.1.3.	Ablegen und Aufstehen.....	8
1.1.4.	Gehen .....	10
1.1.5.	Futteraufnahme.....	11
1.1.6.	Wiederkauen.....	13
1.1.7.	Wasseraufnahme .....	15
1.2.	Variationen des Normalverhaltens durch Haltungs- und Managementparameter .....	15
1.3.	Tierbezogene Variationen des Normalverhalten.....	17
1.3.1.	Rasse.....	17
1.3.2.	Alter und Parität .....	18
1.3.3.	Größe und Gewicht .....	19
1.3.4.	Laktationsstufe und Milchleistung.....	20
1.3.5.	Rang in der Herde .....	21
1.4.	Abweichungen vom Normalverhalten .....	22
1.4.1.	Brunst .....	22
1.4.2.	Abkalbung .....	23
1.4.3.	Erkrankungen .....	25
1.4.3.1.	Peripartale Gesundheitsstörungen.....	25
1.4.3.2.	Lahmheit.....	28
1.4.3.3.	Mastitis .....	30
1.4.4.	Witterung.....	31
2.	<b>Monitoringsysteme</b> .....	33
2.1.	Sensoren .....	35
2.2.	Anbringung von Sensoren am Tier .....	39
2.3.	Verhaltensdatenerfassung für das Training und die Validierung von Monitoringsystemen.....	40
2.4.	Maschinelle Lernmodelle.....	43
2.4.1.	Algorithmen .....	44
2.4.2.	Datenerfassungsfrequenz und Fenstergröße.....	51
2.4.3.	Features .....	55
2.5.	Performance von Monitoringsystemen in der Verhaltenserfassung .....	58
2.5.1.	Liegen.....	59
2.5.2.	Stehen .....	62
2.5.3.	Aufstehen und Ablegen.....	63
2.5.4.	Gehen .....	64

2.5.5.	Fressen.....	65
2.5.6.	Grasen.....	67
2.5.7.	Wiederkauen.....	69
2.5.8.	Trinken .....	71
2.6.	Performance von Monitoringsystemen in der Erfassung von Ursachen für Verhaltensänderungen bei Milchkühen.....	72
2.6.1.	Brunst .....	72
2.6.2.	Abkalbung .....	74
2.6.3.	Erkrankungen .....	75
<b>3.</b>	<b>Hitzebelastung .....</b>	<b>79</b>
3.1.	Mechanismen der Thermoregulation bei Milchkühen .....	79
3.1.1.	Körpertemperatur .....	79
3.1.2.	Wärmeproduktion.....	80
3.1.3.	Wärmeabgabe.....	81
3.2.	Messung einer Hitzebelastung über den Anstieg von Kortisolwerten .....	83
3.3.	Folgen einer Hitzebelastung.....	86
3.4.	Indices zur Definition einer Hitzebelastung.....	87
3.4.1.	Indices .....	87
3.4.2.	Schwellenwerte .....	92
3.5.	Tierbezogene Einflussfaktoren auf die Entstehung einer Hitzebelastung.....	95
3.6.	Verhaltensänderungen unter Hitzebelastung.....	98
3.7.	Automatisierte Erfassung einer Hitzebelastung .....	100
3.8.	Maßnahmen zur Reduktion einer Hitzebelastung .....	102
3.8.1.	Gegenmaßnahmen im Stall .....	102
3.8.2.	Gegenmaßnahmen auf der Weide .....	104
3.8.3.	Haltungsübergreifende Gegenmaßnahmen .....	105
<b>IV.</b>	<b>TIERE, MATERIAL UND METHODEN .....</b>	<b>107</b>
<b>1.</b>	<b>Entwicklung maschineller Lernmodelle zur Verhaltenserfassung bei Milchkühen auf der Weide .....</b>	<b>108</b>
1.1.	Übersicht über die Datenerfassung .....	108
1.2.	Entwicklung, Validierung und Anwendung der maschinellen Lernmodelle .....	112
1.3.	Erfassung von Einflussfaktoren auf das Tierverhalten .....	112
1.3.1.	Witterung.....	113
1.3.2.	Body Condition Score .....	113
1.3.3.	Milchleistung und Milch Inhaltsstoffe .....	113
1.4.	Auswertung und Statistik .....	114
<b>2.</b>	<b>Untersuchung einer beginnenden Hitzebelastung bei Milchkühen auf der Weide .....</b>	<b>115</b>
2.1.	Übersicht über die Datenerfassung .....	115
<b>V.</b>	<b>ERSTE PUBLIKATION .....</b>	<b>117</b>

---

VI.	<b>ZWEITE PUBLIKATION .....</b>	<b>143</b>
VII.	<b>ERWEITERTE ERGEBNISSE.....</b>	<b>160</b>
1.	<b>Performance der maschinellen Lernmodelle.....</b>	<b>160</b>
2.	<b>Verhalten der Tiere an Tagen der Datenerhebung für die Modellentwicklung.....</b>	<b>161</b>
3.	<b>Ergebnisse der Einflussfaktoren und Zusammenhang mit dem Tierverhalten .....</b>	<b>165</b>
VIII.	<b>ERWEITERTE DISKUSSION.....</b>	<b>167</b>
1.	<b>Performance der maschinellen Lernmodelle.....</b>	<b>167</b>
2.	<b>Verhalten der Tiere an Tagen der Datenerhebung für die Modellentwicklung.....</b>	<b>169</b>
3.	<b>Einsatz des Monitoringsystems für die Untersuchung einer beginnenden Hitzebelastung bei Fleckviehkühen .....</b>	<b>171</b>
IX.	<b>FAZIT.....</b>	<b>173</b>
X.	<b>ZUSAMMENFASSUNG .....</b>	<b>174</b>
XI.	<b>SUMMARY.....</b>	<b>177</b>
XII.	<b>LITERATURVERZEICHNIS .....</b>	<b>180</b>
XIII.	<b>VERZEICHNIS DER ABBILDUNGEN UND TABELLEN .....</b>	<b>215</b>
1.	<b>Abbildungsverzeichnis .....</b>	<b>215</b>
1.1.	Abbildungen aus den Kapiteln III, IV und VII .....	215
1.2.	Abbildungen in der ersten Publikation.....	216
1.3.	Abbildungen in der zweiten Publikation.....	217
2.	<b>Tabellenverzeichnis.....</b>	<b>218</b>
2.1.	Tabellen aus den Kapiteln III, IV und VII .....	218
2.2.	Tabellen in der ersten Publikation.....	221
2.3.	Tabellen in der zweiten Publikation.....	222
XIV.	<b>DANKSAGUNG .....</b>	<b>223</b>



**ABKÜRZUNGSVERZEICHNIS**

ACTH	Adrenocorticotropic hormone	Pe-K	Korrelationskoeffizient nach Pearson
AMS	Automatisches Melksystem	PLF	Precision Livestock Farming
AUC	Area under the curve	PPV	Positiver Vorhersagewert
BCS	Body condition score	R <sup>2</sup>	Bestimmtheitsmaß
BGHI	Black-globe Humidity Index	REM	Rapid eye movement
BGT	Black-globe Temperature	RF	Random Forest
CCC	Korrelationskoeffizient nach Lin	RFID	Radio-Frequency Identification
CCI	Comprehensive Climate	RME	Relative Measurement Error
Co-K	Cohens Kappa	ROC	Receiver operating characteristics
CRH	corticotropin-releasing hormone	Se	Sensitivität
DA	Diskriminanzanalyse	Sl	Slope
DBT	Dry-bulb Temperature	Sp	Spezifität
DHLI	Dairy Heat Load Index	Sp-K	Korrelationskoeffizient nach Spearman
DI	Discomfort Index	SVM	Support Vector Machine
DIM	Days in milk	THI	Temperature Humidity Index
DT	Decision Tree	THIadj	Adjusted Temperature Humidity Index
ETIC	Equivalent Temperature Index for Dairy Cows	TM	Trockenmasse
FN	False negative	TN	True negative
FP	False positive	TP	True positive
FS	F-Score	WBT	Wet-bulb Temperature
Ge	Genauigkeit		
GPS	Global Positioning System		
HF	Holstein-Friesian		
In	Intercept		
KM	K-means		
KNN	K-nearest Neighbour		
LiR	Lineare Regression		
LoR	Logistische Regression		
NB	Naïve Bayes		
NEFA	Non-esterified fatty acid		
NN	Neuronale Netze		
NPV	Negativer Vorhersagewert		
NREM	Non-rapid eye movement		



## I. EINLEITUNG

Die Nachfrage nach mehr Tierwohl bei der Haltung von Nutztieren steigt seitens der Verbraucher (ALONSO et al. 2020). Tierwohl wird unter anderem als Freiheit von Erkrankungen, Schmerzen und Belastungen definiert (WELFARE QUALITY® CONSORTIUM 2009). Insbesondere die Belastung durch die Witterung ist im Hinblick auf die Klimaerwärmung und die damit einhergehende Zunahme von Tagen mit Temperaturen oberhalb der Temperaturkomfortzone von Milchkühen hoch relevant (HAMMAMI et al. 2013; CARVALHO et al. 2021). Um Belastungssituationen zu erkennen bzw. die Tiergesundheit und damit das Tierwohl zu überprüfen, muss der Landwirt seine Tiere visuell kontrollieren. Steigende Herdengrößen reduzieren die für die Kontrolle der Einzeltiere verfügbare Zeit (KEYSERLINGK et al. 2009; BERCKMANS 2014). Werden die Tiere auf der Weide gehalten, wird die Tierkontrolle zusätzlich durch Witterungseinflüsse und große Distanzen erschwert. Automatisierte Tiermonitoringsysteme können den Landwirt bei der Tierkontrolle unterstützen (MAROTO MOLINA et al. 2020). Die Systeme enthalten Sensoren, die je nach Anbringungsort am Tier die Bewegung des Kopfes und Halses, des Kiefers, der Gliedmaßen, der Ohren, des Schwanzes oder des Pansens erfassen (ALSAAOD et al. 2015; BORCHERS et al. 2016; HAMILTON et al. 2019; WERNER et al. 2019; STEINMETZ et al. 2020). Auf die erfassten Daten werden maschinelle Lernmodelle angewendet, die in den Sensordaten Muster erkennen und diese verschiedenen Verhaltensweisen zuordnen (BURKOV 2019). Über die kontinuierliche Erfassung der Verhaltensdauern und -häufigkeiten mit einem Monitoringsystem können Änderungen dieser Parameter automatisiert registriert werden. Bei Milchkühen treten Änderungen im Verhalten im Zusammenhang mit der Brunst, der Abkalbung, bei Erkrankungen und unter Witterungsbelastung auf (KING et al. 2017a; HEINICKE et al. 2018; ZEBARI et al. 2018; GIARETTA et al. 2021). Diese Konditionen können mit einem Monitoringsystem automatisiert, zuverlässig, frühzeitig und auf Einzeltierebene erkannt werden (STANGAFERRO et al. 2016a, 2016b, 2016c; BORCHERS et al. 2017; MINEGISHI et al. 2019). Die auf dem Markt für Milchkühe erhältlichen Monitoringssysteme wurden entweder für den Stall oder für die Weide entwickelt und erkennen im jeweils anderen Haltungssystem das Verhalten häufig nicht zuverlässig (ELISCHER et al. 2013; AMBRIZ-VILCHIS et al. 2015; STYGAR et al. 2021). Daraus, dass in einigen Regionen Europas, so auch in

Bayern, die klimatischen Bedingungen in Kombination mit mangelnder Fläche die ganzjährige Weidehaltung verhindern (VAN DEN POL-VAN DASSELAAR et al. 2020), ergibt sich der Bedarf nach einem Monitoringsystem, das das Verhalten der Tiere sowohl auf der Weide als auch im Stall zuverlässig erkennt.

Ziel dieser Untersuchung, die im Rahmen des am Institut für Landtechnik und Tierhaltung der Bayerischen Landesanstalt für Landwirtschaft in Zusammenarbeit mit dem Lehrstuhl für Tierschutz, Verhaltenskunde, Tierhygiene und Tierhaltung der tierärztlichen Fakultät der LMU München bearbeiteten Projekts „FutureIOT-Rindertracking“ durchgeführt wurde, war die Entwicklung und Validierung maschineller Lernmodelle für die automatisierte Verhaltenserkennung bei Milchkühen im Stall und auf der Weide mit einem Monitoringsystem. Die entwickelten Modelle sollten im Anschluss dafür genutzt werden, die mit einer beginnenden Hitzebelastung verbundenen Verhaltensänderungen bei Milchkühen auf der Weide zu untersuchen.

## II. VORABVERÖFFENTLICHUNGEN

Vorabveröffentlichung von Teilstudienergebnissen im Rahmen von Tagungen:

- Schmeling L., Thurner S., Maxa J., Rauch E. Recording the behaviour of grazing dairy cows to develop a sensor based health monitoring system. 9<sup>th</sup> European Conference on Precision Livestock Farming. 26.-29.08.2019, Cork, Ireland. 707-713. ISBN 978-1-84170-654-2
- Schmeling L., Thurner S., Maxa J., Rauch E. Verhaltensbeobachtung bei Milchkühen zur Entwicklung eines sensorbasierten Systems zur Gesundheitsüberwachung. 14. Tagung Bau, Technik und Umwelt in der landwirtschaftlichen Nutztierhaltung. 24.-26.09.2019, Bonn. 160-165. ISBN 978-3-945088-69-2
- Schmeling L., Rauch E., Thurner S. Entwicklung eines Monitoringsystems zur Ermittlung einer beginnenden Hitzebelastung bei Milchkühen mit Weidehaltung. Agrarwissenschaftliches Symposium des Hans Eisenmann-Forums 2020. 29.10.2020, Freising. 45-47.
- Schmeling L., Rauch E., Erhard M., Thurner S. Ermittlung der Einflussfaktoren auf das Liegeverhalten von Milchkühen mit Weidehaltung. 52. Internationale Tagung Angewandte Ethologie, Aktuelle Arbeiten zur artgemäßen Tierhaltung 2020. 26.-27.11.2020, online. ISBN 978-3-945088-78-4
- Schmeling L., Thurner S., Nicklas D., Erhard M., Rauch E. Automated detection of grazing behaviour with a collar-based monitoring system. 21<sup>st</sup> EGF Symposium 2021. Sensing – New Insights into Grassland Science and Practice. 17.-19.05.2021, online. 193-195. ISBN 978-3-00-068789-1
- Schmeling L., Elmamooz G., Nicklas D., Rauch E., Thurner S. Evaluation of a sensor-based system for monitoring rumination in dairy cows with access to pasture. EurAgEng 2021. New Challenges for Agricultural Engineering towards a Digital World. 05.-08.07.2021, online. 154-155.

### III. ERWEITERTE LITERATURÜBERSICHT

#### 1. Verhalten von Milchkühen

##### 1.1. Normalverhalten in Abhängigkeit vom Haltungssystem

Das folgende Kapitel beschreibt das Normalverhalten von Milchkühen mit den verschiedenen Hauptverhaltensweisen, ihrer Bedeutung, ihres Zeitbudgets und ihrer Verteilung auf die verschiedenen Tageszeiten je nach Haltungssystem. Die abgedeckten Haltungssysteme sind die Anbindehaltung, der Laufstall und die Weidehaltung. Das Normalverhalten von Milchkühen teilt sich in unterschiedliche Funktionskreise auf. Die wichtigsten Funktionskreise umfassen das Ruheverhalten, die Futtaufnahme, das Wiederkauen, die Fortbewegung, sowie die Wasseraufnahme und den Kot- und Harnabsatz. Die verschiedenen Verhaltensweisen nehmen unterschiedliche Anteile eines Tages ein und unterscheiden sich darin, zu welchen Tageszeiten sie gezeigt werden. Die Verhaltensweisen sind auf Perioden aufgeteilt, die sich in ihrer Frequenz und Dauer unterscheiden können.

##### 1.1.1. Ruheverhalten

Der größte Anteil des Ruheverhaltens entfällt bei Milchkühen auf die Verhaltensweise **Liegen**. Im Liegen ist der Blutfluss zum Euter hin erhöht (METCALF et al. 1992; RULQUIN und CAUDAL 1992) und ein Entzug von Liegemöglichkeit führt zum Abfall der Wachstumshormonproduktion (MUNKSGAARD und LØVENDAHL 1993), welche entscheidend für die Milchproduktion ist (DAVIS et al. 1988). BACH et al. (2008) fanden einen Zusammenhang zwischen der Anzahl an verfügbaren Liegeplätzen und der Herdenleistung laktierender Milchkühe. Auch für die Klauengesundheit spielt das Liegeverhalten eine Rolle. So treten bei einer Reduktion der Liegezeit vermehrt Klauenläsionen auf (LEONARD et al. 1996). In der Trächtigkeit ist im Liegen der Blutfluss zum graviden Uterus erhöht (NISHIDA et al. 2004), was eine Versorgung des Fötus mit Sauerstoff und Nährstoffen sicherstellt.

Die mittlere Liegedauer gesunder Milchkühe pro Tag unterscheidet sich je nach Haltungsform. Während die Tiere auf der Weide im Mittel 9,5 bis 10,3 h mit Liegen

verbringen (BEGGS et al. 2018; SEPÚLVEDA-VARAS et al. 2018), sind es im Laufstall 10,5 bis 11,0 h (ITO et al. 2009; BEWLEY et al. 2010; TOLKAMP et al. 2010) und in Anbindehaltung 12,5 bis 13,5 h (CHARLTON et al. 2016; FUKASAWA et al. 2019). Auch im direkten Vergleich liegt in den meisten Untersuchungen die Liegedauer im Laufstall über der auf der Weide und die Liegedauer in Anbindehaltung über der in den beiden anderen Haltungssystemen (KROHN und MUNKSGAARD 1993; HERNANDEZ-MENDO et al. 2007; LEGRAND et al. 2009; DOHME-MEIER et al. 2014; BLACK und KRAWCZEL 2016). In der Untersuchung von OLMOS et al. (2009) hingegen lagen die Tiere pro Tag auf der Weide länger als im Stall. Insgesamt lässt sich eine starke Varianz in der täglichen Liegezeit zwischen den Einzeltieren beobachten. In einer Studie von DEMING et al. (2013) im Laufstall variierten die Liegezeiten der einzelnen Tiere pro Tag zwischen 5,1 h und 16,7 h. Für die Anbindehaltung beobachteten CHARLTON et al. (2016) eine Spannweite von 6,3 bis 17,9 h pro Tier und Tag.

Das Liegeverhalten teilt sich im Mittel auf 7 bis 12 Liegeperioden pro Tag mit einer durchschnittlichen Dauer von 54 bis 88 min auf (ITO et al. 2009; BEWLEY et al. 2010; TOLKAMP et al. 2010; SEPÚLVEDA-VARAS et al. 2018). Der Unterschied zwischen Stall und Weide ist hier weniger ausgeprägt bzw. unterscheiden sich die Ergebnisse zwischen den verschiedenen Studien. BLACK und KRAWCZEL (2016) beobachteten trotz kürzerer Gesamtliegezeit auf der Weide weder einen Unterschied in der Dauer noch in der Anzahl der Liegeperioden zwischen Laufstall und Weide. In der Untersuchung von LEGRAND et al. (2009) unterschied sich die Zahl der Liegeperioden nicht, die Dauer lag im Stall aber über der auf der Weide. OLMOS et al. (2009) hingegen erfassten auf der Weide eine längere mittlere Liegeperiodendauer. Die längere Gesamtliegezeit im Stall in dieser Untersuchung begründet sich in der höheren Zahl der Liegeperioden im Stall.

Auch bei der Zahl und Dauer einzelner Liegeperioden gibt es Variationen zwischen den Einzeltieren. CHARLTON et al. (2016) beobachteten in Anbindehaltung eine Spannweite von 4 bis 24 Liegeperioden pro Tier und Tag mit einer Variation der mittleren Dauer von 28 bis 150 min. In der Studie von DEMING et al. (2013) im Laufstall variierte die Liegeperiodenzahl zwischen 2 und 15 und die mittlere Liegeperiodendauer pro Tier und Tag zwischen 35 und 223 min. Die minimale Liegeperiodendauer in einer Studie von BEWLEY et al. (2010) betrug 1 min, in der Untersuchung von KOK et al. (2015) dauerte die kürzeste Liegeperiode 4 s. Die

maximale Liegeperiodendauer wird mit 362 min (BEWLEY et al. 2010) bzw. 260 min (KOK et al. 2015) und 96 min (TOLKAMP et al. 2010) angegeben. Längere Liegeperioden sind häufig von kurzen Stehperioden unterbrochen. Meist legen sich die Tiere nach diesen kurzen Unterbrechungen auf die Körperseite, auf der sie vorher nicht gelegen haben (TUCKER et al. 2009). Um zwischen kurzen Pausen zwischen zwei Liegeevents und tatsächlichen Unterbrechungen zwischen zwei Liegeperioden zu unterscheiden, ermittelten TOLKAMP et al. (2010) ein Liegeperiodenkriterium von 4 min, d. h. erst ab einer Nicht-Liegeperiodendauer von über 4 min zwischen zwei Liegeevents wird von einer tatsächlichen Unterbrechung ausgegangen. In der Studie von ALSAOD et al. (2015) trennten bereits 50 s zwei Liegeperioden voneinander. HENRIKSEN and MUNKSGAARD (2019) rechneten Liegeperioden mit einer Dauer von unter 3 min zur vorherigen Liegeperiode dazu.

Das Liegeverhalten wird in Milchkuhherden mit einer hohen Synchronität gezeigt (FLURY und GYGAX 2016). Im Tagesverlauf liegen die Tiere nachts mehr als tagsüber (WINCKLER et al. 2015; HERBUT und ANGRECKA 2018), sodass hier die Synchronität am höchsten ist (FLURY und GYGAX 2016). Die Synchronität des Liegeverhaltens ist auf der Weide höher als im Stall (FLURY und GYGAX 2016) und im Laufstall höher als in Anbindehaltung (KROHN et al. 1992).

Ein Teil des Liegeverhaltens wird bei Kühen mit **Schlafen** verbracht. Schlaf wird unterteilt in rapid eye movement (REM)- und non-rapid eye movement (NREM)-Schlaf. Während REM-Schlaf ausschließlich im Liegen mit entspanntem Kopf gezeigt wird (TERNMAN et al. 2014), kann NREM-Schlaf auch im Stehen stattfinden (RUCKEBUSCH 1974). Die Dauer des REM-Schlafs pro Tag wird mit 10 bis 50 min angegeben, die des NREM-Schlafs mit 54 bis 192 min (RUCKEBUSCH 1972; TERNMAN et al. 2018; KULL et al. 2019; TERNMAN et al. 2019). Beide Schlafstadien werden vermehrt nachts gezeigt (RUCKEBUSCH 1972; TERNMAN et al. 2018).

Neben Schlafen zeigen Kühe **Dösen/Schlummern** (engl.: drowsing). RUCKEBUSCH (1972) beschreibt dies als ein Zwischenstadium zwischen Schlaf und Wachzustand. Diese Verhaltensweisen nimmt 7 bis 8 h pro Tag ein und wird in der Regel im Liegen gezeigt (RUCKEBUSCH 1972; KULL et al. 2019).

### 1.1.2. Stehen

Auf der Weide verbringen Milchkühe im Mittel 2,5 bis 6,8 h pro Tag mit Stehen (PHILLIPS und LEAVER 1986; TUCKER et al. 2007a). Während des Stehens können parallel verschiedene Verhaltensweisen gezeigt werden. Dazu gehört Wiederkauen, Trinken, Sozial-, Komfort- und Erkundungsverhalten. Auch Grasens findet zum Teil im Stehen statt. Da im Laufstall die Futteraufnahme ausschließlich im Stehen stattfindet, liegt die Stehzeit hier mit durchschnittlich 12 bis 14 h (HUZZEY et al. 2005; BEWLEY et al. 2010; JAWOR et al. 2012; BEER et al. 2016) pro Tag deutlich höher als auf der Weide (DOHME-MEIER et al. 2014). BEWLEY et al. (2010) geben für den Laufstall eine Spannweite von 5,7 bis 19,1 h pro Tier für die tägliche Stehzeit an. Im Laufstall unterscheidet man vor allem zwischen den Funktionsbereichen, in welchen das Stehen gezeigt wird, z. B. am Futtertisch, in den Liegeboxen oder auf den Laufwegen. Die Stehzeit in den Liegeboxen beläuft sich dabei im Mittel auf 1,5 bis 4,3 h, die Stehzeit im Laufgang auf 2,6 bis 3,5 h (COOK et al. 2007; WINCKLER et al. 2015). Auch im Stall kann im Stehen Wiederkauen, Trinken, Sozial-, Komfort- und Erkundungsverhalten gezeigt werden. Im Anbindestall verbringen Milchkühe insgesamt im Mittel 11,0 bis 12,9 h pro Tag mit Stehen, wovon 6,8 bis 8,5 h mit Fressen verbracht werden (HALEY et al. 2001).

Die Häufigkeit, mit der Stehverhalten am Tag gezeigt wird, lässt sich in Stehperioden ausdrücken. Dabei hängt die Zahl der Stehperioden stark von den festgelegten Kriterien ab, die eine Stehperiode definieren. HUZZEY et al. (2005) und JAWOR et al. (2012) zählten im Schnitt 12 bis 13 Stehperioden pro Tier und Tag, wobei sie eine Stehperiode als Zeit zwischen zwei Liegeperioden definierten ohne Gehsequenzen zu berücksichtigen. BEER et al. (2016) hingegen legten eine Mindestdauer von 50 bzw. 4 s zur Abgrenzung einer Stehperiode zum Liegen bzw. Gehen fest und ermittelten damit eine mittlere Zahl von 120 Stehperioden pro Tier und Tag. In Anbindehaltung können die Tiere kein Gehverhalten zeigen, weshalb eine Stehperiode hier tatsächlich die Zeit zwischen zwei Liegeperioden einnimmt. HALEY et al. (2001) zählten pro Tier und Tag im Durchschnitt 11 bis 15 Stehperioden.

Entsprechend der unterschiedlichen Definitionen unterscheidet sich mit einer Spannweite von 5 bis 80 min (HALEY et al. 2001; HUZZEY et al. 2005; JAWOR et al. 2012; BEER et al. 2016) auch die mittlere Stehperiodendauer stark. TOLKAMP et al.

(2010) beobachteten nur wenige Stehperioden mit einer Dauer von weniger als 1 min, wobei sich die Verteilung kurzer Stehperioden nicht von der langer Stehperioden unterschied.

### 1.1.3. Ablegen und Aufstehen

Das Ablegen ist der Übergang von einer stehenden Position in eine liegende. Vor dem Beginn des eigentlichen Ablegevorgangs suchen Milchkühe mit gesenktem Kopf nach einem Liegeplatz und inspizieren diesen dann mit pendelnden Kopfbewegungen (KROHN und MUNKSGAARD 1993). Der Ablegevorgang beginnt dann mit dem Beugen der Karpalgelenke und dem Niederknien auf den Untergrund. Im Anschluss senken die Tiere ihr Hinterteil ab und kommen vollständig zum Liegen (KROHN und MUNKSGAARD 1993; WECHSLER et al. 2000; DIRKSEN et al. 2020).

KROHN und MUNKSGAARD (1993) verglichen das Ablegeverhalten von Milchkühen in Anbindehaltung, im Laufstall und auf der Weide miteinander. Die Zeit für die Liegeplatzsuche entfällt für Tiere in Anbindehaltung im Gegensatz zu Tieren im Laufstall oder auf der Weide. Zwischen Laufstall und Weide unterschied sie sich nur geringfügig (15 vs. 19 s,  $p > 0,05$ ). Die Inspektion des Liegeplatzes dauerte in Anbindehaltung im Mittel länger als im Laufstall und dort wiederum länger als auf der Weide (42-51 vs. 21 vs. 8 s,  $p < 0,05$ ). Somit lag, trotz ähnlicher durchschnittlicher Dauer des eigentlichen Ablegevorgangs (8-14 vs. 8 vs. 7 s,  $p > 0,05$ ), die mittlere Gesamtdauer des Ablegens in Anbindehaltung signifikant höher als im Laufstall und dort wiederum höher als auf der Weide (KROHN und MUNKSGAARD 1993). WECHSLER et al. (2000) untersuchten das Ablegeverhalten im Laufstall auf unterschiedlichen Untergründen und auf der Weide, wo sie keine Unterschiede in der mittlere Ablegedauer feststellten (5 vs. 5 s,  $p > 0,5$ ). ZAMBELIS et al. (2019a) untersuchten das Ablegeverhalten in Anbindehaltung und beobachteten mittlere Dauern für die Liegeplatzinspektion von 26 bis 29 s und durchschnittliche Dauern für den eigentlichen Ablegevorgang von 7 bis 9 s. Den kürzesten Ablegevorgang beobachteten WECHSLER et al. (2000) mit 2 s, den längsten zeigte ein Tier in der Untersuchung von ZAMBELIS et al. (2019a) mit 24 s.

Die Charakteristika für abnormales Ablegeverhalten inklusive der Häufigkeit, mit der sie in den Untersuchungen von ZAMBELIS et al. (2019a) in Anbindehaltung und DIRKSEN et al. (2020) im Laufstall aufgetreten sind, sind in Tabelle 1 aufgeführt.

Auch hundeartiges Ablegen, bei dem statt den Karpalgelenken zuerst das Hinterteil abgesenkt wird, zählt zum abnormalen Ablegeverhalten, wurde aber in beiden Untersuchungen nicht beobachtet (ZAMBELIS et al. 2019a; DIRKSEN et al. 2020). Im direkten Vergleich wurden in Anbindehaltung mehr Ablegevorgänge unterbrochen als im Laufstall oder auf der Weide (KROHN und MUNKSGAARD 1993). In der Studie von WECHSLER et al. (2000) wurde bei 11 bis 35 % der Ablegevorgänge Schwierigkeiten beobachtet, einen Unterschied zwischen Laufstall und Weide gab es nicht.

**Tabelle 1: Verschiedene Abweichungen im Ablegeverhalten von Milchkühen mit der Häufigkeit ihres Auftretens (%) in den Studien von ZAMBELIS et al. (2019a) und DIRKSEN et al. (2020)**

Art der Abweichung	Häufigkeit des Auftretens [%]	
	ZAMBELIS et al. 2019a	DIRKSEN et al. 2020
Abbrechen des Ablegevorgangs	-	0,1
Wiederholte Pendelbewegungen mit dem Kopf vor dem Ablegen	-	39
Scharren mit den Vorderklauen vor dem Ablegen	-	6
Wiederholte Gewichtsverlagerung zwischen den Vordergliedmaßen vor dem Beugen der Karpalgelenke	-	22
Wiederholte Gewichtsverlagerung zwischen den Hintergliedmaßen beim Knien	13-21	26
Berühren der Stalleinrichtung beim Ablegevorgang	71-72	35
Ausrutschen beim Ablegevorgang	13	-

Das Aufstehen ist der Übergang von einer liegenden Position in eine stehende. Die Tiere bringen ihr Hinterteil durch das Strecken ihrer Hintergliedmaßen nach oben. Mit einem Kopfschwung wird der vordere Körper angehoben und die Füße werden aufgestellt (WECHSLER et al. 2000; DIRKSEN et al. 2020).

WECHSLER et al. (2000) verglichen das Aufstehverhalten von Milchkühen im Laufstall und auf der Weide. Die mittlere Dauer für den Aufstehvorgang betrug sowohl im Stall als auch auf der Weide 7 bis 8 s. ZAMBELIS et al. (2019a) beobachteten in Anbindehaltung eine mittlere Aufstehdauer von 25 bis 35 s. Der kürzeste Aufstehvorgang wurde mit 2 s von WECHSLER et al. (2000) beobachtet. ZAMBELIS et al. (2019a) erfassten die längste Aufstehdauer mit 190 s.

Die Charakteristika für abnormales Aufstehverhalten inklusive der Häufigkeit, mit der sie in den Untersuchungen von ZAMBELIS et al. (2019a) in Anbindehaltung und DIRKSEN et al. (2020) im Laufstall aufgetreten sind, sind in Tabelle 2 aufgeführt.

**Tabelle 2: Verschiedene Abweichungen im Aufstehverhalten von Milchkühen mit der Häufigkeit ihres Auftretens (%) in den Studien von ZAMBELIS et al. (2019a) und DIRKSEN et al. (2020)**

Art der Abweichung	Häufigkeit des Auftretens [%]	
	ZAMBELIS et al. 2019a	DIRKSEN et al. 2020
Abbrechen des Aufstehvorgangs	-	0,2
Wiederholter Aufstehversuch	13-17	-
Pferdeartiges Aufstehen <sup>1</sup>	0	0,7
Rückwärts Rutschen des Körpers vor oder während des Aufstehvorgangs	12-20	33
Berühren der Stalleinrichtung beim Aufstehvorgang	3	29
Zögern vor oder während der Kopfschwungbewegung	13-20	19
Seitlicher Kopfschwung	-	43

<sup>1</sup> Beim pferdeartigen Aufstehen werden die Vordergliedmaßen vollständig gestreckt, bevor das Hinterteil angehoben wird.

#### 1.1.4. Gehen

Im Laufstall verbringen Milchkühe im Mittel 0,5 bis 0,7 h pro Tag mit Gehen (MATTACHINI et al. 2013; BEER et al. 2016). Auf der Weide entfällt ein Großteil der Fortbewegung auf das Grasens, während dem die Tiere mit gesenktem oder gehobenem Kopf in kurzen Sequenzen vorwärts gehen. Reines Gehverhalten wird hier vor allem auf dem Weg vom und zum Melken gezeigt (PHILLIPS und LEAVER

1986), wobei die Entfernung des Melkstands eine entscheidende Rolle spielt (BEGGS et al. 2018). PHILLIPS und LEAVER (1986) geben die reine Gehzeit auf der Weide mit 0,6 bis 1,3 h an. Die Schrittzahl unterscheidet sich zwischen Weide und Stall deutlich (BLACK und KRAWCZEL 2016; ATKINS et al. 2020), da auf der Weide die unterm Grasem gemachten Schritte mitgezählt werden. Während für den Stall Schrittzahlen von 947 bis 7535 angegeben werden (BEWLEY et al. 2010; ATKINS et al. 2020), ist die Spannweite auf der Weide mit 1705 bis 15075 Schritten pro Tag deutlich größer. Die zurückgelegte Strecke pro Schritt beträgt zwischen 1,3 und 1,5 m (TELEZHENKO 2009; BEER et al. 2016) und unterscheidet sich zwischen Stall und Weide nicht (ALSAAOD et al. 2017). Milchkühe bewegen sich mit einer Geschwindigkeit von 0,72 bis 1,4 m/s vorwärts (TELEZHENKO 2009; BEER et al. 2016), wobei die Geschwindigkeit auf der Weide über der im Stall liegt (ALSAAOD et al. 2017).

#### 1.1.5. Futteraufnahme

Im Stall erfolgt die Futteraufnahme über das **Fressen** einer vorgelegten Futtermittelration. Im Mittel verbringen Milchkühe 4,1 bis 5,3 h am Tag mit Fressen (DADO und ALLEN 1993, 1994; VOELKER und ALLEN 2003; SCHIRMANN et al. 2011; MIGUEL-PACHECO et al. 2014). Die Futteraufnahme verteilt sich auf 6 bis 11 Fressperioden mit einer durchschnittlichen Dauer von 27 bis 40 min (DADO und ALLEN 1994; TOLKAMP et al. 2002; VOELKER und ALLEN 2003; MIGUEL-PACHECO et al. 2014). Eine Fressperiode, die auch als Mahlzeit (engl.: meal) bezeichnet wird, besteht aus kleineren Fressevents, die geclustert auftreten (TOLKAMP et al. 1998). Zwei Fressperioden werden von einer Phase ohne Fressen unterbrochen, die es von den kurzen Pausen zwischen zwei Fressevents zu unterscheiden gilt. Hierfür wird die minimale Dauer, ab der man von einer Unterbrechung zwischen zwei Perioden und nicht von einer Pause zwischen zwei Events ausgeht, ermittelt. Die minimale Dauer wird auch als Interperiodenkriterium (engl.: interbout criterion) bezeichnet. TOLKAMP et al. (1998) ermittelten ein Interperiodenkriterium für das Fressverhalten von 23,8 bis 28,0 min. In der Untersuchung von AZIZI et al. (2009) lag das mittlere Interperiodenkriterium bei 28,5 min. SCHIRMANN et al. (2011) ermittelten ein Interperiodenkriterium von 41,8 min, je Tier variierte die Dauer von 26,4 bis 63,7 min. HUZZEY et al. (2005) ermittelten ein mittleres Interperiodenkriterium von 26,4 min und gaben eine tierindividuelle Spannweite von 5,3 bis 105,2 min an. Die

durchschnittliche Unterbrechung zwischen zwei Fressperioden bzw. Mahlzeiten liegt bei 100 bis 106 min (VOELKER und ALLEN 2003).

Während der Futteraufnahme zeigen die Tiere durchschnittlich 62 bis 75 Kauschläge pro Minute (DADO und ALLEN 1994; VOELKER und ALLEN 2003). Damit nehmen sie 63 bis 165 g Trockenmasse (TM) pro Minute auf, was in einer Futteraufnahme von 2,2 bis 3,5 kg je Mahlzeit und einer Gesamttagesaufnahme von 14 bis 25 kg TM resultiert (DADO und ALLEN 1993, 1994; TOLKAMP et al. 2002; VOELKER und ALLEN 2003; SCHIRMANN et al. 2011).

Tagsüber verbringen Milchkühe mehr Zeit mit Fressen als nachts. Die Peaks liegen am Vormittag und am Nachmittag oder Abend (KETELAAR-DE LAUWERE et al. 1999; FLURY und GYGAX 2016; BARKER et al. 2018). Dabei besteht ein enger Zusammenhang der Fresszeiten mit den Fütterungszeiten sowie den Melkzeiten (DEVRIES und KEYSERLINGK 2005; VAL-LAILLET et al. 2008); siehe auch 1.2.

Beim **Grasen**, über das die Futteraufnahme auf der Weide erfolgt, wird das Gras mit der Zunge und den Lippen gepackt und abgebissen (= Grasebiss; engl.: bite). Im Mund wird das Gras dann mit mahlenden Kieferbewegungen gekaut (= Kauschlag; engl: chew) und abgeschluckt. Abbeißen und Kauen können dabei auch überlappen (= Kau-Grasebiss; engl: chew-bite) (GALLI et al. 2018; CHELOTTI et al. 2020). Milchkühe verbringen im Mittel 8,3 bis 11,0 h pro Tag mit Grasen (PHILLIPS und LEAVER 1986; TUCKER et al. 2007a; PÉREZ-RAMÍREZ et al. 2009; PRENDIVILLE et al. 2010; SHEAHAN et al. 2013). Das Graseverhalten verteilt sich auf 6 bis 10 Graseperioden mit einer mittleren Dauer von 72 bis 97 min (PÉREZ-RAMÍREZ et al. 2009; PRENDIVILLE et al. 2010). Zwei Graseperioden werden von einer Phase ohne Grasen unterteilt, deren minimale Dauer man als Interperiodenkriterium (engl.: interbout criterion) bezeichnet. Hierbei werden kurze Sequenzen, in denen die Tiere mit gehobenem oder gesenktem Kopf, kauend oder nicht kauend, vorwärts gehen zum Graseverhalten und nicht als Unterbrechung gezählt. ROOK und HUCKLE (1997) ermittelten ein Interperiodenkriterium von 5 min, während PÉREZ-RAMÍREZ et al. (2009) und WERNER et al. (2018) in Anlehnung an BRUN et al. (1984) 7 min wählten.

Während der Grasaufnahme führen die Tiere im Mittel 51 bis 60 Kieferbewegungen pro Minute aus, von denen 20 bis 31 tatsächliche Grasebisse sind. Mit einem

Grasebiss werden durchschnittlich 0,13 bis 1,1 g Graastrockenmasse aufgenommen, sodass die Aufnahmerate pro Graseminute im Schnitt bei 19 bis 31 g liegt (PÉREZ-RAMÍREZ et al. 2009; PRENDIVILLE et al. 2010; OUDSHOORN et al. 2013; GALLI et al. 2018). Insgesamt nehmen Milchkühe so pro Tag durchschnittlich 14 bis 17 kg TM auf (PÉREZ-RAMÍREZ et al. 2009; PRENDIVILLE et al. 2010).

Im Tagesverlauf wird Gras vor allem tagsüber gezeigt. Die Peaks liegen dabei meist vormittags und nachmittags bzw. am frühen Abend, während mittags und nachts weniger gegrast wird (ROOK und HUCKLE 1997; TUCKER et al. 2007a; PÉREZ-RAMÍREZ et al. 2009). Bei Verkürzung der Tageslänge konzentrieren Milchkühe die Grasezeiten vermehrt auf die Tageslichtstunden (PHILLIPS und LEAVER 1986).

#### **1.1.6. Wiederkauen**

Das Wiederkauen ist ein essenzieller Teil der Futtermittelveerdauung bei Rindern. Die Zerkleinerung durch das wiederholte Kauen vergrößert die Partikeloberfläche, die zur mikrobiellen Zersetzung zur Verfügung steht. Wiederkauen erhöht die Speichelproduktion (CASSIDA und STOKES 1986). Der Speichel dient als Puffer, um das optimale Milieu für die Mikroorganismen im Pansen zu schaffen. Das Wiederkauen ermöglicht den Aufschluss und die Verwertung des rohfaserreichen Futters. Ein positiver Zusammenhang zwischen Wiederkauzeit und Milchleistung (SORIANI et al. 2013; STONE et al. 2017; KAUFMAN et al. 2018) unterstreicht die Relevanz der effizienten Futtermittelveerdauung durch das Wiederkauen.

Milchkühe kauen im Mittel 371 bis 499 min pro Tag wieder (DADO und ALLEN 1994; VOELKER und ALLEN 2003; PRENDIVILLE et al. 2010; GREGORINI et al. 2012; GREGORINI et al. 2013; TERNMAN et al. 2018; WEIGELE et al. 2018). ZEBELI et al. (2006) beobachteten dabei tierindividuelle Unterschiede zwischen 151 und 632 min pro Tag. O'CONNELL et al. (1989) fanden keinen Unterschied in der Wiederkaudauer pro Tag zwischen Weide und Laufstall, DOHME-MEIER et al. (2014) hingegen beobachteten auf der Weide kürzere Wiederkauzeiten als im Stall. Wiederkauen findet vor allem im Liegen, aber auch im Stehen statt. SCHIRMANN et al. (2012) und STONE et al. (2017) stellten einen positiven Zusammenhang zwischen der täglichen Liegedauer und der täglichen Wiederkaudauer fest. Während NIELSEN et al. (2000) und WOBSCHELL (2017) für den Stall einen Anteil des Wiederkauens im Stehen von 40 bis 56 % an der Gesamtwiederkauzeit ermittelten, lag der Anteil

auf der Weide mit 19 % in den Studien von WALKER et al. (2008) und PHILLIPS und LEAVER (1986) deutlich niedriger.

Beim Wiederkauen wird ein Futterbolus durch die Kontraktion des Netzmagens in die Maulhöhle befördert (= regurgitiert). Im Mittel werden 352 bis 594 Boli pro Tag regurgitiert (PRENDIVILLE et al. 2010; GREGORINI et al. 2013; WEIGELE et al. 2018). Diese werden dann für 0,78 bis 1,93 min mit 59 bis 65 Wiederkauschlägen gekaut (VOELKER und ALLEN 2003; PRENDIVILLE et al. 2010; GREGORINI et al. 2013; WEIGELE et al. 2018), eingespeichelt und abgeschluckt. Bis zur Regurgitation des nächsten Bolus vergehen im Mittel 47 bis 50 s (GREGORINI et al. 2012; GREGORINI et al. 2013). Das Wiederkauverhalten tritt in Perioden auf. Zwei Wiederkauperioden werden von einer Phase ohne Wiederkauen unterteilt, deren minimale Dauer man als Interperiodenkriterium (engl.: interbout criterion) bezeichnet. DADO und ALLEN (1993) ermittelten, dass ab einer Pause von 7,5 min eine neue Wiederkauperiode beginnt und der regurgitierte Bolus nicht mehr zur vorherigen Wiederkauperiode gezählt wird. SCHIRMANN et al. (2016) legten fest, dass ab einer Pause von 30 s eine neue Wiederkauperiode beginnt und ELISCHER et al. (2013) gingen bereits ab 10 s ohne Wiederkaubewegungen vom Ende der Wiederkauperiode aus. Im Mittel liegen zwischen zwei Wiederkauperioden 68 bis 71 min (VOELKER und ALLEN 2003). Pro Tag zeigen Milchkühe 13 bis 17 Wiederkauperioden mit einer mittleren Dauer von 26 bis 39 min (DADO und ALLEN 1993; VOELKER und ALLEN 2003; PRENDIVILLE et al. 2010). DONG et al. (2018) gaben eine Spannweite von 11 bis 69 min für die Wiederkauperiodendauer an. Zu Beginn und zum Ende einer Periode ist die Rate der Wiederkauschläge, also die Geschwindigkeit, mit der wiedergekaut wird, geringer als in der Mitte (MELIN et al. 2007).

Wiederkauen wird vor allem nachts gezeigt (TERNMAN et al. 2018) mit einem zusätzlichen Peak am Nachmittag (O'CONNELL et al. 1989; GREGORINI et al. 2012; SCHIRMANN et al. 2012). Dabei war im direkten Vergleich die zeitliche Verteilung des Wiederkauverhaltens im Stall weniger klar definiert als auf der Weide (O'CONNELL et al. 1989). Die Wiederkauperioden sind nachts länger, während sich ihre Zahl zwischen Tag und Nacht nicht unterscheidet (TERNMAN et al. 2018).

### 1.1.7. Wasseraufnahme

Milchkühe verbringen im Mittel 17 bis 19 min am Tag mit Trinken (DADO und ALLEN 1994; VOELKER und ALLEN 2003). Die Anzahl an Trinkperioden pro Tag schwankt stark von 2 (JAGO et al. 2005) über 7 (CARDOT et al. 2008) bis 15 (DADO und ALLEN 1994). Die mittlere Dauer einer Trinkperiode wird mit 72 bis 103 s (CHAPINAL et al. 2007; FORIS et al. 2019) angegeben. Pro Trinkminute schlucken die Tiere im Schnitt 37 bis 40 mal (PINHEIRO MACHADO FILHO et al. 2004). Auch die durchschnittliche Trinkmenge ist mit einer Spannweite von 26 (JAGO et al. 2005) bis 93 l pro Tier und Tag (OSBORNE et al. 2002) sehr unterschiedlich. Der Großteil der Wasseraufnahme erfolgt tagsüber (CARDOT et al. 2008). Die meisten Trinkvorgänge werden nach dem Melken (JAGO et al. 2005) bzw. nach der Futtervorlage gezeigt (OSBORNE et al. 2002).

### 1.2. Variationen des Normalverhaltens durch Haltungs- und Managementparameter

Zahlreiche Haltungs- und Managementparameter führen zu Variationen im Normalverhalten von Milchkühen. Tabelle 3 gibt einen Überblick über die wichtigsten Faktoren.

**Tabelle 3: Übersicht über Haltungs- und Managementfaktoren, die das Verhalten von Milchkühen beeinflussen**

Haltungs- oder Managementfaktor	beeinflusste Verhaltensweisen	Literaturquelle
Melken		
Art des Melksystems	Liegen, Fressen	FLURY und GYGAX 2016
Melkzeiten	Liegen, Fressen, Trinken	OSBORNE et al. 2002; JAGO et al. 2005; LEGRAND et al. 2009; NORRING und VALROS 2016
Melkhäufigkeit	Gehen, Grasen	TUCKER et al. 2007a
Wartezeit vor dem Melken	Liegen	BEGGS et al. 2018
Entfernung zwischen Melkstand und Weide	Liegen, Gehen	BEGGS et al. 2018

Liegeboxen		
Oberflächenmaterial der Liegeboxen	Liegen	COOK et al. 2004; TUCKER und WEARY 2004; PALO et al. 2006; TUCKER et al. 2009; ITO et al. 2014
Verschmutzung der Liegeboxen	Liegen	ITO et al. 2014
Maße und Aufbau der Liegeboxen	Liegen	TUCKER et al. 2004; TUCKER et al. 2006
Herdenmanagement		
Herdengröße	Liegen, Gehen	FLURY und GYGAX 2016; BEGGS et al. 2019
Besatzdichte	Liegen, Gehen	PHILLIPS und LEAVER 1986; FREGONESI et al. 2007; ITO et al. 2014; WINCKLER et al. 2015
Umgruppierungen	Liegen, Stehen, Fressen, Wiederkauen	HASEGAWA et al. 1997; HERSKIN et al. 2004; SCHIRMANN et al. 2011; MAZER et al. 2020
Fütterung		
Häufigkeit der Futtevorlage	Liegen	DEMING et al. 2013; ITO et al. 2014
Zeitpunkt der Futtevorlage	Liegen, Trinken	OSBORNE et al. 2002; DEVRIES und KEYSERLINGK 2005
Futterzusammensetzung (Grundfutter-, Kraftfuttergehalt)	Fressen	FRIGGENS et al. 1998; TOLKAMP et al. 2002
Fasergehalt des Grundfutters	Fressen	ABRAHAMSE et al. 2008; SUZUKI et al. 2014
Weidemanagement		
Begrenzung der Weidezeiten	Liegen, Gehen, Fressen, Grasens, Wiederkauen	KETELAAR-DE LAUWERE et al. 1999; GREGORINI et al. 2009; PÉREZ-RAMÍREZ et al. 2009; GREGORINI et al. 2012; CRUMP et al. 2019

Zeitpunkt der Weidezeiten	Grasen	GREGORINI et al. 2009; PÉREZ-RAMÍREZ et al. 2009
Distanz zwischen Stall und Weide	Grasen	SPÖRNDLY und WREDLE 2004
Aufwuchshöhe	Liegen, Grasen	MOTUPALLI et al. 2014
Futtermverfügbarkeit auf der Weide	Liegen	PÉREZ-RAMÍREZ et al. 2009; O'DRISCOLL et al. 2015, 2019
Zufütterung im Stall bei Weidehaltung	Grasen, Wiederkauen	PHILLIPS und LEAVER 1986; SPÖRNDLY und WREDLE 2004; SHEAHAN et al. 2013
Wasserversorgung		
Größe des Wassertrogs	Trinken	PINHEIRO MACHADO FILHO et al. 2004
Wasserflussrate	Trinken	ANDERSSON et al. 1984
Wassertemperatur	Trinken	OSBORNE et al. 2002
Sonstiges		
Art des Kuhverkehrs	Wiederkauen	MELIN et al. 2007
Bodenbelag der Laufwege	Gehen	PHILLIPS und MORRIS 2001; ALSAOD et al. 2017

### 1.3. Tierbezogene Variationen des Normalverhalten

#### 1.3.1. Rasse

Am häufigsten werden in Deutschland Milchkühe der Rasse Holstein-Schwarzbunt, auch Holstein Friesian (HF) genannt, gehalten. Die zweithäufigste Rasse in der Milchviehhaltung ist die Zweinutzungsrasse Fleckvieh (engl.: Simmental), die im Süden von Deutschland überwiegt. Weitere in Deutschland für die Milchproduktion gehaltene Rassen sind Holstein-Rotbunt und Braunvieh (STATISTISCHES BUNDESAMT 2021). Auch in anderen Ländern sind HF-Kühe vorherrschend. Weitere vertretene Milchviehrassen sind unter anderem Jersey und Ayrshire (STRINGLEMAN und SCRIMEGEOUR 2008; DECHOW 2015).

In den meisten Untersuchungen wird das Verhalten von Holstein- mit Jersey-Kühen verglichen. Die tägliche Liegezeit unterscheidet sich zwischen den beiden Rassen

nicht, wobei Holstein-Kühe längere Liegeperioden zeigen (MAZER et al. 2020). Sowohl auf der Weide als auch im Stall nehmen Holstein-Kühe mehr Futter auf als Jersey-Kühe, wobei die höhere Futteraufnahme nicht begleitet ist von einer erhöhten Fressdauer oder -frequenz, sondern sich auf einer erhöhten Aufnahmerate begründet (AIKMAN et al. 2008; PRENDIVILLE et al. 2010). Auch die Wiederkaudauer liegt bei Holstein-Kühen höher (AIKMAN et al. 2008; PRENDIVILLE et al. 2010). Die größten Unterschiede zwischen verschiedenen Rassen resultieren aber aus den Unterschieden in der Milchleistung, die in Kapitel 1.3.4 beschrieben sind.

### **1.3.2. Alter und Parität**

Milchkühe, die noch kein Kalb geboren haben, bezeichnet man als Färsen oder nullipar. Im Alter von 26 bis 30 Monaten bekommen Milchkühe im Schnitt ihr erstes Kalb (DIEPOLD 2019; STEELE 2020). Nach der ersten Abkalbung beginnt die erste Parität und die Tiere gelten als primipar. Im Gegensatz dazu werden Milchkühe, die mehr als ein Kalb geboren haben, als multipar bezeichnet. Je höher das Alter des Tieres, desto höher in der Regel auch die Parität.

Das Tierverhalten unterscheidet sich je nach Parität. In den meisten Untersuchungen im Stall wurde bei primiparen im Vergleich zu multiparen Tieren eine kürzere tägliche Liegezeit bei einer höheren Liegeperiodenfrequenz und kürzeren Liegeperiodendauer beobachtet (SEPÚLVEDA-VARAS et al. 2014; NEAVE et al. 2017; PIÑEIRO et al. 2019; MAZER et al. 2020). THORUP et al. (2015) beobachteten eine signifikante Erhöhung der Liegedauer ab der dritten Parität. NORRING et al. (2012) und BEWLEY et al. (2010) fanden keinen Unterschied in der Liegezeit zwischen primi- und multiparen Tieren. In Anbindehaltung lagen in einer Untersuchung von FUKASAWA et al. (2019) die primiparen Tiere mehr als die multiparen, die Liegeperiodenfrequenz war hier auch bei den primiparen Tieren höher. CRUMP et al. (2019) beobachteten beim Vergleich zwischen Stall und Weide eine Zunahme der Liegezeit mit steigendem Alter auf der Weide, während sich die Liegezeit im Stall reduzierte. Mit zunehmender Parität steigt die Wiederkaudauer pro Tag an (MIGUEL-PACHECO et al. 2014; KING et al. 2017b; STONE et al. 2017). Dabei ist die Dauer der Wiederkauperioden länger, während sich die Frequenz nicht signifikant unterscheidet (DADO und ALLEN 1994). Primipare Tiere sind aktiver als multipare Tiere und verbringen mehr Zeit pro Tag mit Gehen (THORUP et al. 2015;

KING et al. 2017b; CRUMP et al. 2019). Multipare Milchkühe zeigen eine erhöhte Futteraufnahme in Vergleich mit primiparen (DADO und ALLEN 1994; AZIZI et al. 2009). Während DADO und ALLEN (1994) dabei keinen Unterschied in den verschiedenen Parametern des Fressverhaltens beobachteten, verbrachten die primiparen Tiere in der Studie von AZIZI et al. (2009) mehr Zeit am Tag mit Fressen und teilten ihre Fressdauer auf mehr Perioden auf. Die höhere Futteraufnahme begründete sich in einer gesteigerten Fressrate (AZIZI et al. 2009). Auch die Wasseraufnahme ist bei multiparen Milchkühen höher, während keine Unterschiede im Trinkverhalten inklusive Trinkdauer zu beobachten sind (DADO und ALLEN 1994).

### 1.3.3. Größe und Gewicht

Der Körperkonditionsscore (engl.: Body condition score, BCS) gibt das Energiereservelevel einer Milchkuh wieder und ist dafür geeignet, die Veränderungen der Energiereserve in der Laktation zu beurteilen (BEWLEY und SCHUTZ 2008). Anhand des äußeren Erscheinungsbildes einer Milchkuh wird, z. B. nach EDMONSON et al. (1988), der BCS festgelegt. Dabei besteht ein enger Zusammenhang zwischen Veränderungen im Körpergewicht und Veränderungen des BCS (JAURENA et al. 2005). Nach der Abkalbung nehmen Körpergewicht und BCS zunächst ab, um dann über den Verlauf der Laktation hinweg anzusteigen (BANOS et al. 2004; DOHME-MEIER et al. 2014; GÁSPÁRDY et al. 2014).

Milchkühe zeigen je nach Körpergewicht bzw. BCS Unterschiede im Verhalten. Mit zunehmendem BCS liegen die Tiere vermehrt (TUCKER et al. 2007b; KING et al. 2017b). Tiere mit niedrigem BCS zeigen eine erhöhte Fressdauer im Vergleich zu Tieren mit hohem BCS (TUCKER et al. 2007b), wobei die Kaeffizienz bei Tieren mit höherem Körpergewicht gesteigert ist (BAE et al. 1983). Während BAE et al. (1983) mit steigendem Körpergewicht eine Abnahme der Wiederkaudauer beobachteten, konnten MIGUEL-PACHECO et al. (2014) keinen Unterschied feststellen.

Neben dem Körpergewicht bzw. dem BCS sind auch die Maße des Körperrahmens der Tiere für das Verhalten relevant. Im Stall spielen hierbei in Relation zur Widerristhöhe die Gestaltung und Abmessung der Liegeboxen eine große Rolle für das Ablege-, Aufsteh- und Liegeverhalten (DIRKSEN et al. 2020), siehe auch 1.2).

Die Körperhöhe und -länge von Milchkühen korreliert positiv mit ihrer Schrittlänge (TELEZHENKO 2009).

#### **1.3.4. Laktationsstufe und Milchleistung**

Mit der Abkalbung beginnt die Laktation einer Milchkuh. Über den Verlauf der Laktation hinweg verändert sich die Milchleistung, weshalb ein enger Zusammenhang zwischen Milchleistung und Laktationsstufe besteht. Zum Beginn der Laktation steigt die Milchleistung etwa bis zum 90. Tag in Milch (engl.: days in milk, DIM) an, erreicht dann eine Plateau-Phase und fällt etwa ab dem 120. DIM wieder ab (GÁSPÁRDY et al. 2014; KING et al. 2017a). Betrachtet man die gesamte Laktation, so sinkt die Milchleistung mit Fortschreiten der Laktation (DEMING et al. 2013; KING et al. 2017b). Nach einer Wartezeit von 42 bis 80 Tagen nach der Abkalbung werden Milchkühe erneut besamt (HILBK-KORTENBRUCK 2020). Deshalb schreitet mit dem Verlauf der Laktation parallel auch die Trächtigkeit der Tiere voran.

Im Verlauf der Laktation ändert sich parallel zur Milchleistung auch das Verhalten der Tiere. Unmittelbar nach der Geburt steigt die zuvor zur Abkalbung hin gesunkene Fress-, Wiederkau- und Liegedauer zunächst wieder an (JENSEN 2012; SCHIRMANN et al. 2013). Die Liegezeit steigt auch im weiteren Verlauf der Laktation weiter an (BEWLEY et al. 2010; DEMING et al. 2013; ITO et al. 2014; THORUP et al. 2015; KING et al. 2017b). Dabei nimmt die Liegeperiodendauer zu, während die Liegeperiodenfrequenz sinkt (DEMING et al. 2013; KING et al. 2017a). Auch die Fressdauer bzw. Grasedauer steigt zunächst bis zur Plateauphase weiter an (DEVRIES et al. 2003; DOHME-MEIER et al. 2014). Sie fällt dann aber zum Ende der Laktationsphase hin ab, begleitet von einer Reduktion der Mahlzeitendauer und einer Steigerung der Fressfrequenz (ABRAHAMSE et al. 2008). Die Wiederkaudauer reduziert sich nach dem initialen Anstieg nach der Abkalbung über den Verlauf der Laktation ebenfalls (GÁSPÁRDY et al. 2014; MIGUEL-PACHECO et al. 2014; KING et al. 2017b; MÜSCHNER-SIEMENS et al. 2020). Im Hinblick auf die Aktivität beobachteten KING et al. (2017b) eine Reduktion der Aktivität mit zunehmenden DIM. In einer anderen Studie hingegen beobachteten KING et al. (2017a) eine Steigerung der Aktivität im Verlauf der Laktation. Auch in der Untersuchung von THORUP et al. (2015) zeigten die Tiere in der frühen Laktation eine geringere Aktivität als in der Mitte oder am Ende.

Unabhängig von den durch die Laktationsstufe bedingten Verhaltensänderungen zeigen Tiere mit verschiedenen Milchleistungen Unterschiede im Verhalten. Bei gleicher Laktationsstufe liegen Tiere mit einer hohen Milchleistung weniger (FREGONESI und LEAVER 2001; NORRING et al. 2012; STONE et al. 2017). Hochleistende Tiere nehmen mehr Futter auf (FREGONESI und LEAVER 2001). FREGONESI und LEAVER (2001) beobachteten mit steigender Milchleistung eine Zunahme der Fresszeit pro Tag, NORRING et al. (2012) hingegen registrierten keinen Unterschied. In einigen Studien stieg die Gesamtwiederkaudauer mit zunehmender Milchleistung (STONE et al. 2017; MÜSCHNER-SIEMENS et al. 2020), während in der Untersuchung von NORRING et al. (2012) nur die Wiederkauzeit im Stehen zunahm. TAPKI und ŞAHIN (2006) beobachteten in niedrig leistenden Tieren eine höhere Wiederkaudauer. Mit zunehmender Milchleistung steigt der Wasserbedarf (MEYER et al. 2004), was in einer Zunahme der Trinkdauer resultiert (TAPKI und ŞAHIN 2006).

### **1.3.5. Rang in der Herde**

Der soziale Rang einer Milchkuh wird meist anhand von Verdrängungsvorgängen, z. B. am Futtertisch, ermittelt. Die Vorgänge werden gezählt und die dominante (= verdrängende) und die untergeordnete (= verdrängte) Kuh werden bestimmt. Daraus wird dann ein Dominanz-Index berechnet, der den sozialen Rang des Tieres wiedergibt (PHILLIPS und RIND 2002; VAL-LAILLET et al. 2008; UNGERFELD et al. 2014). Auch die Hierarchiestruktur in einer Herde kann über die Verdrängungsvorgänge anhand verschiedener Indices berechnet werden. Die Dominanzbeziehungen in einer Herde sind dabei häufig zirkulär und bi-direktional (VAL-LAILLET et al. 2008). Tiere mit einer höheren Parität und einem höheren Körpergewicht haben einen höheren Dominanzindex (PHILLIPS und RIND 2002; VAL-LAILLET et al. 2008). Höherrangige Tiere produzieren mehr Milch (VAL-LAILLET et al. 2008).

Zudem nimmt der soziale Rang Einfluss auf das Verhalten. Tiere mit einem hohen Rang liegen mehr im Vergleich zu niedrigrangigen Tieren, die stattdessen mehr Zeit mit Stehen (in der Liegebox) verbringen (GALINDO and BROOM 2000). Während PHILLIPS und RIND (2002) keinen Unterschied in der Wiederkaudauer pro Tag beobachteten, kauten in der Studie von UNGERFELD et al. (2014) die Tiere mit einem höheren Dominanzlevel mehr wieder. Auf die Fressdauer im Stall hat das

Dominanzlevel keinen Einfluss (PHILLIPS und RIND 2002; VAL-LAILLET et al. 2008), wobei VAL-LAILLET et al. (2008) eine erhöhte Fresszeit in den 2 h nach Futtervorlage bei dominanten Tieren beobachteten. MELIN et al. (2007) beobachteten dabei eine höhere Kaurate (Kauschläge/Minute) für Tiere mit niedrigem Rang. Auf der Weide verbringen niedrigrangige Tiere mehr Zeit mit Grasens als Tiere mit hohem Rang (UNGERFELD et al. 2014). PHILLIPS und RIND (2002) beobachteten dabei eine höhere Biss- bzw. Kaurate (Bisse bzw. Kauschläge/Minute) bei hochrangigen Tieren.

#### **1.4. Abweichungen vom Normalverhalten**

Zahlreiche Faktoren können bei Milchkühen zu Abweichungen im Verhalten führen. Je nach Faktor variieren die Verhaltensweisen in ihrer täglichen Gesamtdauer, ihrer Frequenz und/oder der Dauer einzelner Verhaltensperioden. Meist lässt sich der Ursprung der Verhaltensänderung nicht nur auf einen einzelnen Faktor begrenzen, sondern vielmehr auf ein Zusammenspiel verschiedener Faktoren. Als physiologisch auftretende Phänomene alterieren die Brunst und die Abkalbung durch hormonelle Veränderungen das Tierverhalten. Daneben führen Erkrankungen als pathologische Ereignisse zu Verhaltensänderungen, aber auch äußere Faktoren wie die Witterung resultieren in Abweichungen im Tierverhalten.

##### **1.4.1. Brunst**

Die Brunst bezeichnet den Abschnitt vor der Ovulation, in dem die Tiere die für die Brunst typischen Verhaltensänderungen zeigen. Ursache für die Veränderungen ist der Anstieg von Östrogen, welches von dem im Ovar heranreifenden Follikel stammt. Zu den Brunstsymptomen gehören das Bespringen und die Duldung des Bespringens durch andere Tiere, sowie das Kinn auflegen und das Beschnüffeln der Anogenitalregion anderer Tiere (KERBRAT und DISENHAUS 2004; PALMER et al. 2012; DOBSON et al. 2018). Insgesamt steigt im Zeitraum der Brunst die Aktivität der Tiere an (LØVENDAHL and CHAGUNDA 2010; MINEGISHI et al. 2019). In einer Untersuchung von VEISSIER et al. (2017) zeigten die Tiere sowohl am Tag vor der Brunst als auch am Tag der Brunst selber ein erhöhtes Aktivitätslevel.

Der Zeitraum, in dem Milchkühe Brunstverhalten zeigen, variiert bedingt durch verschiedene Einflussfaktoren und umfasst zwischen 3 und 28 h (ROELOFS et al. 2005; DOBSON et al. 2018; SCHWEINZER et al. 2019). Je mehr Tiere gleichzeitig in Brunst sind, desto länger und intensiver ist das gezeigte Brunstverhalten (HURNIK

et al. 1975; ROELOFS et al. 2005). Primipare Tiere zeigen eine intensivere Brunst als multipare Tiere (ROELOFS et al. 2005). Auf der Weide gehaltene Tiere zeigen mehr Brunstsymptome als Tiere im Stall (PALMER et al. 2012). Die Bodenbeschaffenheit hat Einfluss auf die Intensität und Dauer der Brunstsymptome (RODTIAN et al. 1996). Bei hochleistenden Tieren hingegen ist die Brunst kürzer und die extremen Verhaltensweisen wie Bespringen und Dulden werden weniger gezeigt (LOPEZ et al. 2004). Auch lahme Tiere zeigen eine reduzierte Brunstdauer (WALKER et al. 2008). Ein Ausbleiben der Brunstsymptome bezeichnet man als stille Brunst. Unter Hitzebelastung zeigen mehr Tiere eine stille Brunst (RODTIAN et al. 1996).

Neben den für die Brunst typischen Verhaltensweisen sind bei Milchkühen um den Zeitpunkt der Brunst auch Veränderungen der Hauptverhaltensweisen, insbesondere ihrer Dauer, zu beobachten. Die Geh- und Stehzeit ist auf Kosten der Liegezeit erhöht (HURNIK et al. 1975; KERBRAT und DISENHAUS 2004; ZEBARI et al. 2018). Die Wiederkaudauer ist reduziert (REITH and HOY 2012; MINEGISHI et al. 2019). Die Tiere verbringen am Tag der Brunst weniger Zeit mit Fressen (ZEBARI et al. 2018) und zeigen vermehrt agonistisches Verhalten gegenüber anderen Herdenmitgliedern (HURNIK et al. 1975; KERBRAT und DISENHAUS 2004). Änderungen der Hauptverhaltensweisen, wie z. B. eine Reduktion der Fresszeit treten auch während einer stillen Brunst auf (ZEBARI et al. 2018).

#### **1.4.2. Abkalbung**

Die Abkalbung wird bei Milchkühen in fünf Phasen unterteilt. Die erste Phase beginnt bereits einige Wochen vor der Geburt und wird als Vorbereitungsphase bezeichnet. Anzeichen für den Beginn dieser Phase sind das Einfallen der Beckenbänder, Anschwellen des Euters und ein geröteter Vulvabereich (BERGLUND et al. 1987). Der Geburtsprozess beginnt dann mit der Öffnungsphase, die mit zunehmender Unruhe des Muttertiers anfängt und mit dem Sprung der Fruchtblase endet. Die Öffnungsphase dauert im Schnitt 40 bis 140 min (OWENS et al. 1985; BERGLUND et al. 1987; KOVÁCS et al. 2016). Im Anschluss folgt bis zum Sichtbarwerden des Kälberkopfes im Vulvabereich die Aufweitungphase, die durchschnittlich 15 bis 90 min andauert (OWENS et al. 1985; BERGLUND et al. 1987; SCHUENEMANN et al. 2011). Bis zur vollständigen Austreibung des Fötus folgt danach die Austreibungsphase, die im Mittel 35 bis 70 min dauert (SCHUENEMANN

et al. 2011; PALOMBI et al. 2013). Daraufhin beginnt die Nachgeburtsphase, die mit dem vollständigen Abgang der Nachgeburt im Durchschnitt 2,5 bis 5 h nach Geburt beendet ist (OWENS et al. 1985; BERGLUND et al. 1987). Die hormonellen Veränderungen, die mit den verschiedenen Phasen der Geburt einhergehen, resultieren beim Muttertier in Verhaltensänderungen. Verschiedene Verhaltensweisen sind zu verschiedenen Zeitpunkten in Relation zum Geburtszeitpunkt von den Änderungen betroffen.

Rund um die Geburt reduziert sich die Fressdauer der Tiere (MIEDEMA et al. 2011b). Eine signifikante Reduktion lässt sich ab 8 h vor dem Geburtszeitpunkt beobachten (JENSEN 2012; SCHIRMANN et al. 2013; GIARETTA et al. 2021). Ab 6 h nach der Geburt steigt die Fressdauer kontinuierlich wieder an, bleibt aber in den Tagen nach der Geburt reduziert (JENSEN 2011; SCHIRMANN et al. 2013). Auch die Wiederkaudauer sinkt im peripartalen Zeitraum. CLARK et al. (2015) konnten dabei bereits am Tag vor der Geburt eine Reduktion von 15 % beobachten und eine weitere Reduktion um 18 % am Tag der Geburt selbst. Auch SCHIRMANN et al. (2013), PAHL et al. (2014), OUELLET et al. (2016) und HORVÁTH et al. (2021) beobachteten eine Reduktion der Wiederkauzeit am Tag der Geburt. Während HORVÁTH et al. (2021) ab 2 h vor Abschluss der Austreibung eine signifikante Reduktion ausmachten, reduzierten die Tiere in der Studie von PAHL et al. (2014) 4 h präpartum signifikant ihre Wiederkaudauer. Nach der Geburt steigt die Wiederkaudauer nach 4 h wieder an und erreicht nach 24 bis 48 h ihren Ausgangswert (SCHIRMANN et al. 2013). Milchkühe erhöhen rund um den Geburtszeitpunkt ihre Aktivität (JENSEN 2012; CLARK et al. 2015). JENSEN (2012) beobachteten die Aktivitätssteigerung ab 6 h präpartum. In der Untersuchung von CLARK et al. (2015) erreichte das Aktivitätslevel an Tag 2 nach der Geburt seinen Höhepunkt und sank danach bis Tag 5 wieder auf das Ausgangslevel ab. Das erhöhte Aktivitätslevel um die Geburt geht mit einer Steigerung der Stehzeit, sowie der Gehzeit und Schrittzahl einher, die am Tag der Geburt und am Tag nach der Geburt auftritt (HUZZEY et al. 2005; MIEDEMA et al. 2011b; TITLER et al. 2015; BLACK und KRAWCZEL 2016). Gleichzeitig findet am Tag vor der Geburt eine Reduktion der Liegezeit statt (JENSEN 2012). Im Vergleich der 2h-Intervalle vor dem Geburtszeitpunkt beobachtete JENSEN (2012) eine signifikante Reduktion der Liegezeit ab 6 h vor der Geburt. Trotz Reduktion der Liegezeit erhöht sich die Frequenz der Liegeperioden um den Zeitpunkt der Geburt deutlich. JENSEN (2012)

beobachtete ab 6 h vor der Geburt eine signifikante Erhöhung der Liegefrequenz, während MIEDEMA et al. (2011a) und MIEDEMA et al. (2011b) ab 4 h vor der Geburt eine signifikante Erhöhung ausmachten. Ab 1 h nach der Geburt steigt die Liegezeit bei gleichzeitiger Reduktion der Liegefrequenz stetig wieder an (JENSEN 2012).

Neben den Abweichungen der Hauptverhaltensweisen zeigen Milchkühe im peripartalen Zeitraum eine Änderung der für die Geburt spezifischen Verhaltensweisen. Dazu gehört unter anderem das Schwanzheben. Sowohl die Dauer als auch die Frequenz sind präpartal erhöht (MIEDEMA et al. 2011a, 2011b; GIARETTA et al. 2021). Die Erhöhung der Frequenz und der Dauer beginnt 6 bis 4 h vor der Geburt. Die Frequenz erreicht 2h vor Geburt ihr Maximum (MIEDEMA et al. 2011a). JENSEN (2012) beobachtete neben dem Schwanzheben, dass die Tiere 2 h vor Geburt signifikant häufiger ihren Kopf zum Bauch drehen als in den Stunden zuvor. Nach der Geburt zeigt das Muttertier auf das Kalb gerichtetes Sozialverhalten wie Beschnüffeln und Belecken. Diese Verhaltensweisen treten direkt nach der Geburt in hoher Frequenz und Dauer auf und nehmen in den ersten 24 h nach Geburt stetig ab (JENSEN 2011, 2012).

In einigen Untersuchungen konnten Unterschiede in den Verhaltensänderungen rund um die Abkalbung zwischen primiparen und multiparen Tieren gefunden werden. In der Studie von MIEDEMA et al. (2011a) zeigten primipare Tiere einen stärkeren Anstieg der Liegeperiodenfrequenz 4 h vor der Geburt. Der Anstieg der Frequenz des Schwanzhebens begann zudem bei den primiparen Tieren früher als bei den multiparen (MIEDEMA et al. 2011a). In der Untersuchung von NEAVE et al. (2017) zeigten primipare Tiere in den drei Wochen nach der Geburt eine höhere Zahl, aber dafür kürzere Liegeperioden als multipare Tiere.

### **1.4.3. Erkrankungen**

#### **1.4.3.1. Peripartale Gesundheitsstörungen**

Zahlreiche hormonelle und stoffwechselbezogene Veränderungen bei Milchkühen rund um den Zeitpunkt der Abkalbung reduzieren die Abwehrfunktion des Immunsystems und erhöhen in diesem Zeitraum die Anfälligkeit für Gesundheitsstörungen (LEBLANC 2010). Zu den auftretenden Gesundheitsstörungen gehören Stoffwechselstörungen ((subklinische) Hyperketonämie/Ketose, (subklinische) Hypokalzämie/Milchfieber),

Uteruserkrankungen (Nachgeburtsverhalten, Metritis) und Erkrankungen des Verdauungsapparates (Labmagenverlagerung) (BAREILLE et al. 2003). Die Gesundheitsstörungen gehen mit einer Reduktion der Futterraufnahme und der Milchleistung einher (BAREILLE et al. 2003). Zudem reduziert das Auftreten peripartaler Gesundheitsstörungen die Fruchtbarkeit (HAN und KIM 2005).

Eine subklinische **Ketose** entsteht durch ein Zusammenspiel aus der plötzlichen Erhöhung des Energiebedarfs durch den Beginn der Milchproduktion und der reduzierten Energiezufuhr durch eine verringerte Futterraufnahme. Die negative Energiebilanz führt zum Abbau von Fettsäuren zu Ketonkörpern, die als Energielieferant dienen (COOPER 2014). Eine Ketose wird diagnostiziert über einen  $\beta$ -Hydroxybutyrat-Gehalt im Blut von  $\geq 1,0$  bis 1,2 mmol/l innerhalb der ersten 14 Tage nach der Abkalbung (LIBOREIRO et al. 2015; SCHIRMANN et al. 2016; KING et al. 2017a; PIÑEIRO et al. 2019). Eine subklinische Ketose tritt im Mittel 9 Tage nach der Abkalbung auf (STANGAFERRO et al. 2016a). Multipare Tiere, die an einer subklinischen Ketose erkrankt sind, zeigen an Tag 2 bis 4 nach der Abkalbung eine Steigerung der Liegezeit (PIÑEIRO et al. 2019). Die Fressdauer und die Besuche am Futtertisch sind reduziert, während die Fressrate erhöht ist. Die Veränderungen des Fressverhaltens beginnen 7 Tage vor der Abkalbung und dauern bis 2 Tage davor (Fressrate) bzw. 8 (Besuche am Futtertisch) und 14 (Fressdauer) Tage danach an (SCHIRMANN et al. 2016). Tiere, die an einer subklinischen Ketose erkranken, zeigen eine Reduktion der Wiederkaudauer 7 Tage vor bis 17 Tage nach der Abkalbung bzw. 6 Tage vor bis 5 Tage nach der Diagnose (SCHIRMANN et al. 2016; STANGAFERRO et al. 2016a; KING et al. 2017a). Auch die Aktivität ist unter subklinischer Ketose herabgesetzt. Die Aktivitätsminderung lässt sich 4 bis 11 Tage nach der Abkalbung (LIBOREIRO et al. 2015) bzw. 5 Tage vor bis 5 Tage nach der Diagnose (STANGAFERRO et al. 2016a) beobachten.

Eine subklinische **Hypokalzämie** ist durch einen verringerten Kalziumgehalt im Blut charakterisiert, der aus dem plötzlichen Kalziumbedarf für die Kolostrumbildung bei gleichzeitigem Unvermögen der Aufrechterhaltung des Kalziumhaushalts resultiert (REINHARDT et al. 1988; HORST et al. 2005). Bei einer klinischen Hypokalzämie, auch Milchfieber genannt, werden die Symptome des Kalziummangels, wie Muskelschwäche, Lethargie und Festliegen, sichtbar (JAWOR et al. 2012). Eine (subklinische) Hypokalzämie tritt im Mittel am ersten Tag nach der Abkalbung auf (BAREILLE et al. 2003). Verschiedene Studien untersuchten den

Einfluss einer subklinischen Hypokalzämie auf das Verhalten von Milchkühen. In der Untersuchung von JAWOR et al. (2012) wurde eine subklinische Hypokalzämie mit einem Blutkalziumgehalt von  $\leq 1,8$  mmol/l innerhalb der ersten 24 h nach Abkalbung definiert, während LIBOREIRO et al. (2015) 8,55 ng/dl in den ersten 72 h nach Abkalbung als Grenzwert festlegten. Tiere mit subklinischer Hypokalzämie zeigen eine reduzierte Stehdauer am Tag vor der Diagnose (JAWOR et al. 2012). Zudem zeigen die Tiere eine verringerte Wiederkaudauer vor, sowie am Tag und Folgetag der Abkalbung (LIBOREIRO et al. 2015).

**Nachgeburtverhalten** ist der fehlende Abgang fetaler Membranen innerhalb von 24 h nach der Abkalbung (LIBOREIRO et al. 2015; STANGAFERRO et al. 2016a). Tiere mit Nachgeburtverhalten haben ein höheres Risiko für Metritis und Stoffwechselstörungen (HAN und KIM 2005). Nachgeburtverhalten geht mit einer Reduktion der Wiederkaudauer von Tag 2 bis 8 und einer Verminderung der Aktivität von Tag 1 bis 7 nach der Abkalbung einher (LIBOREIRO et al. 2015).

Eine **Metritis** ist die Entzündung des Myometriums und äußert sich mit wässrigem, rosa-braunem, stinkendem vaginalen Ausfluss (LIBOREIRO et al. 2015; SCHIRMANN et al. 2016; STANGAFERRO et al. 2016a). Risikofaktoren für die Entstehung einer Metritis sind unter anderem Schweregeburt und Nachgeburtverhalten (BRUUN et al. 2002).

Im Mittel tritt eine Metritis 6 bis 7 Tage nach der Abkalbung auf (BAREILLE et al. 2003; STANGAFERRO et al. 2016c). Von Tag 3 bis 14 ist bei Tieren mit Metritis nach der Abkalbung die Fressdauer reduziert (SCHIRMANN et al. 2016). Auch die Wiederkaudauer ist 2 bis 12 Tage nach der Abkalbung (LIBOREIRO et al. 2015) bzw. 5 Tage vor bis 5 Tage nach der Diagnosestellung (STANGAFERRO et al. 2016c) vermindert. Eine Reduktion der Aktivität tritt bei Tieren mit Metritis 2 bis 12 Tage nach der Abkalbung (LIBOREIRO et al. 2015) bzw. 5 Tage vor bis 5 Tage nach Diagnosestellung (STANGAFERRO et al. 2016c) auf.

Eine **Labmagenverlagerung** kann nach links oder rechts erfolgen. Die Diagnose wird bei Reduktion der Futteraufnahme anhand des typischen „Pingens“ bei der Perkussionsauskultation gestellt (KING et al. 2017a). Eine Labmagenverlagerung tritt im Mittel 15 Tage nach der Abkalbung auf (STANGAFERRO et al. 2016a) und wird z. B. durch das vorherige Auftreten von Metritis und Nachgeburtverhalten begünstigt (LEBLANC et al. 2005). Im Zusammenhang mit einer

Labmagenverlagerung kommt es zu einer Reduktion der Wiederkauzeit. Diese Verringerung tritt im Zeitraum von 8 Tagen vor bis 5 Tagen nach der Diagnosestellung auf (STANGAFERRO et al. 2016a; KING et al. 2017a). Auch die Aktivität der betroffenen Tiere reduziert sich im Zeitraum von 5 Tagen vor bis 5 Tage nach der Diagnose (STANGAFERRO et al. 2016a).

#### **1.4.3.2. Lahmheit**

Eine Lahmheit ist das klinische Erscheinungsbild einer Erkrankung oder Verletzung des Bewegungsapparates, bei dem die Tiere aufgrund von schmerzhaften Prozessen Veränderungen in der Körperhaltung, sowie dem Gangbild zeigen (VAN NUFFEL et al. 2015). Anhand des Ausmaßes der Veränderungen erfolgt die Einteilung des Schweregrads der Lahmheit. Hierfür wurden Locomotion- oder Lahmheitsscores, z. B. von SPRECHER et al. (1997), entwickelt. Lahmheiten treten in Deutschland mit einer Prävalenz von 25 % (SJÖSTRÖM et al. 2018) auf und stellen eine der wichtigsten Abgangsursachen für Milchkühe aus der Herde dar (LKV BAYERN E. V. 2020). Auf Betrieben mit Weidehaltung treten weniger Lahmheiten auf (OLMOS et al. 2009; SJÖSTRÖM et al. 2018). Zu den Ursachen für eine Lahmheit gehören unter anderem Klauengeschwüre, Weiße-Linie-Erkrankung, (inter-) digitale Dermatitis und Klauenfäule (ALMEIDA et al. 2008; NAVARRO et al. 2013). Diese Ursachen müssen sich allerdings auch nicht zwingend in Form von Abweichungen in Körperhaltung und Gangbild zeigen (BEER et al. 2016). Kosten für Diagnostik und Therapie, ein Rückgang der Milchleistung, sowie eine Reduktion der Fruchtbarkeit sind die ökonomisch bedeutsamen Folgen einer Lahmheit (KANEENE und HURD 1990; GREEN et al. 2002). Neben diesen wirtschaftlichen Auswirkungen ist eine Lahmheit begleitet von Schmerzen und stellt damit eine Reduktion des Wohlbefindens für das Tier dar (BUSTAMANTE et al. 2015).

Eine Lahmheit führt zu Abweichungen der Dauer, sowie der Frequenz der Hauptverhaltensweisen. So reduziert sich bei Tieren mit Lahmheit die tägliche Fresszeit (ALMEIDA et al. 2008; MIGUEL-PACHECO et al. 2014; BEER et al. 2016; BARKER et al. 2018; WEIGELE et al. 2018). MIGUEL-PACHECO et al. (2014) führten die reduzierte Fresszeit auf signifikante Abnahme der Frequenz bei unveränderter Fressperiodendauer zurück. ALMEIDA et al. (2008), BEER et al. (2016), MIGUEL-PACHECO et al. (2014) und KING et al. (2017a) beobachteten eine Reduktion der

täglichen Wiederkaudauer bei Tieren mit Lahmheit im Vergleich zu Tieren mit unauffälligem Lahmheitsscore. Dabei registrierten KING et al. (2017a) die Veränderung bereits im Zeitraum -14 bis -1 d vor Diagnose der Lahmheitsursache. In einer anderen Untersuchung von KING et al. (2017b) und in den von PAVLENKO et al. (2011) und WEIGELE et al. (2018) durchgeführten Studien zeigten Tiere mit Lahmheit hingegen keine signifikante Reduktion der Wiederkauzeit. PAVLENKO et al. (2011) beobachteten jedoch eine signifikante Steigerung der Wiederkauzeit im Stehen bei Tieren mit digitaler Dermatitis und eine Tendenz zur Steigerung bei Tieren mit Sohlengeschwür. In dieser Untersuchung lag auch die Gesamtstehzeit pro Tag bei lahmen Tieren höher (PAVLENKO et al. 2011). Auch ALMEIDA et al. (2008) und COOK et al. (2007) beobachteten eine erhöhte Stehzeit bei Tieren mit Abweichungen im Gangbild. In anderen Studien wiederum wurde eine reduzierte tägliche Stehzeit beobachtet (WALKER et al. 2008; NAVARRO et al. 2013; BEER et al. 2016). Während ALMEIDA et al. (2008) und PAVLENKO et al. (2011) eine Steigerung der Gehzeit bei Tieren mit Abweichungen im Gangbild bzw. einer digitalen Dermatitis und Sohlengeschwüren beobachteten, zeigten lahme Tiere in den meisten Untersuchungen eine reduzierte Gehzeit im Vergleich zu Tieren ohne Lahmheit (WALKER et al. 2008; THORUP et al. 2015; BEER et al. 2016; WEIGELE et al. 2018). Im Hinblick auf das Liegeverhalten beobachtete der Großteil der Studien für Tiere mit erhöhtem Lahmheitsscore bzw. Beeinträchtigungen der Klauen im Vergleich zu gesunden Tieren eine erhöhte tägliche Liegezeit mit verlängerten Liegeperioden und einer gleichbleibenden Liegefrequenz (BEER et al. 2016; NECHANITZKY et al. 2016; KING et al. 2017b; WEIGELE et al. 2018). CHAPINAL et al. (2009) beobachteten die Erhöhung der Liegezeit und der Liegeperiodendauer nur für Tiere mit Ulcera, SEPÚLVEDA-VARAS et al. (2014) nur für stark lahme Tiere und ITO et al. (2010) nur für stark lahme Tiere, die mit Tiefstreu-Liegeboxen gehalten werden. In der Untersuchung von DEMING et al. (2013) war die Liegedauer und die Liegefrequenz erhöht. Im Gegensatz dazu beobachteten ALMEIDA et al. (2008) keine signifikante Veränderung der Liegezeit und COOK et al. (2004) eine Reduktion der täglichen Liegedauer bei erhöhtem Lahmheitsscore. Auch auf das Sozial- und Komfortverhalten nimmt eine Lahmheit Einfluss. So befinden sich lahme Tiere in der Melkordnung weiter hinten als Tiere ohne Lahmheit (WALKER et al. 2008) und besuchen die Kuhbürste seltener (WEIGELE et al. 2018).

### 1.4.3.3. Mastitis

Bei einer Mastitis sind aufgrund einer Infektion mit euterpathogenen Keimen ein oder mehrere Euterviertel entzündlich verändert. Man unterscheidet zwischen klinischen und subklinischen Mastitiden. Während bei einer subklinischen Mastitis die Zellzahl erhöht und/oder euterpathogene Mikroorganismen nachweisbar sind, sind bei der klinischen Mastitis zusätzlich Entzündungssymptome am Euter sowie makroskopische Veränderungen der Milch sichtbar (BAREILLE et al. 2003; STANGAFERRO et al. 2016b; SEPÚLVEDA-VARAS et al. 2018; CAPLEN and HELD 2021 [Im Druck]). Eine klinische Mastitis lässt sich weiter in eine lokale und eine systemische Mastitis unterscheiden. Bei einer systemischen Mastitis kommen zu den Veränderungen an Euter und Milch noch Fieber und/oder andere systemische Symptome hinzu (BAREILLE et al. 2003; SEPÚLVEDA-VARAS et al. 2016; STANGAFERRO et al. 2016b). Eine Mastitis führt zu einem Abfall der Milchleistung, der je nach Ausprägung von 5 Tagen vor bis über 140 Tage nach Diagnosestellung andauern kann (BAREILLE et al. 2003; LUKAS et al. 2009). Neben dem finanziellen Verlust durch den Abfall der Milchleistung fallen bei einer Mastitis Kosten durch den zusätzlichen Arbeitsaufwand, den Tierarzt, die Diagnostik, die benötigten Medikamente, die aufgrund der Therapie verworfene Milch und den Ersatz des Tieres im Falle der Ausscheidung aus der Herde an. Die mittleren Gesamtkosten von Mastitiserkrankungen belaufen sich auf 158 bis 483 € pro Tier und Jahr (DOEHRING and SUNDRUM 2019). Eutererkrankungen sind die zweithäufigste Abgangsursache für Milchkühe (LKV BAYERN E. V. 2020).

Milchkühe, die an einer subklinischen oder klinischen Mastitis erkrankt sind, weisen Änderungen im Verhalten auf. Während CAPLEN and HELD (2021 [Im Druck]) bei subklinischer Mastitis keine Veränderung des Liegeverhaltens beobachteten, stellten SIIVONEN et al. (2011) und FOGSGAARD et al. (2015) eine Reduktion der Liegedauer bei an klinischer Mastitis erkrankten Tieren fest. Dabei ist vor allem die Liegedauer auf der Körperseite der betroffenen Euterseite reduziert (SIIVONEN et al. 2011). Die Liegeperiodenfrequenz hingegen steigt (FOGSGAARD et al. 2015). Bei subklinischer Mastitis legen die Tiere beim Liegen vermehrt ihren Kopf auf ihrer Flanke ab (CAPLEN and HELD 2021 [Im Druck]). Die Futteraufnahme ist sowohl bei subklinischer als auch bei klinischer Mastitis reduziert (FOGSGAARD et al. 2012; FOGSGAARD et al. 2015; POTTER et al. 2018; SEPÚLVEDA-VARAS et al. 2018). FOGSGAARD et al. (2015) beobachteten die Reduktion bereits zehn,

SEPÚLVEDA-VARAS et al. (2018) fünf Tage vor Diagnosestellung. Die verminderte Futteraufnahme geht mit einer reduzierten Fressrate (Futtermenge/Zeiteinheit) einher (FOGSGAARD et al. 2015; SEPÚLVEDA-VARAS et al. 2018). Während SEPÚLVEDA-VARAS et al. (2018) auch eine Reduktion der Besuche am Futtertisch beobachteten, stellten FOGSGAARD et al. (2015) keinen signifikanten Unterschied in der Anzahl der Fressperioden fest. Ab Beginn der Therapie steigen Fresszeit, Besuche am Futtertisch und damit die Futteraufnahme unmittelbar wieder an (FOGSGAARD et al. 2015; SEPÚLVEDA-VARAS et al. 2018). Neben der Futteraufnahme ist auch die Wiederkaudauer bei von einer Mastitis betroffenen Tieren reduziert (SIIVONEN et al. 2011; FOGSGAARD et al. 2012; STANGAFERRO et al. 2016b). STANGAFERRO et al. (2016b) beobachteten die Reduktion bereits einen Tag vor der Diagnosestellung. Nach Behandlung erreicht die Wiederkaudauer nach etwa zwei Tagen wieder ihr Vorniveau (STANGAFERRO et al. 2016b). Die Schrittzahl (FOGSGAARD et al. 2015), die gelaufene Strecke (CAPLEN and HELD 2021 [Im Druck]) sowie die Stehdauer und Anzahl der Stehperioden ist bei an Mastitis erkrankten Tieren erhöht (SIIVONEN et al. 2011). VEISSIER et al. (2017) beobachteten insgesamt eine erhöhte Aktivität bei Tieren mit Mastitis, während STANGAFERRO et al. (2016b) eine reduzierte Aktivität, insbesondere am Tag der Diagnosestellung, feststellten. VEISSIER et al. (2017) beobachteten verminderte Tagesrhythmik bei Tieren mit Mastitis. Auch das Sozialverhalten ist bei Tieren mit Mastitis verändert. Verdrängungen anderer Tiere am Futtertisch (SEPÚLVEDA-VARAS et al. 2018) sowie allgemein das soziale Erkundungsverhalten und die soziale Reaktivität sind reduziert (CAPLEN and HELD 2021 [Im Druck]).

#### **1.4.4. Witterung**

Die Witterung nimmt Einfluss auf das Verhalten von Milchkühen. Zum einen entstehen die Veränderungen durch die Überschreitung der oberen kritischen Temperatur der thermoneutralen Zone einer Kuh (BRÜGEMANN 2012; HAMMAMI et al. 2013). In diesem Fall spricht man von einer Hitzebelastung. Die mit einer Hitzebelastung verbundenen Verhaltensänderungen sind in Kapitel 3.6 aufgeführt und erläutert. Doch auch durch niedrige Temperaturen, in Kombination mit Wind und Niederschlag, kann es zu einer Belastung von Milchkühen kommen (TUCKER et al. 2007b; WEBSTER et al. 2008). Als Reaktion auf die Witterung verändern die Tiere ihr Verhalten. Unter Kältebelastung steigern Milchkühe auf Kosten der Liegezeit ihre Stehzeit (TUCKER et al. 2007b; WEBSTER et al. 2008). WEBSTER et

al. (2008) beobachteten außerdem ein vermehrtes Liegen mit seitlich auf dem Körper abgelegtem Kopf, sowie eine Zunahme des Stehens mit gesenktem Kopf. Zudem ist die Fresszeit der Tiere reduziert (TUCKER et al. 2007b; WEBSTER et al. 2008). Haben die Tiere freie Wahl zwischen Stall und Weide, so reduziert Niederschlag bei kühlen Temperaturen die Zeit, die sie draußen verbringen (SMID et al. 2019), insbesondere nachts (LEGRAND et al. 2009).

## 2. Monitoringsysteme

Der Einsatz von Monitoringsystemen und die damit verbundene Erfassung und Verarbeitung tierbezogener Daten zur Verbesserung bzw. Automatisierung des Tiermanagements wird als Precision Livestock Farming (PLF) bezeichnet (BERCKMANS 2014). Monitoringsysteme werden am Tier angebracht und erfassen mit Hilfe verschiedener Sensoren Daten zu Tierverhalten und Tierphysiologie. Die Daten werden mittels Informations- und Kommunikationstechnologie verarbeitet und dem Landwirt für die Entscheidungsfindung bzw. -unterstützung zur Verfügung gestellt (HOSTIOU et al. 2017; GARCÍA et al. 2020).

Die Verwendung von PLF-Lösungen für das Tiermanagement hat zahlreiche Vorteile. Über die kontinuierliche und automatisierte Erfassung können Änderungen im Tierverhalten unmittelbar registriert werden. Änderungen im Tierverhalten treten im Zusammenhang mit der Brunst (siehe 1.4.1), der Abkalbung (siehe 1.4.2), Erkrankungen (siehe 1.4.3) oder Belastungen durch die Witterung (siehe 1.4.4 und 3.6) auf. Der Einsatz eines Monitoringsystems steigert die Rate der Brunsterkennung (HOLMAN et al. 2011), was die Chance für eine erfolgreiche Besamung erhöht und Kosten vermeidet, die mit einer verpassten Brunst einhergehen (SHALLOO et al. 2014; DOLECHECK et al. 2016). Eine frühzeitige Detektion von Erkrankungen bzw. Belastungen der Tiergesundheit reduziert den Antibiotikaeinsatz (TREVISI et al. 2014), minimiert die mit einer Erkrankung verbundenen Kosten (KANEENE und HURD 1990) und stellt eine schnelle Wiederherstellung von Tiergesundheit und Tierwohl sicher (STANGAFERRO et al. 2016a, 2016b, 2016c).

Die manuelle Tierkontrolle ist eine zeitaufwändige Aufgabe, weshalb der Einsatz von PLF-Lösungen das Potential hat, Arbeitszeit einzusparen (HOSTIOU et al. 2017) bzw. durch Verschiebung der Tierkontrolle vom Stall zum Computer, die Flexibilität der Arbeitsverteilung zu erhöhen (JAGO et al. 2013; ALLAIN 2016; KLING-EVEILLARD et al. 2020). Die Verwendung automatisierter Tierüberwachungssysteme erhöht die Kontrolle über das Tiermanagement (KLING-EVEILLARD et al. 2020) und ermöglicht eine Überwachung auf Einzeltierebene (WATHES et al. 2008; STYGAR et al. 2021). Die Tierkontrolle durch Monitoringsysteme ist objektiv und ermöglicht die Erfassung von Parametern, welche manuell nicht möglich, bzw. mit einem unrealisierbaren Aufwand

verbunden wäre (STONE 2020). Insbesondere im Hinblick auf stetig wachsende Herdengrößen, welche die für das Einzeltier verfügbare Zeit reduzieren, bietet der Einsatz automatisierter Lösungen für die Tierkontrolle großes Potential (BERCKMANS 2014). Herausforderungen, die in Zusammenhang mit dem Einsatz von PLF-Lösungen auftreten, sind die Sicherstellung der Verfügbarkeit kostengünstiger und verlässlicher Systeme (WATHES et al. 2008), die Schaffung der Möglichkeit zur Kombination und Integration von Systemen unterschiedlicher Anbieter (WOLFERT et al. 2017) und die leicht verständliche Präsentation der komplexen Interpretation der erfassten Daten (STONE 2020). Die Verwendung von Technologien zur Tierkontrolle kann die Interaktionszeit zwischen Landwirt und Tier reduzieren (HOSTIOU et al. 2017), weshalb einige Landwirte ein Austauschen ihrer Erfahrung und Profession durch die Technik fürchten (KLING-EVEILLARD et al. 2020). Dieser Aspekt, sowie das Ansehen von PLF-Lösungen bei den Verbrauchern, müssen in die zukünftige Entwicklung und Applikation von Monitoringsystemen mit einbezogen werden, um von den zahlreichen Vorteilen für Landwirt und Tier profitieren zu können (EASTWOOD et al. 2019).

Für den Einsatz von Monitoringsystemen ist die Laufzeit des Akkus, die Robustheit des Systemgehäuses und die Art der Datenübertragung essenziell (HALADJIAN et al. 2018). Die Datenübertragung kann in Echtzeit erfolgen (REITER et al. 2018) oder zu bestimmten Tageszeiten, wie z. B. beim Melken. Letzteres ist insbesondere auf der Weide die Methode der Wahl, da hier eine Vielzahl von Antennen für die Datenübertragung nötig wäre (PEREIRA et al. 2020). Zu Forschungszwecken können die Daten auch auf einem Speichermedium abgelegt und im Anschluss an das Experiment heruntergeladen werden (RIABOFF et al. 2020). Im Hinblick auf die für den Landwirt vom Monitoringsystem bzw. der zugehörigen Software ausgegebenen Alarmmeldungen, ist eine hohe Erkennungsrate bei gleichzeitiger Reduktion von Fehlalarmen das Ziel, was häufig einen Kompromiss darstellt (LØVENDAHL and CHAGUNDA 2010; MINEGISHI et al. 2019).

Monitoringsysteme enthalten unterschiedliche Sensoren, die je nach Anbringungsort die Bewegung verschiedener Körperteile erfassen. Durch die Anwendung von maschinellen Lernmodellen auf die Sensordaten werden Regelmäßigkeiten ermittelt, die den verschiedenen Verhaltensweisen zugeordnet werden können (BROWN et al. 2013; RAHMAN et al. 2018). Für die Erstellung bzw. das Training der Lernmodelle sind Referenz-, also Ground Truth-Daten,

erforderlich, die über Verhaltensbeobachtungen gewonnen werden. Fertige Lernmodelle müssen anhand weiterer Ground Truth-Daten evaluiert werden (STYGAR et al. 2021). Erkennen die Lernmodelle die verschiedenen Verhaltensweisen zuverlässig, so kann ihre Dauer und ihr zeitliches Auftreten, sowie Änderungen dieser Parameter, erfasst werden. Über die Registrierung von Verhaltensänderungen können die Brunst, Erkrankungen und Belastungen der Tiergesundheit automatisiert und frühzeitig erkannt werden.

## 2.1. Sensoren

Monitoringsysteme zur Erfassung des Tierverhaltens enthalten verschiedene Sensoren, die je nach Anbringungsort die Bewegung verschiedener Körperteile erfassen. Häufig werden verschiedene Sensoren kombiniert, was den Informationsgewinn erhöht (BROWN et al. 2013). Eine Übersicht über die zur Erfassung der verschiedenen Verhaltensweisen verwendeten Sensoren und Sensorkombinationen findet sich in Tabelle 4.

Am häufigsten vertreten sind bei der Verhaltenserfassung von Tieren **Beschleunigungssensoren** (Accelerometer) (STYGAR et al. 2021). Diese messen die Beschleunigung eines Objekts in verschiedene Richtungen. Grundlage dafür ist, dass die im Sensor enthaltene seismische Masse durch Beschleunigung des Sensors für Druckschwankungen sorgt, die über eine piezoelektrische Sensorplatte in ein elektrisches Signal umgewandelt werden (HANSEN et al. 2007). Das elektrische Signal kann im Anschluss nach Kalibration in Beschleunigung umgerechnet werden (BROWN et al. 2013). Die am Tier gemessene Beschleunigung setzt sich aus der Gravitation und der durch die Bewegung verursachten Beschleunigung zusammen, weshalb sowohl statische als auch dynamische Verhaltensweisen erfasst werden können (SHEPARD et al. 2010; BROWN et al. 2013). Am häufigsten werden zur Verhaltenserfassung bei Tieren Sensoren verwendet, die die Beschleunigung in drei Achsen messen (BROWN et al. 2013). Die Achsen sind dabei dorsoventral, anterior-posterior (= rostrokaudal) und lateral in Relation zum Tierkörper ausgerichtet (SHEPARD et al. 2010). Zur Erkennung von Graseverhalten beispielsweise sind aber zwei Achsen ausreichend (OUDSHOORN et al. 2013; MOLFINO et al. 2017). Mit einem Beschleunigungssensor kann je nach Anbringungsort (siehe Abbildung 1) Liegen, Stehen, Gehen, Fressen, Grasen und Wiederkauen bei Milchkühen erkannt werden (BIKKER et al. 2014; ALSAOD et al.

2015; BORCHERS et al. 2016; BENAÏSSA et al. 2017; MOLFINO et al. 2017; BENAÏSSA et al. 2019). Auch Schwanzbewegungen können mit einem Beschleunigungssensor erfasst werden (KRIEGER et al. 2018).

In Kombination mit Beschleunigungssensoren wird häufig ein **Magnetometer** zur Verhaltenserfassung bei Tieren genutzt (WILLIAMS et al. 2017; RAHMAN et al. 2018). Ein Magnetometer misst die Orientierung im magnetischen Feld und dessen Intensität, wovon die Ausrichtung und Bewegung des Tieres in Relation zum Erdmagnetfeld abgeleitet werden kann (CHAKRAVARTY et al. 2019; CONNERS et al. 2021). Auch die Messung mit einem Magnetometer kann auf drei Achsen erfolgen (WILLIAMS et al. 2017). Mit der Kombination aus Beschleunigungssensor und Magnetometer kann Ruhen, Stehen, Grasen und Wiederkauen erkannt werden (GONZÁLEZ et al. 2015; RAHMAN et al. 2018).

Ergänzt werden können Beschleunigungssensor und Magnetometer zusätzlich durch ein **Gyroskop** (ANDRIAMANDROSO et al. 2017). Dieses misst Änderungen der Winkelgeschwindigkeit. Die durch die Änderungen hervorgerufene Verschiebung einer Resonanzmasse wird dabei in ein elektrisches Signal umgewandelt (GALLACHER 2012). Die Messung der Winkelgeschwindigkeit kann ebenfalls in drei Achsen erfolgen (STANČIN and TOMAŽIČ 2011). Mit der Kombination aus Beschleunigungssensor, Magnetometer und Gyroskop kann das Wiederkau- und Graseverhalten von Milchkühen erfasst werden (ANDRIAMANDROSO et al. 2017).

Die Kieferbewegungen beim Wiederkauen und Grasen, sowie das Regurgitieren beim Wiederkauen verursachen charakteristische Geräusche, die mit einem **Mikrofon** erfasst werden können (SCHIRMANN et al. 2009; GALLI et al. 2018). Über einen Mikroprozessor werden die akustischen Signale verarbeitet und die Wiederkaudauer, die Dauer einzelner Wiederkauevents und Wiederkauperioden (SCHIRMANN et al. 2009) bzw. die Anzahl der Grasebisse und Kauschläge, sowie die Grasedauer können erfasst werden (GALLI et al. 2018; CHELOTTI et al. 2020).

Auch über einen in das Nasenband eines Halfters integrierten **Drucksensor** können die Kieferbewegungen von Milchkühen erfasst werden. Der Sensor besteht aus einem luft- oder flüssigkeitsgefüllten Druckschlauch, dessen Deformation bei Bewegungen des Kiefers registriert und an einen Datenlogger gesendet wird (BALCH 1971; DADO und ALLEN 1993; STEINMETZ et al. 2020). Damit können die Wiederkau-, Fress- und Trinkdauer, einzelne Wiederkau- und Fressperioden, sowie individuelle (Wieder-)Kauschläge und Bisse registriert werden (BALCH 1971;

DADO und ALLEN 1993; RUUSKA et al. 2016; STEINMETZ et al. 2020). Auch Graseverhalten, inklusive einzelner Grasebisse, kann mit einem Drucksensor erfasst werden (WERNER et al. 2018). BALCH et al. (1951) und DADO und ALLEN (1993) nutzten den gleichen Sensoraufbau zur Messung der Pansenkontraktionen zur Erfassung des Wiederkauverhaltens, indem sie den Druckschlauch über eine Fistel in den Pansen einlegten. Ein Drucksensor wird zum Teil auch mit einem Accelerometer kombiniert zur Erfassung des Wiederkau- und Graseverhaltens eingesetzt (ROMBACH et al. 2018; STEINMETZ et al. 2020). Der Drucksensor erfasst dabei die Kieferbewegungen, während das Accelerometer die Kopfbewegungen registriert.

Ein **Neigungsmesser** (Inclinometer) misst die Neigung eines Objekts in Relation zur Erdanziehung. Neigt sich das Objekt, bewegt sich aufgrund der Erdanziehung die im Sensor integrierte Masse, was zu einer Verschiebung von Elektroden und zur Erzeugung eines elektrischen Signals führt. Neigungssensoren werden am Schwanz angebracht, um dessen Bewegung (Heben und Senken) zu erfassen. Die Frequenz bzw. Frequenzerhöhung der Schwanzbewegungen gibt Hinweise auf den Zeitpunkt der Abkalbung, sodass Neigungsmesser in Sensorsysteme zur automatisieren Erkennung des Abkalbezeitpunkts eingesetzt werden (GIARETTA et al. 2021; VOß et al. 2021).

Über die Lokalisation der Tiere in den verschiedenen Funktionsbereichen im Stall oder auf der Weide können Rückschlüsse auf das Tierverhalten gezogen werden. So wird die Aufenthaltszeit am Futtertisch zur Evaluation des Fressverhaltens (BARKER et al. 2018), die Aufenthaltszeit am Wassertrog zur Erfassung des Trinkverhaltens (CHAPINAL et al. 2007) und die Aufenthaltszeit in den Liegeboxen zur Registrierung des Ruheverhaltens genutzt (TULLO et al. 2016). Für die Lokalisation werden am häufigsten **Global Positioning System (GPS)**- oder **Radio-Frequency Identification (RFID)-Sensoren** verwendet (STYGAR et al. 2021). Lokalisierungssensoren werden häufig in Kombination mit anderen Sensoren verwendet, um die Genauigkeit der Verhaltenserkennung zu erhöhen. BARKER et al. (2018) kombinierten einen RFID-Sensor mit einem Accelerometer zur Erfassung des Fressverhaltens.

Neben dem Tierverhalten können weitere Parameter über Sensoren am Tier erfasst werden, die Informationen zur Tiergesundheit und zum Tierwohl liefern. Hierfür

werden unter anderem **Temperatursensoren** (ANTANAITIS et al. 2016) und **pH-Sensoren** (DADO und ALLEN 1993; ANTANAITIS et al. 2016) eingesetzt (STYGAR et al. 2021).

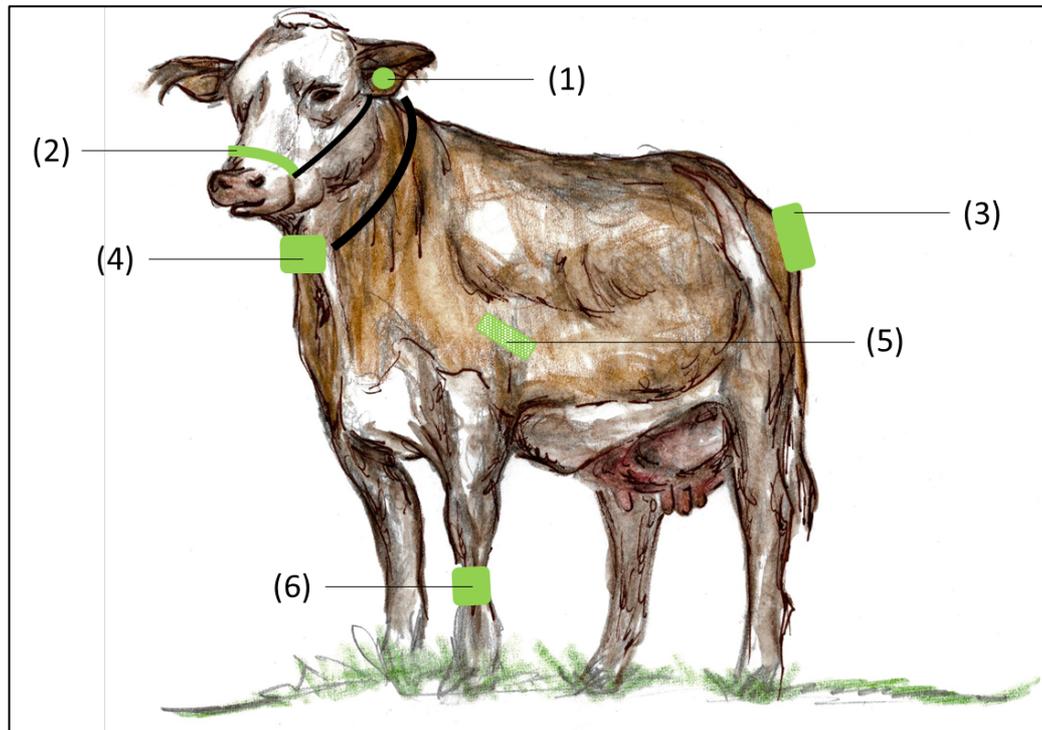
**Tabelle 4: Übersicht über die zur Verhaltenserfassung bei Milchkühen genutzten Sensoren bzw. Sensorkombinationen**

Sensor bzw. Sensorkombination	Erfasste Verhaltensweisen	Literaturquelle <sup>1</sup>
Accelerometer	Ruhen / Liegen, Stehen, Gehen, Fressen, Grasens, Wiederkauen, Schwanzbewegungen	NIELSEN 2013; ALSAOD et al. 2015; BORCHERS et al. 2016; KRIEGER et al. 2018; BENAÏSSA et al. 2019; HAMILTON et al. 2019; WERNER et al. 2019
Drucksensor	Fressen, Grasens, Wiederkauen	DADO und ALLEN 1993; RUUSKA et al. 2016
Mikrofon	Grasens, Wiederkauen	GALLI et al. 2018; CHELOTTI et al. 2020
RFID <sup>2</sup> -Sensor	Liegen, Fressen, Trinken, Gehen/Stehen	TULLO et al. 2016
Accelerometer + Magnetometer	Stehen, Grasens, Wiederkauen	RAHMAN et al. 2018
Accelerometer + Magnetometer + Gyroskop	Grasens, Wiederkauen	ANDRIAMANDROSO et al. 2017
Accelerometer + RFID <sup>2</sup> -Sensor	Fressen	BARKER et al. 2018
Accelerometer + Drucksensor	Fressen, Grasens, Wiederkauen, Trinken	ROMBACH et al. 2018; WERNER et al. 2018; STEINMETZ et al. 2020

<sup>1</sup>Beispieluntersuchungen, in denen der Sensor bzw. die Sensorkombination validiert wurde, <sup>2</sup>RFID = Radio-Frequency Identification

## 2.2. Anbringung von Sensoren am Tier

Monitoringsysteme können bei Milchkühen an unterschiedlichen Stellen am Tierkörper angebracht werden (siehe Abbildung 1).



**Abbildung 1: Mögliche Körperstellen für die Anbringung von Monitoringsystemen bei Milchkühen: (1) als Ohrmarke, (2) am Halfter, (3) am Schwanz, (4) am Halsband, (5) als Pansenbolus eingebracht in den Pansen, (6) als Pedometer an der Gliedmaße (©Anna Hofbauer)**

Tabelle 5 gibt einen Überblick über die Verhaltensweisen, die an den verschiedenen Anbringungsorten erkannt werden können. Während mit einem Halsband alle Hauptverhaltensweisen (Ruhen/Liegen, Stehen, Gehen, Fressen, Grasens, Wiederkauen) erfasst werden können (OUDSHOORN et al. 2013; MOLFINO et al. 2017; BENAÏSSA et al. 2019; WERNER et al. 2019), registrieren Sensoren an der Gliedmaße vorwiegend Lokomotionsverhalten (Ruhen/Liegen, Stehen, Gehen) (LEDGERWOOD et al. 2010; ALSAAOD et al. 2015), aber auch Fressverhalten (BORCHERS et al. 2016; BENAÏSSA et al. 2019). Mit Sensoren an Ohr und Halfter können vor allem Verhaltensweisen mit Kieferbewegungen (Fressen, Grasens, Wiederkauen, Trinken) (BORCHERS et al. 2016; RUUSKA et al. 2016; GALLI et al. 2018; JEMILA und PRIYADHARSINI 2018; STEINMETZ et al. 2020), aber auch ruhige Verhaltensweisen wie Stehen und Ruhen (BIKKER et al. 2014; RAHMAN et al. 2018) erfasst werden.

**Tabelle 5: Übersicht über die zur Verhaltenserfassung bei Milchkühen genutzten Anbringungsorte bzw. Kombination aus Anbringungsorten für Sensoren am Tier**

Anbringungsort des Sensors am Tier	Erfasste Verhaltensweisen	Literaturquellen <sup>1</sup>
Halsband	Ruhen / Liegen, Stehen, Gehen, Fressen, Grasens, Wiederkauen, Trinken	TULLO et al. 2016; ANDRIAMANDROSO et al. 2017; BARKER et al. 2018; RAHMAN et al. 2018; WERNER et al. 2019; CHELOTTI et al. 2020
Gliedmaße	Ruhen / Liegen, Stehen, Gehen, Fressen	ALSAAOD et al. 2015; BORCHERS et al. 2016
Ohr	Ruhen / Liegen, Stehen, Fressen, Grasens, Wiederkauen	BORCHERS et al. 2016; RAHMAN et al. 2018
Pansen	Wiederkauen	DADO und ALLEN 1993; HAMILTON et al. 2019
Schwanz	Schwanzbewegungen	KRIEGER et al. 2018
Halfter	Fressen, Grasens, Wiederkauen	RUUSKA et al. 2016; GALLI et al. 2018; RAHMAN et al. 2018; ROMBACH et al. 2018; STEINMETZ et al. 2020
Gliedmaße + Halfter	Liegen, Stehen, Gehen, Fressen, Grasens	NIELSEN 2013; PEREIRA et al. 2021
Halsband + Gliedmaße	Liegen, Stehen, Fressen	BENAISSA et al. 2019

<sup>1</sup>Beispieluntersuchungen, in denen der Anbringungsort bzw. die Kombination aus Anbringungsorten validiert wurde

### 2.3. Verhaltensdatenerfassung für das Training und die Validierung von Monitoringsystemen

Für das Training maschineller Lernmodelle, die in einem Monitoringsystem in den erfassten Sensordaten automatisiert die verschiedenen Verhaltensweisen erkennen, sowie für die anschließende Evaluation der Modelle, werden Ground Truth-Daten als Referenz benötigt. Ground Truth-Daten können mit Hilfe verschiedener Methodiken generiert werden.

Das Verhalten der Tiere kann mittels **Direktbeobachtung** erfasst werden. Dabei befindet sich der Beobachter in unmittelbarer Nähe zum Tier. Die Präsenz des Beobachters kann zur Beeinflussung der Tiere führen (NAGUIB und KRAUSE 2020), weshalb eine Phase der Gewöhnung der Datenerfassungsphase vorgeschaltet sein sollte (MUNKSGAARD et al. 2020). Direktbeobachtungen sind gegenüber anderen Verhaltenserfassungsmethoden zeitintensiv, insbesondere auf der Weide und unter extremen Witterungsbedingungen (MÜLLER und SCHRADER 2003). Neben der Direktbeobachtung kann das Verhalten mittels **Videobeobachtung** aufgezeichnet werden. Ein Vorteil gegenüber der Direktbeobachtung ist, dass das Videomaterial wiederholt und verlangsamt oder beschleunigt angeschaut werden kann, wodurch die Verhaltenserfassung vereinfacht und präzisiert wird (VAN ERP-VAN DER KOOIJ et al. 2016). Zudem können mehrere zur gleichen Zeit aufgenommene Tiere nacheinander kontinuierlich beobachtet werden. Auf der anderen Seite sind kleinere Bewegungen, z. B. Kieferbewegungen beim Wiederkauen im Liegen, je nach Kameraposition möglicherweise schwer zu erkennen (VAN ERP-VAN DER KOOIJ et al. 2016). Je nach Installation der Kameras muss für die Datenerfassung der/die Beobachter/in nicht permanent vor Ort sein, sodass die Tiere ungestört sind (NAGUIB und KRAUSE 2020).

Sowohl bei der Direktbeobachtung als auch bei Anfertigung und Betrachtung von Videoaufnahmen zur Verhaltenserfassung können verschiedene Auswertungstechniken angewendet werden. Es kann entweder ein Fokustier oder eine ganze Tiergruppe beobachtet werden (LEHNER 1992). Die Verhaltensbetrachtung kann kontinuierlich oder in einem festgelegten Zeitintervall, *time sampling* genannt, stattfinden (LEHNER 1992). Bei der kontinuierlichen Methode wird Start- und Endzeitpunkt der Verhaltensweisen registriert. Bei intervallstrukturierter Verhaltensbeobachtung unterscheidet man zwischen der Ja-Nein-Methode, auch *one-zero sampling* genannt, und der Momentregistrierung, dem *instantaneous sampling* (LEHNER 1992; NAGUIB und KRAUSE 2020). Bei beiden Methoden wird abhängig von den zu beobachtenden Verhaltensweisen ein Zeitintervall festgelegt, das zwei Beobachtungspunkte voneinander trennt. Beim *one-zero sampling* wird am Beobachtungszeitpunkt erfasst, ob das Verhalten im Zeitintervall davor stattgefunden hat, während beim *instantaneous sampling* registriert wird, ob das Verhalten am Beobachtungszeitpunkt selbst stattfindet (LEHNER 1992; NAGUIB und KRAUSE 2020). Werden mehrere Verhaltensweisen

erfasst, kann auch die vorherrschende Verhaltensweise im Zeitintervall bestimmt werden (TYLER 1979; BENAÏSSA et al. 2017; MOLFINO et al. 2017; ZAMBELIS et al. 2019b). Beim instantaneous sampling wird davon ausgegangen, dass die Verhaltensweise im gesamten vorangegangenen Intervall stattgefunden hat, wenn das Verhalten zum Beobachtungszeitpunkt gezeigt wird (BARKER et al. 2018).

Bei einer Tiergruppe, also wenn das Verhalten mehrerer Tiere gleichzeitig erfasst wird, nennt man das one-zero sampling auch behaviour sampling, das instantaneous sampling wird als scan sampling bezeichnet (NAGUIB und KRAUSE 2020). Das instantaneous sampling eignet sich nicht für kurz andauernde Verhaltensweisen (NAGUIB und KRAUSE 2020), da diese nicht immer genau zum Beobachtungszeitpunkt stattfinden. Die Dauer der Verhaltensweisen ergibt sich beim one-zero sampling und beim instantaneous sampling aus der Addition der Zeitintervalle zwischen den Beobachtungszeitpunkten.

Die kontinuierliche Fokustierbeobachtung liefert die genauesten Ergebnisse, ist aber am zeitaufwändigsten (MUNKSGAARD et al. 2020). Instantaneous sampling gibt das Verhalten meist besser wieder als die one-zero-Methode (TYLER 1979). Bei Tiergruppen ist scan sampling ein geeigneter Ersatz für die kontinuierliche Fokustierbeobachtung zur Verhaltenserfassung. Je kürzer das Zeitintervall, desto höher die Übereinstimmung mit der kontinuierlichen Erfassung, insbesondere bei kurz andauernden Verhaltensweisen (MITLÖHNER et al. 2001). Zwischen Direkt- und Videobeobachtung konnten REITER et al. (2018) keinen Unterschied feststellen.

Vor der Beobachtung müssen die zu erfassenden Verhaltensweisen klar definiert werden. Insbesondere bei unklaren Übergängen zwischen zwei Verhaltensweisen müssen eindeutige Definitionen festgelegt werden (NAGUIB und KRAUSE 2020). Die Auflistung der Verhaltensdefinitionen wird als Ethogramm bezeichnet. Die Verhaltenserfassung anhand eines Ethogramms bezeichnet man bei der Auswertung von Videobeobachtungen auch als Labeling, wobei einzelne Verhaltensweisen als Labels bezeichnet werden.

Ein Beobachter kann bei der Direktbeobachtung oder der Auswertung von Videobeobachtungen unterbewusst voreingenommen sein und die Daten entsprechend erfassen bzw. auswerten. Diesem Beobachtereffekt (engl.: observer bias) kann entgegen gewirkt werden, indem der Beobachter in Unwissenheit über

die Ziele der Erfassung gelassen wird oder mehrere Beobachter eingesetzt werden (NAGUIB und KRAUSE 2020). Bei der Videoauswertung können von einem Beobachter Abschnitte doppelt ausgewertet werden und die Intrabeobachterverlässlichkeit (engl.: intra-observer reliability) bestimmt werden (MATTACHINI et al. 2013). Bei mehreren Beobachtern ist es sinnvoll die Übereinstimmung der Datenerfassung mittels Interbeobachterverlässlichkeit (engl.: inter-observer reliability) zu bestimmen (REITER et al. 2018).

Neben Direkt- und Videobeobachtung können Verhaltensdaten für die Evaluation von Monitoringsystemen bzw. ihrer maschinellen Lernmodelle auch mit einem **weiteren Monitoringsystem** gesammelt werden. Beispielsweise validierten PEREIRA et al. (2020) ein Accelerometer-basiertes Monitoringsystem, das am Ohr zur automatisierten Erfassung des Graseverhaltens angebracht wird, anhand eines Drucksensorhalters. WERNER et al. (2019) nutzten das gleiche Drucksensorhalter zur Validierung eines Halsband-basierten Accelerometersystems für die automatisierte Erkennung von Grasen. Das Drucksensorhalter war jeweils bereits in anderen Untersuchungen validiert worden. Auch **tierunabhängige Sensoren** können als Validierungsgrundlage dienen. RUUSKA et al. (2016) nutzten beispielsweise automatisierte Futtertröge, die die Aufenthaltsdauer der Tiere registrieren, um die von einem Drucksensorhalter erfassten Fresszeit zu überprüfen.

#### 2.4. Maschinelle Lernmodelle

Ein maschinelles Lernmodell besteht aus einem Algorithmus, der auf zuvor bestimmte Datenabschnitte (Fenster) angewendet wird und anhand festgelegter statistischer Variablen (Features) eine Entscheidung trifft bzw. eine Klassifizierung vornimmt (RAHMAN et al. 2018; BURKOV 2019). Im Fall von Monitoringsystemen kann diese Klassifizierung eine Verhaltensweise sein. Die Features stehen dabei für Muster in den Sensordaten, die charakteristisch für die verschiedenen Verhaltensweisen sind. Maschinelle Lernmodelle werden im Zusammenhang mit Monitoringsystemen auch im nächsten Schritt, also für die Erkennung der Brunst, der Abkalbung, von Erkrankungen oder Belastungen der Tiergesundheit genutzt. Da diese Umstände zu Verhaltensänderungen führen, sind Features in diesem Kontext Schwellenwerte, anhand denen eine Einteilung in brünstig/nicht brünstig, Abkalbung/keine Abkalbung, krank/nicht krank, belastet/nicht belastet

vorgenommen wird. Auch hier wird ein bestimmter Datenabschnitt, z. B. Tage nach der Abkalbung, betrachtet.

Man unterscheidet bei maschinellen Lernmodellen zwischen überwachtem (supervised) und unüberwachtem (unsupervised) Lernen. Beim überwachten Lernen wird ein Algorithmus anhand eines gelabelten Datensatzes trainiert, ungelabelte Daten anhand bestimmter Kriterien bzw. Muster zu klassifizieren. Beim unüberwachten Lernen identifiziert der Algorithmus die Muster selbständig und teilt die Daten basierend darauf in Klassen ein (DUTTA et al. 2015; BURKOV 2019). Bei Monitoringsystemen wird meist überwachtes Lernen verwendet.

Beim Training eines Lernmodells kann es zu Überanpassung (engl.: overfitting) kommen. Das heißt, der Algorithmus ist zu gut an die Trainingsdaten angepasst und kann mit unbekanntem Daten nicht bzw. nur schlecht umgehen. Zu einer Überanpassung kommt es bei komplexen Modellen, einer hohen Anzahl an Merkmalen und einem kleinen Trainingsdatensatz (BURKOV 2019).

Insgesamt gilt es bei der Erstellung maschineller Lernmodelle, die Kombination aus Algorithmus, Fenstergröße und Features zu finden, die zu einer möglichst genauen Einteilung in die gewünschten Klassen führt und gleichzeitig wenig Rechenleistung für die Klassifizierung benötigt, um die Akkulaufzeit des Monitoringsystems zu verlängern.

#### **2.4.1. Algorithmen**

Ein Algorithmus dient dazu, Sensordaten verschiedenen Verhaltensweisen bzw. Verhaltensänderungen einem bestimmten Zustand (Brunst, Abkalbung, Erkrankung, Belastung) zuzuordnen, also dazu, Daten zu klassifizieren. Die Klassifizierung durch einen Algorithmus kann generell in zwei (binär, engl.: binary) (SMITH et al. 2016) oder in mehrere (engl.: multiclass) (ALSAAOD et al. 2015) Kategorien erfolgen. Eine binäre Klassifizierung benötigt dabei weniger Rechenleistung. Für eine mehrkategoriale Klassifizierung kann die Einteilung in die Klassen entweder bereits durch den Algorithmus selbst erfolgen oder es werden mehrere binäre Algorithmen miteinander kombiniert (MARTISKAINEN et al. 2009; RAHMAN et al. 2016; RAHMAN et al. 2018). Werden verschiedene binäre Algorithmen miteinander kombiniert, ist zu beachten, dass mehrere Algorithmen ihre spezifische Klasse gleichzeitig erkennen können und die endgültige

Entscheidung für eine Klasse, z. B. anhand eines weiteren Algorithmus, geregelt werden muss (SMITH et al. 2016).

Im folgenden Abschnitt werden die wichtigsten, für Monitoringsysteme genutzten Algorithmen, erläutert. Tabelle 6 gibt eine Übersicht über die für die Verhaltenserfassung genutzten Algorithmen. Tabelle 7 gibt eine Übersicht über die für die Erkennung der Brunst, der Abkalbung, von Erkrankungen oder Belastungen genutzten Algorithmen.

Regressionsmodelle werden als Algorithmen zur Verhaltensklassifizierung bei Milchkühen verwendet. Beim **linearen Regressionsmodell** (LiR) wird die lineare Beziehung zwischen verschiedenen Datenmerkmalen genutzt, um eine Vorhersage zu treffen. Dabei gilt es die optimalen Merkmale (Features) der bekannten Daten zu finden, anhand derer eine möglichst genaue Einteilung unbekannter Daten vorgenommen werden kann. Der Abstand der einzelnen Trainingsdatenpunkte von der Regressionsgeraden bzw. -hyperebene soll dabei so gering wie möglich sein (BURKOV 2019). Mit einer **logistischen Regression** (LoR) wird die Wahrscheinlichkeit bestimmt, mit der ein unbekannter Datenpunkt aufgrund eines Merkmals zu einer Klasse gehört (BURKOV 2019). Regressionsmodelle sind einfach interpretierbar und wenig anfällig für eine Überanpassung an die Trainingsdaten, gleichzeitig sind sie im Vergleich zu anderen Algorithmen allerdings weniger flexibel (DREISEITL und OHNO-MACHADO 2002; BURKOV 2019).

Bei der **Diskriminanzanalyse** (DA) wird davon ausgegangen, dass zwei Klassen aufgrund von Merkmalen unterschieden werden können und die Daten innerhalb einer Klasse normalverteilt sind (NIELSEN 2013; DUTTA et al. 2015). Die Diskriminanzanalyse wird auch genutzt, um die Merkmale zu ermitteln, die entscheidend für die Klasseneinteilung sind, um so die Anzahl der für die Einteilung benötigten Merkmale zu reduzieren (DUTTA et al. 2015).

Ein für Monitoringsysteme häufig genutzter Algorithmus ist der **Decision Tree** (DT). Die finale Entscheidung wird hier in mehrere Stufen aufgeteilt (SAFAVIAN und LANDGREBE 1991). In jeder Stufe wird anhand von Features eine Entscheidung getroffen, die wiederum zu einer weiteren Gabelung mit einer Entscheidung führen kann. Die einzelnen Entscheidungsstufen sind dabei meist binär, das heißt an jeder Gabelung erfolgt eine Einteilung in zwei Klassen (DUTTA et al. 2015; GONZÁLEZ

et al. 2015; VÁZQUEZ DIOSDADO et al. 2015). Charakteristika eines DT sind die Tiefe (depth), also die Anzahl der Entscheidungsstufen, und die Höhe (height), also die Klassifizierung mit den meisten vorgeschalteten Entscheidungsstufen (SAFAVIAN und LANDGREBE 1991). Der DT-Algorithmus benötigt wenig Rechenleistung (VÁZQUEZ DIOSDADO et al. 2015) und ist leicht interpretierbar. Auf der anderen Seite ist er instabil und empfindlich gegenüber kleinen Änderungen in den Trainingsdaten (DWYER und HOLTE 2007).

Eine Kombination mehrerer Entscheidungsbäume bezeichnet man als **Random Forest** (RF) (BREIMAN 2001; RIABOFF et al. 2020). Jeder DT entsteht dabei aus einer Teilmenge an Features und führt zu einer Klassifizierung (RAHMAN et al. 2018). Die finale Entscheidung für eine Klasse wird anhand der (gewichteten) Häufigkeit getroffen, mit der eine Klasse als finale Entscheidung aus einem DT resultiert (BONISSONE et al. 2010; RAHMAN et al. 2018; RIABOFF et al. 2020). Charakterisiert wird ein RF durch die Anzahl der DT (RIABOFF et al. 2020), die auch die benötigte Rechenleistung bestimmt (OSHIRO et al. 2012). Der RF-Algorithmus ist im Vergleich zum DT stabiler, benötigt aber mehr Rechenleistung (ALI et al. 2012).

Ein weiterer von Monitoringsystemen genutzter Algorithmus ist die **Support Vector Machine** (SVM)-Methode, bei der Vektoren die Daten anhand von Features in Klassen unterteilen. Die Vektoren bilden dabei Hyperebenen zur Unterteilung der Klassen, die möglichst weit von der Klasse bzw. ihren Datenpunkten entfernt liegen (RIABOFF et al. 2020). Charakteristisch für den SVM-Algorithmus ist der Abstand, den einzelne Datenpunkte einer Klasse zum Vektor bzw. zur Hyperebene haben (HALADJIAN et al. 2018). SVM-Algorithmen können mit komplexen Klassifizierungen umgehen, benötigen dafür allerdings eine hohe Rechenleistung (BENAÏSSA et al. 2017, 2019).

Der **Naive Bayes** (NB)-Algorithmus ordnet Datenpunkte der Klasse zu, zu der sie am wahrscheinlichsten gehören, wobei davon ausgegangen wird, dass die Features, nach denen die Klassen eingeteilt werden, unabhängig voneinander sind (RISH 2001; BENAÏSSA et al. 2019). Die Erstellung eines NB-basierten Modells ist einfach, weshalb der Algorithmus für große Datensätze gut geeignet ist (BENAÏSSA et al. 2017, 2019), aber die Annahme der Feature-Unabhängigkeit führt zu einem Informationsverlust (RISH 2001).

Der **k-nearest neighbour** (KNN)-Algorithmus ist ein nicht-parametrisches Verfahren. Eine bestimmte Anzahl ( $k$ ) an Nachbarn eines Datenpunktes wird betrachtet und der Datenpunkt wird der Klasse zugeordnet, die unter den Nachbarn am häufigsten vorkommt (DUTTA et al. 2015). Der KNN-Algorithmus arbeitet schnell und ist leicht verständlich (BENAISSA et al. 2017), bei einer großen Datenmenge dauert die Zuordnung neuer Datenpunkte aber lange. Da die Zuteilung neuer Datenpunkte auf den Eigenschaften der Trainingsdaten basiert, bleiben diese, anders als bei anderen Algorithmen, im Arbeitsspeicher (BURKOV 2019).

Auch der **K-means** (KM)-Algorithmus ist ein nicht-parametrisches Verfahren. Hierbei werden Datenpunkte anhand ihrer Merkmale in eine bestimmte Anzahl ( $k$ ) an Klassen eingeteilt, die sich durch eine möglichst geringe Überschneidung ihrer Merkmalsausprägung charakterisieren (VÁZQUEZ DIOSDADO et al. 2015). Jeder Klasse wird ein Merkmalsvektor zugeordnet und der Abstand der einzelnen Datenpunkte zu diesem Vektor berechnet. Die Datenpunkte werden dem Vektor neu zugeordnet, dem sie am nächsten sind und aus den Merkmalen der Datenpunkte wird ein neuer Merkmalsvektor berechnet. Der Vorgang wird wiederholt bis keine Neuordnung mehr stattfindet (BURKOV 2019). Der KM-Algorithmus ist einfach strukturiert, die wiederholte Berechnung der Merkmalsvektoren inklusive Neuordnung der Datenpunkte benötigt aber eine hohe Rechenleistung (VÁZQUEZ DIOSDADO et al. 2015).

**Neuronale Netze** (NN) imitieren Eigenschaften des menschlichen Gehirns. Die Knotenpunkte (Neuronen) des Netzwerks sind in Schichten angeordnet. Es gibt eine Eingangsschicht (engl.: input layer), über die Features in das Netzwerk eingebracht werden, eine oder mehrere zwischengeschaltete versteckte Schichten (engl.: hidden layers) und eine Ausgangsschicht (engl.: output layer), die die verschiedenen Klassen liefert (ZAHEDI 1991; CHELOTTI et al. 2018). Die Neuronen in einem neuronalen Netz sind innerhalb einer Schicht oder zwischen den verschiedenen Schichten miteinander verbunden. Eine Verbindung repräsentiert dabei die Aktivität eines Ausgangsneurons, die mit Hilfe einer Funktion aus den Eingangswerten berechnet und basierend auf Schwellenwerten eingeteilt wird. Die Aktivität eines Neurons wirkt auf das nächste Neuron (ZAHEDI 1991). In neuronale Netze in Monitoringsystemen werden Features bzw. Verhaltensänderungen eingebracht, die auf verschiedene Weise miteinander verbunden werden und letztendlich zu einer Vorhersage bzw. Klassifizierung, also einer Verhaltensweise

oder einem das Verhalten beeinflussenden Zustand, führen. Neuronale Netzwerke sind sehr flexibel und können komplexe Problematiken lösen, gleichzeitig sind sie aber anfällig für eine Überanpassung an die Trainingsdaten (DREISEITL und OHNO-MACHADO 2002).

**Tabelle 6: Übersicht über die von Monitoringsystemen für Milchkühe für die Verhaltenserfassung genutzten Algorithmen**

Algorithmus	klassifizierte Verhaltensweisen	Literaturquelle <sup>1</sup>
Logistische Regression	Ruhen vs. Gehen vs. Grasen vs. Wiederkauen vs. Andere	SMITH et al. 2016
Diskriminanzanalyse	Ruhen vs. Grasen vs. Futtersuche vs. Wiederkauen	DUTTA et al. 2015
	Grasen vs. Nicht-Grasen	NIELSEN 2013
Decision Tree	Liegen vs. Stehen vs. Gehen (inkl. Schrittzahl) vs. Aufstehen vs. Ablegen	ALSAAOD et al. 2015
	Wiederkauen vs. Grasen vs. Andere	ANDRIAMANDROSO et al. 2017; CHELOTTI et al. 2020
	Fressen vs. Nicht-Fressen vs. Melken	BARKER et al. 2018
	Grasen: Kauschläge vs. Kaubisse vs. Bisse	CHELOTTI et al. 2018
	Ruhen vs. Grasen vs. Futtersuche vs. Wiederkauen	DUTTA et al. 2015
	Ruhen im Liegen vs. Ruhen im Stehen vs. Gehen vs. Grasen vs. Wiederkauen im Liegen vs. Wiederkauen im Stehen vs. Andere	RIABOFF et al. 2020
	Liegen vs. Stehen vs. Fressen	VÁZQUEZ DIOSDADO et al. 2015
	Aufstehen vs. Ablegen	VÁZQUEZ DIOSDADO et al. 2015
	Fressen vs. Wiederkauen vs. Trinken vs. Andere	ZEHNER et al. 2017

Random Forest	Grasen: Kauschläge vs. Kaubisse vs. Bisse	CHELOTTI et al. 2018
	Stehen vs. Grasen vs. Wiederkauen	RAHMAN et al. 2018
	Ruhen im Liegen vs. Ruhen im Stehen vs. Gehen vs. Grasen vs. Wiederkauen im Liegen vs. Wiederkauen im Stehen vs. Andere	RIABOFF et al. 2020
	Ruhen vs. Gehen vs. Grasen vs. Wiederkauen vs. Andere	SMITH et al. 2016
Support Vector Machine	Liegen vs. Stehen vs. Fressen	VÁZQUEZ DIOSDADO et al. 2015; BENAÏSSA et al. 2017, 2019
	Wiederkauen vs. Nicht-Wiederkauen	HAMILTON et al. 2019
	Liegen vs. Stehen vs. Ablegen vs. Aufstehen vs. Gehen vs. Wiederkauen	MARTISKAINEN et al. 2009
	Ruhen im Liegen vs. Ruhen im Stehen vs. Gehen vs. Grasen vs. Wiederkauen im Liegen vs. Wiederkauen im Stehen vs. Andere	RAHMAN et al. 2016; RIABOFF et al. 2020
	Ruhen vs. Gehen vs. Grasen vs. Wiederkauen vs. Andere	SMITH et al. 2016
Naive Bayes	Liegen vs. Stehen vs. Fressen	BENAÏSSA et al. 2017, 2019
	Ruhen vs. Grasen vs. Futtersuche vs. Wiederkauen	DUTTA et al. 2015
	Ruhen vs. Gehen vs. Grasen vs. Wiederkauen vs. Andere	SMITH et al. 2016
K-nearest neighbour	Liegen vs. Stehen vs. Fressen	BENAÏSSA et al. 2017, 2019
	Ruhen vs. Grasen vs. Futtersuche vs. Wiederkauen	DUTTA et al. 2015
	Ruhen vs. Gehen vs. Grasen vs. Wiederkauen vs. Andere	SMITH et al. 2016
K-means	Liegen rechts vs. Liegen links vs. Stehen vs. Schwanzheben	KRIEGER et al. 2018

	Liegen vs. Stehen vs. Fressen	VÁZQUEZ DIOSDADO et al. 2015
Neuronale Netze	Wiederkauen vs. Grasen	CHELOTTI et al. 2020
	Grasen: Kauschläge vs. Kaubisse vs. Bisse	CHELOTTI et al. 2018

<sup>1</sup>Beispieluntersuchungen, in denen der Algorithmus angewendet und/oder validiert wurde

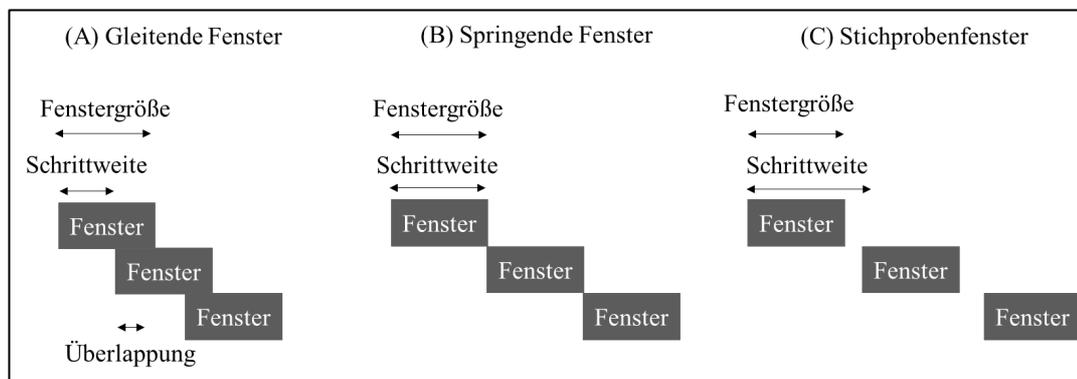
**Tabelle 7: Übersicht über die von Monitoringsystemen für Milchkühe für die Erkennung der Brunst, der Abkalbung, von Erkrankungen oder Belastungen der Tiergesundheit genutzten Algorithmen**

Algorithmus	klassifizierte Zustände	Literaturquelle <sup>1</sup>
Lineare Regression	Brunst vs. keine Brunst	MCGOWAN et al. 2007
	Abkalbung vs. keine Abkalbung	HORVÁTH et al. 2021
Logistische Regression	Lahmheit vs. nicht lahm	BEER et al. 2016; NECHANITZKY et al. 2016
	Brunst vs. keine Brunst	MINEGISHI et al. 2019
Diskriminanz-analyse	Abkalbung vs. keine Abkalbung	BORCHERS et al. 2017
Decision Tree	Lahmheit vs. gesund	KAMPHUIS et al. 2013
	Metritis/Ketose vs. gesund	STEENSELS et al. 2016
Random Forest	Abkalbung vs. keine Abkalbung	BORCHERS et al. 2017
Support Vector Machine	Lahmheit vs. nicht lahm	MARTISKAINEN et al. 2009; HALADJIAN et al. 2018
Neuronale Netze	Abkalbung vs. keine Abkalbung	BORCHERS et al. 2017

<sup>1</sup>Beispieluntersuchungen, in denen der Algorithmus entwickelt und/oder validiert wurde

### 2.4.2. Datenerfassungsfrequenz und Fenstergröße

Für die Erstellung eines maschinellen Lernmodells muss festgelegt werden, auf welchen Teil bzw. Zeitraum der Daten, also welches Datenfenster, der Algorithmus angewendet wird. Ein Fenster wird definiert durch seine Größe. Es wird zwischen verschiedenen Fenstertypen unterschieden (siehe Abbildung 2). Gleitende Fenster (engl.: sliding windows) überlappen, sodass ein Teil der Daten in zwei aufeinanderfolgenden Fenstern enthalten ist. Die Schrittweite ist bei gleitenden Fenstern kleiner als die Fenstergröße. Bei springenden Fenstern (engl.: jumping windows) kommt es zu keiner Überlappung, die Fenster folgen aber direkt aufeinander, sodass die Schrittweite der Fenstergröße entspricht. Fenster können auch stichprobenartig verteilt sein (engl.: sampling windows). Hier ist die Schrittweite größer als die Fenstergröße.



**Abbildung 2: Darstellung der verschiedenen Fenstertypen inklusive ihrer Fenstergröße, Schrittweite und Überlappung**

Neben der Größe und dem Typ der Fenster ist auch die Anzahl an Datenpunkten entscheidend, die in einem Fenster enthalten sind (RAHMAN et al. 2016; RAHMAN et al. 2018). Diese hängt von der Datenerfassungsfrequenz ab. Tabelle 8 gibt einen Überblick über die von in Monitoringsystemen integrierten maschinellen Lernmodellen verwendeten Datenerfassungsfrequenzen, Fenstergrößen und Fenstertypen.

**Tabelle 8: Übersicht über die für Monitoringsysteme genutzten Datenerfassungsfrequenzen und Fenstergrößen zur Erkennung verschiedener Verhaltensweisen**

Fenstergröße [s]	Fenster-typ <sup>1</sup>	Daten-erfassungs-frequenz [Hz]	Klassifizierte Verhaltensweisen	Literaturquelle <sup>2</sup>
1	A	44100	Grasen: Bisse vs. Kauschläge vs. Kaubisse	CHELOTTI et al. 2018
1-60	- <sup>3</sup>	1000	Grasen vs. Wiederkauen vs. Andere	ANDRIAMANDROSO et al. 2017
1,5-30	- <sup>3</sup>	10	Ruhen vs. Gehen vs. Grasens vs. Wiederkauen vs. Andere	SMITH et al. 2016
2-20	- <sup>3</sup>	10	Ruhen vs. Grasens vs. Futtersuche vs. Wiederkauen	DUTTA et al. 2015
10	- <sup>3</sup>	10	Liegen vs. Stehen vs. Ablegen vs. Aufstehen vs. Gehen vs. Fressen vs. Wiederkauen	MARTISKAINEN et al. 2009
10	- <sup>3</sup>	10	Stehen vs. Gehen vs. Grasens vs. Wiederkauen	SCHEIBE und GROMANN 2006
10	- <sup>3</sup>	10	Fressen vs. Wiederkauen vs. Trinken vs. Andere	ZEHNER et al. 2017
20	B	10	Ruhen im Liegen vs. Ruhen im Stehen vs. Gehen vs. Grasens vs. Wiederkauen im Liegen vs. Wiederkauen im Stehen vs. Andere	RAHMAN et al. 2016

20	C	10	Ruhen im Liegen vs. Ruhen im Stehen vs. Gehen vs. Grasen vs. Wiederkauen im Liegen vs. Wiederkauen im Stehen vs. Andere	RAHMAN et al. 2018
60	- <sup>3</sup>	1	Liegen vs. Stehen vs. Fressen	BENAISSA et al. 2017, 2019
60-600	- <sup>3</sup>	44100	Grasen vs. Wiederkauen vs. Andere	CHELOTTI et al. 2020
60-600	- <sup>3</sup>	50	Liegen vs. Stehen vs. Fressen	VÁZQUEZ DIOSDADO et al. 2015
120	A	0,8	Fressen vs. Nicht-Fressen vs. Melken	BARKER et al. 2018
270	- <sup>3</sup>	12,5	Wiederkauen vs. Nicht-Wiederkauen	HAMILTON et al. 2019

<sup>1</sup>Fensterarten: A = gleitendes, B = springendes, C = Stichprobenfenster; <sup>2</sup>Beispieluntersuchungen, in denen die angegebene Kombination aus Fenstergröße, Datenerfassungsfrequenz und Fenstertyp für die Entwicklung/ Validierung eines maschinellen Lernmodells genutzt wurde; <sup>3</sup>Fenstertyp in Quelle nicht angegeben

Werden für die verschiedenen Verhaltensweisen unterschiedliche Fenstergrößen für die binären Algorithmen verwendet, dann muss bei Kombination eine Vereinheitlichung vorgenommen werden (SMITH et al. 2016).

Im Falle der Erkennung der Brunst, der Abkalbung, von Erkrankungen oder Belastungen der Tiergesundheit mit einem Monitoringsystem ist die Fenstergröße dem Zeitintervall gleichzusetzen, das auf eine Verhaltensänderung hin untersucht wird. Dabei wird entweder das Verhalten in einem Zeitraum mit dem eines vorangegangenen Zeitraums verglichen (HOLMAN et al. 2011; CHANVALLON et al. 2014; BORCHERS et al. 2016) oder es wird ein Schwellenwert festgelegt, ab dem die Änderung für eine Alarmmeldung ausreichend ist (HORVÁTH et al. 2021). Eine Übersicht über die für die Erkennung der verschiedenen Zustände mit einem Monitoringsystem betrachteten Zeitintervalle ist in Tabelle 9 gegeben.

**Tabelle 9: Übersicht über die für die Erkennung der Brunst, der Abkalbung, von Erkrankungen und Belastungen der Tiergesundheit mit Monitoringsystemen betrachteten Zeiträume**

betrachtetes Zeitintervall	Vergleichs-zeitraum	klassifizierter Zustand	Literaturquelle <sup>1</sup>
1 Tag	- <sup>2</sup>	Brunst	BRASSEL et al. 2018
1 Tag	10 Tage	Brunst	CHANVALLON et al. 2014
2 h	16 h	Brunst	HOLMAN et al. 2011
1 h	10 d		
3 h	- <sup>2</sup>	Brunst	LØVENDAHL and CHAGUNDA 2010
1 h	5, 10 h	Brunst	MCGOWAN et al. 2007
5 h	5 h		
1 Tag	7 Tage	Brunst	MINEGISHI et al. 2019
6h	6h		
1 Tag	14 Tage	Abkalbung	BORCHERS et al. 2017
8 h	24 h		
1 h	- <sup>2</sup>	Abkalbung	HORVÁTH et al. 2021
2 h	22 h		
6h	6h	Abkalbung	OUELLET et al. 2016
1h	- <sup>2</sup>	Abkalbung	VOß et al. 2021
1 Tag	- <sup>2</sup>	Gesundheitsstörung	STANGAFERRO et al. 2016a, 2016b, 2016c; STEENSELS et al. 2016; BRASSEL et al. 2019
1 Tag	- <sup>2</sup>	Lahmheit	BEER et al. 2016
1 Tag	14 Tage	Lahmheit	KAMPHUIS et al. 2013
12 h	- <sup>2</sup>	Lahmheit	NECHANITZKY et al. 2016

<sup>1</sup>Beispieluntersuchungen, in denen der aufgeführte Zeitraum für die Klassifizierung des Zustands betrachtet wurde; <sup>2</sup>nicht angegeben oder Schwellenwert festgelegt

### 2.4.3. Features

Algorithmen nehmen Klassifizierungen anhand bestimmter Merkmale, Features genannt, vor (BURKOV 2019). Die Features werden aus den festgelegten Fenstern extrahiert bzw. anhand der in einem Fenster enthaltenen Daten berechnet. Von Monitoringsystemen bzw. ihren Algorithmen werden Zeitbereichsfeatures (engl.: time-domain features) und Frequenzbereichsfeatures (engl.: frequency-domain features) genutzt (RAHMAN et al. 2018; BENAÏSSA et al. 2019; RIABOFF et al. 2020). Zu den Zeitbereichsfeatures gehören statistische Metriken, wie z. B. der Mittelwert, der Median, die Standardabweichung, das Minimum und Maximum, die Interquartilsabstände oder auch der Effektivwert (SMITH et al. 2016; RAHMAN et al. 2018; BENAÏSSA et al. 2019). Frequenzbereichsfeatures hingegen berücksichtigen die Periodizität, also das wiederkehrende Muster, der Sensordatenverteilung. Zu ihnen gehören beispielsweise die Spektralenergie oder die Spektralentropie (SMITH et al. 2016; BENAÏSSA et al. 2019).

Bei Sensoren mit mehreren Achsen (Accelerometern, Magnetometern, Gyroskop) können die Features entweder aus Sensordaten einzelner Achsen oder einem zusammengefassten Magnitudenvektor extrahiert werden (SMITH et al. 2016; RIABOFF et al. 2020). Die Zusammenfassung der Achsen sorgt für eine Unabhängigkeit der Features von der Orientierung des Sensors. Da Monitoringsysteme durch die Bewegung der Tiere stetig kleinen Lageänderungen ausgesetzt sind, die bei Orientierungsabhängigkeit die Sensordateninterpretation beeinflussen (BROWN et al. 2013), erhöht die Wahl orientierungsunabhängiger Features die Klassifizierungsgenauigkeit (KAMMINGA et al. 2018).

Die Auswahl der Features kann anhand von Algorithmen vorgenommen werden, die den Einfluss der Features auf die Zielvariable ermitteln (KAMPHUIS et al. 2013; SMITH et al. 2016). Generell ist das Ziel, eine möglichst geringe Anzahl an Features für eine möglichst genaue Klassifizierung zu benötigen. Dadurch reduziert sich die Komplexität des Modells und die Gefahr der Überanpassung (BURKOV 2019).

Sollen Monitoringsysteme Faktoren erkennen, die für Verhaltensänderungen sorgen (die Brunst, die Abkalbung, Erkrankungen oder Belastungen der Tiergesundheit), so stellen Features Schwellenwerte dar. Anhand dieser Schwellenwerte, die Verhaltensdauern, -frequenzen, -periodendauern sein können, klassifiziert der Algorithmus den Zustand des Tieres (brünstig/nicht brünstig,

Abkalbung/keine Abkalbung, krank/gesund, belastet/nicht belastet). Die Klassifizierung kann auf einem Schwellenwert (= einer Verhaltensänderung) (VOß et al. 2021) oder auf mehreren Schwellenwerten (= verschiedenen Änderungen einer Verhaltensweise oder Änderungen verschiedener Verhaltensweisen) (MINEGISHI et al. 2019) basieren. Neben Verhaltensänderungen können auch andere Faktoren, wie das Körpergewicht, die Milchleistung oder die Körpertemperatur als Features in die Erkennung einfließen (KAMPHUIS et al. 2013; OUELLET et al. 2016; STEENSELS et al. 2016). Die Kombination mehrerer Verhaltensweisen bzw. Parameter erhöht dabei die Erkennungsrate (KAMPHUIS et al. 2013; MINEGISHI et al. 2019). Die Änderungen des Verhaltens werden ermittelt, indem das Verhalten des Einzeltieres mit der Herde (dem Herdenmittel) oder mit seinem eigenen Verhalten an den vorangegangenen Tagen verglichen wird (BRASSEL et al. 2018). Wird das Verhalten der Herde mit einbezogen, können Faktoren, die das Verhalten der gesamten Herde beeinflussen (z. B. Umstellungen), herausgerechnet und eine Häufung von Fehlalarmen vermieden werden (ROELOFS et al. 2019). Eine Übersicht über die Features, die von Monitoringsystemen zur Erkennung der ursächlichen Faktoren genutzt werden, findet sich in Tabelle 10.

**Tabelle 10: Übersicht über die zur Erkennung der Brunst, der Abkalbung, von Erkrankungen und Belastungen der Tiergesundheit genutzten Features und ihre Änderung**

Genutzte Features	genutzte Änderung <sup>1</sup>	klassifizierter Zustand	Literaturquelle <sup>2</sup>
Gesamtaktivität Brunstverhalten Liegendauer Grasedauer	↑ ↑ ↓ ↓	Brunst	BRASSEL et al. 2018
Schrittzahl Gesamtaktivität	↑ ↑	Brunst	HOLMAN et al. 2011; CHANVALLON et al. 2014
Gesamtaktivität	↑	Brunst	LØVENDAHL and CHAGUNDA 2010
% aktive Zeit Liegendauer	↑ ↓	Brunst	MCGOWAN et al. 2007
Gesamtaktivität Wiederkaudauer	↑ ↓	Brunst	MINEGISHI et al. 2019

Halsaktivität Schrittzahl Gesamtaktivität Anzahl Liegeperioden Liegedauer Wiederkaudauer	↑ ↑ ↑ ↑ ↓ ↓	Abkalbung	BORCHERS et al. 2017
Schwanzaktivität Wiederkaudauer	↑ ↓	Abkalbung	HORVÁTH et al. 2021
Anzahl Liegeperioden Liegedauer Wiederkaudauer Vaginaltemperatur	↑ ↓ ↓ ↓	Abkalbung	OUELLET et al. 2016
Schwanzheben	↑	Abkalbung	VOß et al. 2021
Liegedauer Gesamtaktivität Grasedauer	↑ ↓ ↓	Gesundheits- störung	BRASSEL et al. 2019
Gesamtaktivität Wiederkaudauer	↓ ↓	Gesundheits- störung	STANGAFERRO et al. 2016a, 2016b, 2016c
Gesamtaktivität Wiederkaudauer Milchleistung Anstieg der Milchleistung Körpergewicht	↑ - - ↓ ↓	Gesundheits- störung	STEENSELS et al. 2016
Gehgeschwindigkeit Fresszeit Anzahl Stehperioden	↓ ↓ ↓	Lahmheit	BEER et al. 2016
Schrittstruktur	-	Lahmheit	HALADJIAN et al. 2018
Körpergewicht Gesamtaktivität Position beim Melken	↓ ↓ ↓	Lahmheit	KAMPHUIS et al. 2013
SD GV <sup>3</sup> Liegedauer	↓	Lahmheit	NECHANITZKY et al. 2016
Struktur Gehverhalten	-	Lahmheit	SCHEIBE und GROMANN 2006

<sup>1</sup>↑ = Zunahme, ↓ = Abnahme; <sup>2</sup>Beispieluntersuchungen, in denen die aufgeführten Features zur Erkennung des Zustands genutzt wurden; <sup>3</sup>Standardabweichung des Gewichts, das auf der weniger belasteten Gliedmaße lastet

## 2.5. Performance von Monitoringsystemen in der Verhaltenserfassung

Die Erfassung verschiedener Verhaltensweisen mit Monitoringsystemen ist die Grundlage für die automatisierte Erkennung der Brunst, der Abkalbung, von Erkrankungen oder Belastungen der Tiergesundheit über die damit verbundenen Verhaltensänderungen.

Auf dem Markt stehen zahlreiche Systeme zur Verfügung, die das Verhalten von Milchkühen erfassen können, von denen aber nur wenige einer Validierung unterzogen wurden. Werden Monitoringsysteme validiert, findet die Untersuchung zum Großteil auf Versuchsbetrieben statt. Meist werden die Systeme anhand von Datensätzen, die unabhängig von den für die Entwicklung der maschinellen Lernmodelle genutzten Daten sind, evaluiert (STYGAR et al. 2021). Monitoringsysteme werden fast ausschließlich in dem Haltungssystem validiert, für das sie entwickelt wurden. Unterscheidet sich die Haltungsumgebung oder werden Haltungsumgebungen kombiniert, variiert auch die Performance der Systeme (ELISCHER et al. 2013; AMBRIZ-VILCHIS et al. 2015; ROMBACH et al. 2018; STYGAR et al. 2021).

Zur Beurteilung der Performance von Monitoringsystemen bzw. ihrer integrierten maschinellen Lernmodelle werden unterschiedliche Messgrößen angewendet. Generell wird die Übereinstimmung zwischen der Vorhersage durch das Modell und der Ground Truth evaluiert (STYGAR et al. 2021). Es lassen sich zwei Formen der Performance-Beurteilung unterscheiden. Zum einen kann betrachtet werden, welche Anzahl bzw. welcher Anteil an Datenpunkten durch das Monitoringsystem richtig oder falsch klassifiziert wird. Dabei werden die Datenpunkte eingeteilt in richtig-positiv (engl.: true positive, TP), richtig-negativ (engl.: true negative, TN), falsch-positiv (engl.: false positive, FP) und falsch-negativ (engl.: false negative, FN). Aus diesen Werten können verschiedene statistische Maße, wie die Sensitivität (auch Recall oder Richtig-Positiv-Rate genannt), die Spezifität (auch Selektivität oder Richtig-Negativ-Rate genannt), der positive Vorhersagewert (auch Präzision genannt) und der negative Vorhersagewert berechnet werden. Daneben gibt es zudem zusammenfassende Maße: Die Genauigkeit fasst den positiven und negativen Vorhersagewert zusammen, der F-Score die Sensitivität und den positiven Vorhersagewert und der relative Messfehler (engl.: relative measurement error, RME) gibt die falsch erfassten Werte in Relation zu den Ground Truth-Werten an. Die genannten Werte werden in der Regel in Prozent angegeben.

Angestrebt wird eine Annäherung an 100 %, außer beim RME, der möglichst nahe Null sein sollte.

Neben der Betrachtung der einzelnen Datenpunkte kann die Performance von Monitoringsystemen auch beurteilt werden, indem die vom System erfassten Verhaltensdauern, -frequenzen und -periodendauern mit den in der Ground Truth beobachteten Parametern verglichen werden und ihre Korrelation in einem festgelegten Zeitraum bestimmt wird. Als Maße werden hier die Korrelationskoeffizienten nach Pearson, Spearman oder Lin, die lineare Regression mit Angabe des Bestimmtheitsmaßes und Cohens Kappa genutzt. Diese Werte werden in der Regel als Dezimalzahlen angegeben und eine Annäherung an Eins wird angestrebt. Für die lineare Regression werden häufig zusätzlich der y-Achsenabschnitt (engl.: Intercept) und die Steigung (engl.: Slope) angegeben. Hier wird eine Annäherung an 0 bzw. 1 angestrebt.

Die folgenden Kapitel geben einen Überblick darüber, wie gut die verschiedenen verfügbaren Systeme die unterschiedlichen Verhaltensweisen im Stall und auf der Weide erkennen.

### **2.5.1. Liegen**

Verschiedene Systeme wurden für die automatisierte Erkennung des Liegeverhaltens entwickelt und validiert. Tabelle 11 gibt einen Überblick über die auf dem Markt erhältlichen Systeme für die automatisierte Erkennung des Liegeverhaltens bei Milchkühen inklusive ihrer in verschiedenen Untersuchungen ermittelten Performance. Neben dem Liegeverhalten können einige Systeme auch einzelne Liegeperioden erkennen. Eine Übersicht über diese Systeme inklusive ihrer Performance findet sich in Tabelle 12. KOK et al. (2015) und MATTACHINI et al. (2013) untersuchten zudem die Erkennung der Liegeperiodendauer. KOK et al. (2015) beobachteten je nach Interboutkriterium eine leichte Über- oder Unterschätzung der Liegeperiodendauer durch das System (IceTag, IceRobotics Ltd., Edinburgh, Schottland). In der Untersuchung von MATTACHINI et al. (2013) erreichte das System (IceQube, IceRobotics Ltd., Edinburgh, Schottland) bei geringer Erfassungsfrequenz einen  $R^2$ -Wert von 0,982 für die Erfassung der Liegeperiodendauer.

**Tabelle 11: Übersicht über erhältliche Systeme zur automatisierten Erfassung des Liegeverhaltens bei Milchkühen und ihre Performance**

Systemname (Firmenname, -sitz)	Sensor <sup>1</sup>	Lok. <sup>2</sup>	Performance <sup>3</sup>	Literaturquelle
Stall				
ADXL330 (Analog Devices, Inc., Wilmington, USA)	A	Hb	Se: 80 PPV: 83 Ge: 84	MARTISKAINEN et al. 2009
AfiAct (Afimilk Agricultural Cooperative Ltd., Kibbutz Afikim, Israel)	A	G	Pe-K: 0,99 CCC: 0,99	BORCHERS et al. 2016
AfiTagII (Afimilk Agricultural Cooperative Ltd., Kibbutz Afikim, Israel)	A	G	Sp-K: 0,98 Sl: 1	HENRIKSEN and MUNKSGAARD 2019
CowScout (GEA Farm Techn., Bonen, Deutschland)	-	G	CCC: 0,996	NIELSEN et al. 2018
HOBO (Onset Computer Coop., Pocasset, USA)	A	G+Hb	Se: 100 PPV: 100	BENAISSA et al. 2019
	A	Hb	Se: 83 PPV: 97	BENAISSA et al. 2019
	A	G	Se: 99,0-99,9 Sp: 99,6-100 PPV: 99,4-100 Pe-K: 0,83-0,93 CCC: 0,81-0,92	LEDGERWOOD et al. 2010; MATTACHINI et al. 2013; BORCHERS et al. 2016; BENAISSA et al. 2019
IceTag (IceRobotics Ltd., Edinburgh, Schottland)	A	G	Se: 99,7 / Sp: 100 PPV: 99,9-100 NPV: 99,8 CCC: 0,99 R <sup>2</sup> : 0,838-1,00	MATTACHINI et al. 2013; NIELSEN et al. 2018
IceQube (IceRobotics Ltd., Edinburgh, Schottland)	A	G	Pe-K: 0,99 CCC: 0,99	BORCHERS et al. 2016
Smarttag (Nedap Livestock Management, Groenlo, Niederlande)	A	G	Pe-K: 0,940-0,986 CCC: 0,969-0,993 Co-K: 0,748-0,838	VAN ERP-VAN DER KOOIJ et al. 2016
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A	G	RME: 0,09	ALSAAOD et al. 2015

Track A Cow (ENGS, Rosh Pina, Israel)	A	G	Pe-K: 0,99 CCC: 0,99	BORCHERS et al. 2016
Weide				
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A	G	Ge: 98,7 Sp-K: 0,99 CCC: 1,00	WERNER et al. 2018

<sup>1</sup>Sensoren: A = Accelerometer; <sup>2</sup>Lokalisierung am Tier: G = Gliedmaße, Hb = Halsband; <sup>3</sup>Performance-Werte: Se = Sensitivität, Sp = Spezifität, PPV = positiver Vorhersagewert, Ge = Genauigkeit, RME = relativer Messfehler, Sp-K = Korrelationskoeffizient nach Spearman, Pe-K = Korrelationskoeffizient nach Pearson, CCC = Korrelationskoeffizient nach Lin, Co-K = Cohens Kappa, Sl = Slope, R<sup>2</sup> = Bestimmtheitsmaß

**Tabelle 12: Übersicht über erhältliche Systeme zur automatisierten Erfassung einzelner Liegeperioden bei Milchkühen und ihre Performance**

Systemname (Firmenname, Firmensitz)	Sensor <sup>1</sup>	Lok. <sup>2</sup>	Performance <sup>3</sup>	Literaturquelle
Stall				
AfiTagII (Afimilk Agricultural Cooperative Ltd., Kibbutz Afikim, Israel)	A	G	PPV: 0,85-0,96	HENRIKSEN and MUNKSGAARD 2019
HOBO (Onset Computer Corporation, Pocasset, USA)	A	G	R <sup>2</sup> :0,80-0,94	LEDGERWOOD et al. 2010
IceTag (IceRobotics Ltd., Edinburgh, Schottland)	A	G	R <sup>2</sup> : 0,052-0,98	MATTACHINI et al. 2013
IceQube (IceRobotics Ltd., Edinburgh, Schottland)	A	G	Se: 99,3 Sp: 97,7 Ge: 99,2	KOK et al. 2015
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A	G	Se: 100	ALSAAOD et al. 2015
Weide				
IceTag (IceRobotics Ltd., Edinburgh, Schottland)	A	G	Se: 100	MCGOWAN et al. 2007

<sup>1</sup>Sensoren: A = Accelerometer; <sup>2</sup>Lokalisierung am Tier: G = Gliedmaße; <sup>3</sup>Performance-Werte: Se = Sensitivität, Sp = Spezifität, PPV = positiver Vorhersagewert, Ge = Genauigkeit, R<sup>2</sup> = Bestimmtheitsmaß

### 2.5.2. Stehen

Das Stehen bei Milchkühen kann mittels verschiedener Monitoringsysteme erkannt werden. Eine Übersicht über die verfügbaren Systeme zur Erfassung des Stehverhaltens bei Milchkühen inklusive ihrer Performance findet sich in Tabelle 13. Auch einzelne Stehperioden können von einigen Systemen erfasst werden. In der Untersuchung von ALSAOD et al. (2015) erkannte ein an der Gliedmaße fixiertes Accelerometer (RumiWatch; ITIN+HOCH GmbH, Liestal, Schweiz) einzelne Stehperioden mit einer Sensitivität von 100 %.

**Tabelle 13: Übersicht über erhältliche Systeme zur automatisierten Erfassung des Stehverhaltens bei Milchkühen und ihre Performance**

Systemname (Firmenname, Firmensitz)	Sensor <sup>1</sup>	Lok. <sup>2</sup>	Performance <sup>3</sup>	Literaturquelle
Stall				
ADXL330 (Analog Devices, Inc., Wilmington, USA)	A	Hb	Se: 80 PPV: 65 Ge: 87	MARTISKAINEN et al. 2009
CowScout (GEA Farm Technologies, Bonen, Deutschland)	-	G	CCC: 0,995	NIELSEN et al. 2018
CowView (GEA Farm Technologies, Bönen, Deutschland)	R	Hb	Se: 0,63 Sp: 0,98 PPV: 0,87 NPV: 0,93 Ge: 0,93	TULLO et al. 2016
HOBO (Onset Computer Corporation, Pocasset, USA)	A	G+Hb	Se: 96 PPV: 96	BENAISSA et al. 2019
	A	Hb	Se: 81 PPV: 68	BENAISSA et al. 2019
	A	G	Se: 76-99,6 Sp: 98,6 PPV: 68-99,0 NPV: 99,4	MATTACHINI et al. 2013; BENAISSA et al. 2019
IceTag (IceRobotics Ltd., Edinburgh, Schottland)	A	G	Se: 96,9-97,7 Sp: 95,1-99,5 PPV: 96,6-99,6 NPV: 95,8-96,7 CCC: 0,999 R <sup>2</sup> : 0,774-0,998	MATTACHINI et al. 2013; NIELSEN et al. 2018

Smarttag (Nedap Livestock Management, Groenlo, Niederlande)	A	G	Pe-K: 0,930-0,981 CCC: 0,963-0,989 Co-K: 0,560-0,562	VAN ERP-VAN DER KOOIJ et al. 2016
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A	G	RME: 4,7	ALSAAOD et al. 2015
Weide				
CSIRO (CSIRO, Canberra, Australien)	A+Ma	Hb	FS: 0,4342-0,874	RAHMAN et al. 2018
CSIRO (CSIRO, Canberra, Australien)	A+Ma	Hf	FS: 0,5096-0,89	RAHMAN et al. 2018
CSIRO (CSIRO, Canberra, Australien)	A+Ma	O	FS: 0,3675-0,86	RAHMAN et al. 2018
RF-Track (RF-Track, Rennes, Frankreich)	A+Ma	Hb	Se: 0,82	RIABOFF et al. 2020
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A+Ma	G	Ge: 96,3 Pe-K: 0,97 CCC: 1,0	WERNER et al. 2018

<sup>1</sup>Sensoren: A = Accelerometer, Ma = Magnetometer, R = Radio Frequency Identification; <sup>2</sup>Lokalisierung am Tier: G = Gliedmaße, Hb = Halsband, Hf = Halfter, O = Ohr; <sup>3</sup>Performance-Werte: Se = Sensitivität, Sp = Spezifität, PPV = positiver Vorhersagewert, NPV = negativer Vorhersagewert, Ge = Genauigkeit, RME = relativer Messfehler, Pe-K = Korrelationskoeffizient nach Pearson, CCC = Korrelationskoeffizient nach Lin, Co-K = Cohens Kappa, R<sup>2</sup> = Bestimmtheitsmaß, FS = F-Score

### 2.5.3. Aufstehen und Ablegen

Auch einzelne Aufsteh- und Ablegevorgänge können von Monitoringsystemen erkannt werden. MARTISKAINEN et al. (2009) ermittelten für ein Halsband-basiertes System (ADXL330, Analog Devices Inc., Wilmington, USA) eine Sensitivität von 71 %, einen positiven Vorhersagewert von 29 % und eine Genauigkeit von 100 % für die Erkennung einzelner Ablege- und Aufstehvorgänge im Stall. Ein von ALSAAOD et al. (2015) im Stall evaluiertes System (RumiWatch, ITIN+HOCH GmbH, Liestal, Schweiz), das an der Gliedmaße befestigt wird, erkannte Aufsteh- und Ablegevorgänge mit einer Sensitivität von 100 %. Zwischen einem anderen Gliedmaßen-basierten System (Smarttag, Nedap Livestock Management, Groenlo, Niederlande) ermittelten VAN ERP-VAN DER KOOIJ et al. (2016) eine

Übereinstimmung mit der Ground Truth von  $r = 0,413$  bis  $0,762$ ,  $CCC = 0,851$  bis  $0,953$  und  $\kappa = 0,817$  bis  $0,85$  für einzelne Aufsteh- und Ablegevorgänge im Stall.

#### 2.5.4. Gehen

Das Gehverhalten, die Schrittzahl, sowie einzelne Gehperioden können von verschiedenen Monitoringsystemen erkannt werden. Tabelle 14 gibt eine Übersicht über die verfügbaren Systeme zur Erfassung des Gehverhaltens bei Milchkühen und Tabelle 15 über die Systeme zur Erfassung der Schrittzahl. Zudem können einzelne Gehperioden detektiert werden. Ein Gliedmaßen-basiertes Accelerometer (RumiWatch, ITIN+HOCH GbmH, Liestal, Schweiz) wurde von ALSAAOD et al. (2015) auf die Erkennung einzelner Gehperioden hin validiert und erkannte diese mit einer Sensitivität von 99 %. Die Schrittlänge und Schrittdauer erkannte das System mit einem RME von 6,65 bzw. 11,92 % (ALSAAOD et al. 2015).

**Tabelle 14: Übersicht über erhältliche Systeme zur automatisierten Erfassung des Gehverhaltens bei Milchkühen und ihre Performance**

Systemname (Firmenname, Firmensitz)	Sensor <sup>1</sup>	Lok. <sup>2</sup>	Performance <sup>3</sup>	Literaturquelle
Stall				
ADXL330 (Analog Devices, Inc., Wilmington, USA)	A	Hb	Se: 79 PPV: 79 Ge: 99	MARTISKAINEN et al. 2009
IceTag (IceRobotics Ltd., Edinburgh, Schottland)	A	G	Se: 26,4-29,1 Sp: 97,9-98,2 PPV: 23,7-30,3 NPV: 98,2	MATTACHINI et al. 2013
CowView (GEA Farm Technologies, Bönen, Deutschland)	R	Hb	Se: 0,78 Sp: 0,97 PPV: 0,53 NPV: 0,99 Ge: 0,96	TULLO et al. 2016
Smarttag (Nedap Livestock Management, Groenlo, Niederlande)	A	G	Pe-K: 0,256 CCC: 0,445-0,503 Co-K: 0,285- 0,372	VAN ERP-VAN DER KOOIJ et al. 2016
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A	G	RME: 17,12	ALSAAOD et al. 2015

Weide				
HMC6343 (Honeywell International Inc., Morristown, USA)	A	Hb	Se: 0,76 PPV: 0,65 FS: 0,7	SMITH et al. 2016
RF-Track (RF-Track, Rennes, Frankreich)	A	Hb	Se: 0,84	RIABOFF et al. 2020
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A	G	Ge: 95,4 Pe-K: 0,78 CCC: 0,92	WERNER et al. 2018

<sup>1</sup>Sensoren: A = Accelerometer, R = Radio Frequency Identification; <sup>2</sup>Lokalisierung am Tier: G = Gliedmaße, Hb = Halsband; <sup>3</sup>Performance-Werte: Se = Sensitivität, Sp = Spezifität, PPV = positiver Vorhersagewert, NPV = negativer Vorhersagewert, Ge = Genauigkeit, RME = relativer Messfehler, Pe-K = Korrelationskoeffizient nach Pearson, CCC = Korrelationskoeffizient nach Lin, Co-K = Cohens Kappa, FS = F-Score

**Tabelle 15: Übersicht über erhältliche Systeme zur automatisierten Erfassung der Schrittzahl bei Milchkühen und ihre Performance**

Systemname (Firmenname, Firmensitz)	Sensor <sup>1</sup>	Lok. <sup>2</sup>	Performance <sup>3</sup>	Literaturquelle
Stall				
CowScout (GEA Farm Technologies, Bonen, Deutschland)	A	G	CCC: 0,679	NIELSEN et al. 2018
IceTag (IceRobotics Ltd., Edinburgh, Schottland)	A	G	CCC: 0,629 R <sup>2</sup> : 0,024-0,765	MATTACHINI et al. 2013 NIELSEN et al. 2018
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A	G	RME: 0,09	ALSAAOD et al. 2015

<sup>1</sup>Sensoren: A = Accelerometer; <sup>2</sup>Lokalisierung am Tier: G = Gliedmaße  
<sup>3</sup>Performance-Werte: RME = relativer Messfehler, CCC = Korrelationskoeffizient nach Lin, R<sup>2</sup> = Bestimmtheitsmaß

### 2.5.5. Fressen

Auch für die automatisierte Erkennung der Futteraufnahme sind Monitoringsysteme erhältlich, deren Performance in verschiedenen Studien evaluiert wurde (Tabelle 16). Einige Systeme erkennen zudem einzelne Fressperioden. MATTACHINI et al. (2016) untersuchten die Erkennung einzelner Fressperioden mit einem Halsband-basierten System (HOB0, Onset Computer Corporation, Pocasset, USA) und ermittelten einen R<sup>2</sup>-Wert von 0,31. In einer

Untersuchung von ALSAOD et al. (2015) erkannte ein an der Gliedmaße befestigter Beschleunigungssensor einzelne Fressperioden mit einer Sensitivität von 99 % und einem RME von 0,09 %. Auch die Erkennung einzelner Kieferbewegungen ist möglich. ZEHNER et al. (2017) evaluierten dafür ein Halfter-basiertes System (RumiWatch, ITIN+Hoch GbmH, Liestal, Schweiz), das mit einer Korrelation von bis zu 0,97 einzelne Kieferbewegungen erkennen konnte.

**Tabelle 16: Übersicht über erhältliche Systeme zur automatisierten Erfassung des Fressverhaltens bei Milchkühen und ihre Performance**

Systemname (Firmenname, Firmensitz)	Sensor <sup>1</sup>	Lok. <sup>2</sup>	Performance <sup>3</sup>	Literaturquelle
Stall				
HOBO (Onset Computer Corporation, Pocasset, USA)	A	G+Hb	Se: 89 PPV: 99	BENAISSA et al. 2019
HOBO (Onset Computer Corporation, Pocasset, USA)	A	Hb	Se: 78,9-96,0 Sp: 93,7 PPV: 81,9-97 NPV: 92,5 Sp-K: 0,9	MATTACHINI et al. 2016; BENAISSA et al. 2019
HOBO (Onset Computer Corporation, Pocasset, USA)	A	G	Se: 81 PPV: 86	BENAISSA et al. 2019
MooMonitor+ (DairyMaster, Co., Kerry, Irland)	A	Hb	Pe-K: 0,93 CCC: 0,8 R <sup>2</sup> : 0,85	GRINTER et al. 2019
Smarttag (Nedap Livestock Management, Groenlo, Niederlande)	A	Hb	Pe-K: 0,801-0,940 CCC: 0,892-0,969 Co-K: 0,403-0,562	VAN ERP-VAN DER KOOIJ et al. 2016
Omnisense (Omnisense Ltd., Elsworth, UK)	A+R	Hb	Se: 74,9 / Sp: 93 PPV: 83,5 Ge: 83,2	BARKER et al. 2018
RumiWatch (ITIN+HOCH GbmH, Liestal, Schweiz)	A+D	Hf	Se: 63-84 Sp: 93-98 PPV: 72,3-92 Ge: 88-92 Sp-K: 0,86-0,96 In: 5,43-13 Sl: 1,01-1,02 R <sup>2</sup> : 0,77	ZEHNER et al. 2017; ROMBACH et al. 2018; STEINMETZ et al. 2020

RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A	G	Se: 99 RME: 0,09	ALSAAD et al. 2015
SensOor (Agis, Harmelen, Niederlande)	A	O	Pe-K: 0,82-0,88 CCC: 0,75-0,88	BIKKER et al. 2014; BORCHERS et al. 2016
Track A Cow (ENGS, Rosh Pina, Israel)	A	G	Pe-K: 0,79 CCC: 0,93	BORCHERS et al. 2016

<sup>1</sup>Sensoren: A = Accelerometer, D = Drucksensor, R = Radio Frequency Identification; <sup>2</sup>Lokalisierung am Tier: G = Gliedmaße, Hb = Halsband, Hf = Halfter, O = Ohr; <sup>3</sup>Performance-Werte: Se = Sensitivität, Sp = Spezifität, PPV = positiver Vorhersagewert, NPV = negativer Vorhersagewert, Ge = Genauigkeit, RME = relativer Messfehler, Sp-K = Korrelationskoeffizient nach Spearman, Pe-K = Korrelationskoeffizient nach Pearson, CCC = Korrelationskoeffizient nach Lin, Co-K = Cohens Kappa, In = Intercept, Sl = Slope, R<sup>2</sup> = Bestimmtheitsmaß

### 2.5.6. Grasen

Gleichermaßen kann auch das Graseverhalten von Milchkühen mit einem Monitoringsystem automatisiert erfasst werden (siehe Tabelle 17). Monitoringsysteme können zudem einzelne Grasebisse erkennen. WERNER et al. 2018 ermittelten einen Korrelationskoeffizienten nach Lin von 0,98 zwischen der mit einem Halfter-basierten System (RumiWatch, ITIN+HOCH GmbH, Liestal, Schweiz) und der mittels Direktbeobachtung erfassten Anzahl an Grasebissen.

**Tabelle 17: Übersicht über erhältliche Systeme zur automatisierten Erfassung des Graseverhaltens bei Milchkühen und ihre Performance**

Systemname (Firmenname, Firmensitz)	Sensor <sup>1</sup>	Lok. <sup>2</sup>	Performance <sup>3</sup>	Literaturquelle
Weide				
CSIRO (CSIRO, Canberra, Australien)	A+Ma	Hb	FS: 0,3596- 0,809	RAHMAN et al. 2018
CSIRO (CSIRO, Canberra, Australien)	A+Ma	Hf	FS: 0,7967- 0,914	RAHMAN et al. 2018
CSIRO (CSIRO, Canberra, Australien)	A+Ma	G	FS: 0,4808- 0,805	RAHMAN et al. 2018
HMC6343 (Honeywell International Inc., Morristown, USA)	A+Ma	Hb	Se: 99 PPV: 97 FS: 0,89	SMITH et al. 2016

IMU (Apple Inc., Cupertino, USA)	A+Ma+ G	Hb	Se: 91,1 Sp: 90,9 PPV: 93,5 Ge: 91,0	ANDRIAMANDROSO et al. 2017
HOBO + IceTag (Onset Computer Corporation, Pocasset, USA; IceRobotics Ltd., Edinburgh, Schottland)	A	Hf + G	Se: 58,5-85,5 Sp: 90,2-93,4 PPV: 85,8-86,8	NIELSEN 2013
HOBO (Onset Computer Corporation, Pocasset, USA)	A	Hf	Se: 58,5-85,5 Sp: 79,9-92,2 PPV: 74,6-83,7	NIELSEN 2013
ICD-PX312 (Sony Corporation of America, New York, USA)	M	Hf	FS: 0,822-0,851	CHELOTTI et al. 2020
MooMonitor+ (Dairymaster, Co., Kerry, Irland)	A	Hb	Sp-K: 0,90-0,94 CCC: 0,95-0,97	WERNER et al. 2019
MPR2400 (Crossbow Technology Inc., Milpitas, USA)	A	Hb	Se: 74 / Sp: 82	OUDSHOORN et al. 2013
RF-Track (RF-Track, Rennes, Frankreich)	A	Hb	Se: 100 Sp: 99	RIABOFF et al. 2020
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A+D	Hf	Ge: 91,5 Sp-K: 0,96 CCC: 0,99 In: 12,2-13,4 Sl: 0,99-1,02	ROMBACH et al. 2018; WERNER et al. 2018
SC-HR (SCR Engineers, Netanya, Israel)	A	Hb	Se: 98 / Sp: 97 PPV: 99 Pe-K: 0,99 CCC: 0,99	MOLFINO et al. 2017
Smartbow (Smartbow GmbH, Weibern, Österreich)	A	O	Se: 92 PPV: 90 Ge: 91	PEREIRA et al. 2020

<sup>1</sup>Sensoren: A = Accelerometer, D = Drucksensor, M = Mikrophon, Ma = Magnetometer, G = Gyroskop; <sup>2</sup>Lokalisierung am Tier: G = Gliedmaße, Hb = Halsband, Hf = Halfter, O = Ohr; <sup>3</sup>Performance-Werte: Se = Sensitivität, Sp = Spezifität, PPV = positiver Vorhersagewert, Ge = Genauigkeit, Sp-K = Korrelationskoeffizient nach Spearman, Pe-K = Korrelationskoeffizient nach Pearson, CCC = Korrelationskoeffizient nach Lin

### 2.5.7. Wiederkauen

Die Wiederkaudauer (siehe Tabelle 18), einzelne Wiederkauperioden (siehe Tabelle 19), sowie einzelne Wiederkauschläge (Tabelle 20) von Milchkühen können von Monitoringsystemen ebenfalls automatisiert erkannt werden.

**Tabelle 18: Übersicht über erhältliche Systeme zur automatisierten Erfassung des Wiederkauverhaltens bei Milchkühen und ihre Performance**

Systemname (Firmenname, Firmensitz)	Sensor <sup>1</sup>	Lok. <sup>2</sup>	Performance <sup>3</sup>	Literaturquelle
Stall				
Hi-Tag (SCR Engineers, Netanya, Israel)	M	Hb	Pe-K: 0,92-0,96 R <sup>2</sup> : 0,86-0,93	SCHIRMANN et al. 2009
MooMonitor+ (Dairymaster, Co., Kerry, Irland)	A	Hb	Pe-K: 0,99 CCC: 0,95 Sl: 0,90 / R <sup>2</sup> : 0,97	GRINTER et al. 2019
Smarttag (Nedap Livestock Management, Groenlo, Niederlande)	A	Hb	Pe-K: 0,807-0,884 CCC: 0,895-0,937 Co-K: 0,470-0,543	VAN ERP-VAN DER KOOIJ et al. 2016
_4	A	P	Se: 89,2 / Sp: 88,8 PPV: 83,2	HAMILTON et al. 2019
Qwes-HR (Lely Ltd., St. Neots, UK)	M	Hb	Sl: 0,74-1,43 R <sup>2</sup> : 0,283-0,976	AMBRIZ-VILCHIS et al. 2015
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A+D	Hf	Se: 90-96 / Sp: 87-98 PPV: 79-95 Ge: 90-95 Sp-K: 0,91-0,96 In: -0,11-1,59 Sl: 0,99-1,00 / R <sup>2</sup> : 0,89	ZEHNER et al. 2017; ROMBACH et al. 2018; STEINMETZ et al. 2020
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A	G	Se: 99 RME: 0,09	ALSAAOD et al. 2015
SensOor (Agis, Harmelen, Niederlande)	A	O	Pe-K: 0,69-1,00 CCC: 0,59-0,93 Co-K: 0,85	BIKKER et al. 2014; BORCHERS et al. 2016
Smartbow (Smartbow GmbH, Weibern, Österreich)	A	O	Pe-K: 0,97-0,99 CCC: 0,96	BORCHERS et al. 2016; REITER et al. 2018

Weide				
CSIRO (CSIRO, Canberra, Australien)	A+Ma	Hb	FS: 0,149-0,913	RAHMAN et al. 2018
CSIRO (CSIRO, Canberra, Australien)	A+Ma	Hf	FS: 0,621-0,932	RAHMAN et al. 2018
CSIRO (CSIRO, Canberra, Australien)	A+Ma	O	FS: 0,1704-0,895	RAHMAN et al. 2018
HMC6343 (Honeywell International Inc., Morristown, USA)	A+Ma	Hb	Se: 88 PPV: 84 FS: 0,86	SMITH et al. 2016
ICD-PX312 (Sony Corporation of America, New York, USA)	M	Hf	FS: 0,453-0,781	CHELOTTI et al. 2020
IMU (Apple Inc., Cupertino, USA)	A+Ma+ G	Hb	Se: 53,1 / Sp: 99,4 PPV: 84,5 Ge: 96,5	ANDRIAMA NDROSO et al. 2017
MooMonitor+ (Dairymaster, Co., Kerry, Irland)	A	Hb	Sp-K: 0,93-0,97 CCC: 0,98	WERNER et al. 2019
Qwes-HR (Lely Ltd., St. Neots, UK)	M	Hb	Sl: 0,57	AMBRIZ- VILCHIS et al. 2015
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A+D	Hf	Ge: 94,3 Sp-K: 0,98 CCC: 0,99 In: -0,64-12,2 Sl: 1,00-1,01	ROMBACH et al. 2018; WERNER et al. 2018
SC-HR (SCR Engineers, Netanya, Israel)	A	Hb	Se: 87 / Sp: 98 PPV: 91 Pe-K: 0,8 CCC: 0,99	MOLFINO et al. 2017

<sup>1</sup>Sensoren: A = Accelerometer, D = Drucksensor, M = Mikrophon, Ma = Magnetometer, G = Gyroskop; <sup>2</sup>Lokalisierung am Tier: G = Gliedmaße, Hb = Halsband, Hf = Halfter, O = Ohr, P = Pansen; <sup>3</sup>Performance-Werte: Se = Sensitivität, Sp = Spezifität, PPV = positiver Vorhersagewert, Ge = Genauigkeit, RME = relativer Messfehler, Sp-K = Korrelationskoeffizient nach Spearman, Pe-K = Korrelationskoeffizient nach Pearson, CCC = Korrelationskoeffizient nach Lin, Co-K = Cohens Kappa, In = Intercept, Sl = Slope, R<sup>2</sup> = Bestimmtheitsmaß, FS = F-Score; <sup>4</sup>nicht angegeben

**Tabelle 19: Übersicht über erhältliche Systeme zur automatisierten Erfassung einzelner Wiederkauperioden bei Milchkühen und ihre Performance**

Systemname (Firmenname, Firmensitz)	Sensor <sup>1</sup>	Lok. <sup>2</sup>	Performance <sup>3</sup>	Literaturquelle
Stall				
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A	G	Se: 99 RME: 0,09	ALSAOD et al. 2015
Smartbow (Smartbow GmbH, Weibern, Österreich)	A	O	Pe-K: 0,99	REITER et al. 2018
Weide				
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A+D	Hf	Se: 99	WERNER et al. 2018

<sup>1</sup>Sensoren: A = Accelerometer, D = Drucksensor, <sup>2</sup>Lokalisierung am Tier: G = Gliedmaße, Hf = Halfter, O = Ohr; <sup>3</sup>Performance-Werte: Se = Sensitivität, RME = relativer Messfehler, Pe-K = Korrelationskoeffizient nach Pearson

**Tabelle 20: Übersicht über erhältliche Systeme zur automatisierten Erfassung einzelner Wiederkauschläge bei Milchkühen und ihre Performance**

Systemname (Firmenname, Firmensitz)	Sensor <sup>1</sup>	Lok. <sup>2</sup>	Performance <sup>3</sup>	Literaturquelle
Stall				
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A+D	Hf	Sp-K: 0,92-0,97 In: -1,51-0,21 Sl: 0,99-1,01 R <sup>2</sup> : 0,94	ZEHNER et al. 2017; ROMBACH et al. 2018; STEINMETZ et al. 2020
Weide				
RumiWatch (ITIN+HOCH GmbH, Liestal, Schweiz)	A+D	Hf	CCC: 1,00 In: -0,27-15,8 Sl: 0,99-1,01	ROMBACH et al. 2018; WERNER et al. 2018

<sup>1</sup>Sensoren: A = Accelerometer, D = Drucksensor; <sup>2</sup>Lokalisierung am Tier: Hf = Halfter; <sup>3</sup>Performance-Werte: Sp-K = Korrelationskoeffizient nach Spearman, CCC = Korrelationskoeffizient nach Lin, In = Intercept, Sl = Slope, R<sup>2</sup> = Bestimmtheitsmaß

### 2.5.8. Trinken

Auch die Erfassung des Trinkverhaltens mit Hilfe eines Monitoringsystems wurde in verschiedenen Untersuchungen evaluiert. ZEHNER et al. (2017) und STEINMETZ et al. (2020) validierten die automatisierte Erkennung des Trinkverhaltens von

Milchkühen mit einem Halfter-basierten System (RumiWatch, ITIN+Hoch GmbH, Liestal, Schweiz). Die Sensitivität des Systems lag dabei bei 14 bis 28 %, die Spezifität bei 99 bis 100 %, der positive Vorhersagewert bei 22 bis 55 % und die Genauigkeit bei 98 bis 99 % (ZEHNER et al. 2017; STEINMETZ et al. 2020). Beim Vergleich der mit dem System ermittelten Trinkzeit ermittelten ZEHNER et al. (2017) einen Korrelationskoeffizienten von 0,42 bis 0,78 zwischen dem System und Direktbeobachtung.

## **2.6. Performance von Monitoringsystemen in der Erfassung von Ursachen für Verhaltensänderungen bei Milchkühen**

Über die Erfassung verschiedener Verhaltensweisen und ihrer Änderungen können die Brunst, die Abkalbung und Erkrankungen, sowie Belastungssituationen für die Tiergesundheit erkannt werden. Die Performance von Monitoringsystemen wird beurteilt, indem die Anzahl der vom System erkannten Ereignisse mit den tatsächlich aufgetretenen Ereignissen (Ground Truth) verglichen wird. Erkennt das System ein Ereignis, gibt es eine Warnmeldung aus. Diese können in TP und FP-Meldungen eingeteilt werden. Wird keine Warnmeldung gegeben, ist das entweder TN oder FN. Aus diesen vier Werten können wie bei der Erkennung der Verhaltensweisen die Sensitivität, die Spezifität, der positive und negative Vorhersagewert, die Falscherkennungsrate, sowie die Genauigkeit und der F-Score berechnet werden (siehe auch Kapitel 2.5). Bei der Erkennung der verschiedenen Verhaltensveränderungen hervorrufenden Faktoren wird häufig auch die Grenzwertoptimierungskurve (engl.: receiver operating characteristics (ROC) curve), welche die Sensitivität und die Falsch-Positiv-Rate kombiniert, berechnet. Als Gütekriterium wird dabei die Fläche unter der Kurve (engl.: area under the curve, AUC) angegeben.

### **2.6.1. Brunst**

Zur Bestätigung der Brunst als Ground Truth dient die visuelle Beobachtung von Brunstsymptomen, der Blut- oder Milchprogesterongehalt und der Zustand von Ovarien und Uterus im transrektalen Ultraschall (BRASSEL et al. 2018). Auch die Bestätigung der Trächtigkeit kann als Bestätigung herangezogen werden (SCHWEINZER et al. 2019). Tabelle 21 gibt eine Übersicht über die auf dem Markt verfügbaren Monitoringsysteme zur Brunsterkennung bei Milchkühen inklusive ihrer Performancewerte.

**Tabelle 21: Übersicht über die auf dem Markt erhältlichen Monitoringsysteme zur Brunsterkennung inklusive ihrer Performance**

Systemname (Firmenname, Firmensitz)	Performance <sup>1</sup>				Literaturquelle Validierung
	Se	Sp	PPV	FDR	
AfiTag PM (Afimilk Agricultural Cooperative Ltd., Kibbutz Afikim, Israel)	71		71		CHANVALLON et al. 2014
	63		74		HOLMAN et al. 2011
Alpro (DeLaval, Tumba, Schweden)	56-84 <sup>2</sup>				LØVENDAHL and CHAGUNDA 2010
Heatime-RuminAct (SCR Engineers, Netanya, Israel)	62		84		CHANVALLON et al. 2014
Heatime activity (SCR Engineers, Netanya, Israel)	59		94		HOLMAN et al. 2011
HeatPhone (Medria Solutions, Saint-Lô, Frankreich)	61		87		CHANVALLON et al. 2014
HerdInsights (Alanya Ltd., Cork, Irland)	93		72		BRASSEL et al. 2018
HR-LD Tag mit hohem Schwellenwert (SCR Engineers, Netanya, Israel)	51-91 <sup>3</sup>	96-99 <sup>3</sup>	21-81 <sup>3</sup>		MINEGISHI et al. 2019
HR-LD Tag mit niedrigem Schwellenwert (SCR Engineers, Netanya, Israel)	79-97 <sup>3</sup>	75-90 <sup>3</sup>	12-26 <sup>3</sup>		MINEGISHI et al. 2019
IceTag mit Activity24/10-Algorithmus (IceRobotics Ltd., Edinburgh, Schottland)	84			22	MCGOWAN et al. 2007
IceTag mit Activity24/5-Algorithmus (IceRobotics Ltd., Edinburgh, Schottland)	76			13	MCGOWAN et al. 2007
Smartbow (Smartbow GmbH, Weibern, Österreich)	97				SCHWEINZER et al. 2019
smaXtec (SmaXtec animal care GmbH, Graz, Österreich)	81		74		ROELOFS et al. 2019

<sup>1</sup>Se = Sensitivität, Sp = Spezifität, PPV = Positiver Vorhersagewert, FDR = Falscherkennungsrate; <sup>2</sup>verschiedene Schwellenwerte für die Erkennung angewendet; <sup>3</sup>Validierung in unterschiedlichen Haltungssystemen und zu unterschiedlichen Jahreszeiten

### 2.6.2. Abkalbung

Auch zur Erkennung der Abkalbung werden Monitoringsysteme eingesetzt. Als Bestätigung der Abkalbung wird hier der Beginn der Aufweitungphase (VOß et al. 2021) oder die abgeschlossene Austreibungsphase (HORVÁTH et al. 2021) genutzt. Tabelle 22 gibt eine Übersicht über die auf dem Markt erhältlichen Monitoringsysteme zur Erkennung der Abkalbung inklusive ihrer Performancewerte.

**Tabelle 22: Übersicht über die auf dem Markt erhältlichen Monitoringsysteme zur Erkennung der Abkalbung inklusive ihrer Performance**

Systemname (Firmenname, Firmensitz)	Performance <sup>1</sup>					Literaturquelle Validierung
	Se	Sp	PPV	NPV	AUC	
HR Tag (SCR Engineers, Netanya, Israel)	0-25 <sup>2</sup>	96-99 <sup>2</sup>	0-40 <sup>2</sup>	92-94 <sup>2</sup>		BORCHERS et al. 2017
IceQube (IceRobotics Ltd., Edinburgh, Schottland)	38-75 <sup>2</sup>	88-91 <sup>2</sup>	23-43 <sup>2</sup>	94-98 <sup>2</sup>		BORCHERS et al. 2017
HR Tag + IceQube (IceRobotics Ltd., Edinburgh, Schottland)	25- 100 <sup>2</sup>	87-93 <sup>2</sup>	17-50 <sup>2</sup>	93- 100 <sup>2</sup>		BORCHERS et al. 2017
Moocall (Moocall Ltd., Dublin, Irland)			13			HORVÁTH et al. 2021
Moocall – Meldung 1 <sup>3</sup> (Moocall Ltd., Dublin, Irland)	19 – 43 – 66 – 69 – 75 <sup>5</sup>	96 – 96 – 89 – 74 – 63 <sup>5</sup>	9 – 21 – 34 – 44 – 56 <sup>5</sup>	98 – 97 – 97 – 89 – 79 <sup>5</sup>		VOß et al. 2021
Moocall – Meldung 2 <sup>4</sup> (Moocall Ltd., Dublin, Irland)	19 – 39 – 47 – 50 – 53 <sup>5</sup>	98 – 97 – 94 – 87 – 82 <sup>5</sup>	17 – 35 – 43 – 52 – 65 <sup>5</sup>	98 – 97 – 95 – 86 – 73 <sup>5</sup>		
SensOor (Agis, Harmelen, Niederlande)	51 – 52 – 68 <sup>6</sup>	51 – 55 – 63 <sup>6</sup>	27 – 15 - 11 6	75 – 88 - 95 <sup>6</sup>	0,5 – 0,6 – 0,7 <sup>6</sup>	OUELLET et al. 2016
Pendant G (Onset Computer Corporation, Bourne, USA)	58 – 52 – 58 <sup>6</sup>	58 – 54 – 61 <sup>6</sup>	34 – 15 – 10 <sup>6</sup>	79 – 88 – 95 <sup>6</sup>	0,6 – 0,6 – 0,6 <sup>6</sup>	

SensOor + Pendant G (Agis, Harmelen, Niederlande; Onset Computer Corporation, Bourne, USA)	57 – 57 – 71 <sup>6</sup>	57 – 57 – 71 <sup>6</sup>	33 – 18 – 16 <sup>6</sup>	78 – 89 – 97 <sup>6</sup>	0,6 – 0,6 – 0,7 <sup>6</sup>	
---	---------------------------------	---------------------------------	---------------------------------	---------------------------------	------------------------------------	--

<sup>1</sup>Se = Sensitivität, Sp = Spezifität, PPV = Positiver Vorhersagewert, NPV = Negativer Vorhersagewert, AUC = Fläche unter der Kurve; <sup>2</sup>unterschiedliche Algorithmen; <sup>3</sup>1h Schwanzaktivität erhöht; <sup>4</sup>2h Schwanzaktivität erhöht; <sup>5</sup>Performance 1h – 2h – 4h – 12h – 24h vor Beginn der Aufweitungphase; <sup>6</sup>Performance 24h – 12 h – 6 h vor Ende der Austreibungsphase

Eine Ergänzung der Verhaltensdaten um weitere Parameter kann die Erkennung verbessern. OUELLET et al. (2016) kombinierten beispielsweise die Verhaltensdaten zweier Systeme (SensOor und Pendant G; Agis, Harmelen, Niederlande und Onset Computer Corporation, Bourne, USA) mit den von einem Thermometer gemessenen Vaginaltemperatur und konnten damit die Performance des Erkennungsmodells verbessern.

### 2.6.3. Erkrankungen

Erkrankungen führen zu Verhaltensänderungen, die mit einem Monitoringsystem erfasst werden können. In verschiedenen Untersuchungen wurde die Performance von Monitoringsystemen in der Erkennung von Erkrankungen – im Speziellen von peripartalen Gesundheitsstörungen, Lahmheiten und Mastitis – getestet. In Untersuchungen zur Erkennung von Erkrankungen, wie peripartalen Gesundheitsstörungen und Mastitis, stellen die Befunde einer klinischen Untersuchung die Ground Truth dar. Je nach erfasster Erkrankung wurden verschiedene Kriterien festgelegt (siehe Tabelle 23).

**Tabelle 23: Kriterien, nach denen peripartale Gesundheitsstörungen in der Ground Truth für die Validierung von Monitoringsystemen definiert wurden**

Erkrankung	Kriterien	Literaturquelle
Ketose	KetoStix-Ergebnis: >1470 µmol/dl bzw. 15 mg/dl Acetoacetat	STEENSELS et al. 2016
	Inappetenz, KetoStix-Ergebnis ≥ moderat	STANGAFERRO et al. 2016a
Labmagenverlagerung	Ping-Geräusch rechts/links bei der Perkussionsauskultation	STANGAFERRO et al. 2016a

Mastitis	geschwollenes/schmerzhaftes Euter, Veränderungen an Milch ± Abgeschlagenheit, Anorexie, Fieber	STANGAFERRO et al. 2016b
Metritis	wässriger, stinkender, dunkler Ausfluss ± Fieber	STANGAFERRO et al. 2016c; STEENSELS et al. 2016
Milchfieber	Hypothermie, Muskelzittern, Festliegen	STANGAFERRO et al. 2016a
Nachgeburtverhalten	fehlender Abgang der Fetalmembranen innerhalb von 24 h nach Abkalbung	STANGAFERRO et al. 2016a
Verdauungsstörung	geringe Kotmenge, Inappetenz	STANGAFERRO et al. 2016a

Monitoringsysteme erkennen **Gesundheitsstörungen** unterschiedlich gut. STEENSELS et al. (2016) untersuchten die kombinierte Erkennung von Metritis und Ketose mit einem Monitoringsystem (SC HR, SCR Ltd, Netanya, Israel), das die Aktivität und Wiederkaudauer für die Detektion heranzieht. Neben den Verhaltensparametern wurden zudem die Milchleistung, die Änderung des Körpergewichts und der Milchleistungsanstieg seit Abkalbung in das Modell integriert. Das Modell erzielte einen AUC-Wert von 0,78. Abhängig von der Parität erkannte das Modell Metritis und Ketose mit einer Sensitivität, einer Spezifität und einer Genauigkeit von 85, 80 und 82 % (Tiere in zweiter Parität) bzw. 76, 93 und 84 % (Tiere mit einer Parität  $\geq 3$ ). STANGAFERRO et al. (2016b) untersuchten das gleiche System, integrierten in das Erkennungsmodell keine weiteren Parameter. Für Erkrankungen des Stoffwechsels und des Verdauungsapparates erzielte das Modell eine Sensitivität von 94 %. Die Sensitivität variierte zwischen den verschiedenen Erkrankungen von 89 (Ketose) bis 100 % (Labmagenverlagerung) (STANGAFERRO et al. 2016a). Eine Mastitis erkannte das Modell mit einer Sensitivität von 55 %, wobei sich die Performance zwischen den verschiedenen Erregern unterschied (STANGAFERRO et al. 2016b). Eine Metritis wurde vom Modell mit einer Sensitivität von 53 % erkannt (STANGAFERRO et al. 2016c). Insgesamt war die Erkennungsrate höher, wenn zwei Erkrankungen gleichzeitig auftraten (STANGAFERRO et al. 2016b, 2016c). Die Erkennung über das Modell erfolgte 0,4 (Mastitis) bis 3,2 Tage (Labmagenverlagerung) vor der klinischen Diagnose (STANGAFERRO et al. 2016a, 2016b, 2016c).

Zur Validierung von Monitoringsystemen zur automatisierten Erkennung von **Lahmheiten** wird häufig der Lahmheitsscore (MARTISKAINEN et al. 2009; KAMPHUIS et al. 2013; BEER et al. 2016) bzw. eine Kombination aus Lahmheitsscore und klinischen Befunden an der Klaue (NECHANITZKY et al. 2016) als Referenz genommen. HALADJIAN et al. (2018) induzierten lahmes Gehen, indem sie eine Klaue mit einem Klauenklotz versahen. Insgesamt werden starke Lahmheiten besser erkannt als weniger ausgeprägte Lahmheiten (KAMPHUIS et al. 2013). Tabelle 24 gibt eine Übersicht über die Performance, die auf dem Markt erhältliche Systeme bei der Erkennung von Lahmheiten erreichen.

**Tabelle 24: Übersicht über die auf dem Markt erhältlichen Monitoringsysteme zur Erkennung von Lahmheiten inklusive ihrer Performance**

Systemname (Firmenname, Firmensitz)	Performance <sup>1</sup>					Literaturquelle Validierung
	Se	Sp	Ge	PPV	AUC	
ADXL330 (Analog Devices, Inc., Wilmington, USA)	65		98	66		MARTISKAINEN et al. 2009
Afikim (Afikim, Kibbutz Afikim, Israel)	26	80 <sup>2</sup>			0,61	KAMPHUIS et al. 2013
	14	90 <sup>2</sup>				
IMU <sup>3</sup> (Apple Inc., Cupertino, USA)	63- 83 <sup>4</sup>	82- 98 <sup>4</sup>	81- 97 <sup>4</sup>			HALADJIAN et al. 2018
RumiWatch Halfter + Pedometer (ITIN+HOCH GmbH, Liestal, Schweiz)	93	92			0,96	BEER et al. 2016
RumiWatch Pedometer – Stehzeit (ITIN+HOCH GmbH, Liestal, Schweiz)	75	70			0,71	NECHANITZKY et al. 2016
RumiWatch Pedometer – Liegezeit (ITIN+HOCH GmbH, Liestal, Schweiz)	78	60			0,71	

<sup>1</sup>Se = Sensitivität, Sp = Spezifität, Ge = Genauigkeit, PPV = Positiver Vorhersagewert, AUC = Fläche unter der Kurve; <sup>2</sup>gesetzte Werte; <sup>3</sup>Inertial Measurement Unit; <sup>4</sup>verschiedene Tiere

Die Kombination von Verhaltensparametern mit weiteren Parametern verbessert die Lahmheitserkennung. KAMPHUIS et al. (2013) kombinierten die Aktivitätsdaten eines Pedometers (Afikim, Kibbutz Afikim, Israel) mit der Veränderung des Lebendgewichts und der Position in der Melkreihenfolge, was den AUC-Wert von 0,61 auf 0,74 und die Sensitivität von 26 auf 50 (bei gesetzter Spezifität von 80 %) bzw. von 14 auf 29 (bei gesetzter Spezifität von 90%). NECHANITZKY et al. (2016) fanden die höchsten Performance-Werte für eine Kombination aus Liegedauer, erfasst mit einem Pedometer (RumiWatch, ITIN+HOCH GmbH, Liestal, Schweiz) und der Standardabweichung des Gewichts, das auf der weniger belastete Gliedmaße lastet (Sensitivität: 94 %, Spezifität: 80%, AUC: 0,86).

### 3. Hitzebelastung

#### 3.1. Mechanismen der Thermoregulation bei Milchkühen

Milchkühe besitzen eine thermoindifferente Zone, in der ihre Körperkerntemperatur ohne Energieaufwand unverändert bleibt. Darüber und darunter liegt die thermoneutrale Zone, in der die Tiere ihre Körperkerntemperatur mittels Wärmeproduktion und Wärmeabgabe konstant halten (BIANCA 1976; HILDEBRANDT et al. 2021) und das Maximum ihrer Leistung mit minimalem metabolischem Aufwand erbringen können (IGONO et al. 1992). Unterhalb des unteren und oberhalb des oberen kritischen Schwellenwerts können die Tiere ihre Körpertemperatur nicht mehr konstant halten und es kommt zur Hypo- bzw. Hyperthermie (BIANCA 1976). Die untere Grenze der thermoneutralen Zone wird je nach Produktionslevel mit -12 bis 2 °C (HAMADA 1971; ANGRECKA und HERBUT 2016), die obere Grenze mit 16 bis 18 °C Außentemperatur (BRÜGEMANN 2012; HAMMAMI et al. 2013) angegeben, wobei neben der Temperatur auch die Luftfeuchte, die Windgeschwindigkeit und die Solarstrahlung (siehe Kapitel 3.4), sowie tierindividuelle Faktoren (siehe Kapitel 3.2) für die Entstehung einer Hitzebelastung eine Rolle spielen.

##### 3.1.1. Körpertemperatur

Die physiologische Körperkerntemperatur wird mit einem Thermometer bestimmt und beträgt bei einer Milchkuh rektal gemessen 38,2 bis 38,9 °C (KIM et al. 2010; BURFEIND et al. 2012; GARNER et al. 2017). Die **rektale** Messung besitzt eine hohe Wiederholbarkeit, je nach Eindringtiefe des Thermometers können aber unterschiedliche Werte gemessen werden (BURFEIND et al. 2010). Neben der Messung im Rektum, kann die Körpertemperatur auch **vaginal** bestimmt werden. Die vaginal gemessene physiologische Körperkerntemperatur wird mit 38,8 bis 38,9 °C angegeben (BURFEIND et al. 2012; GARNER et al. 2017). Diese Messmethode wird häufig für eine kontinuierliche Messung über einen längeren Zeitraum verwendet. Mit Hilfe einer Vaginalspange wird ein Temperaturdatenlogger in der Vaginalhöhle platziert und misst dort in regelmäßigen Abständen die Temperatur (ALLEN et al. 2015; YAN et al. 2020). VICKERS et al. (2010) konnten keinen signifikanten Unterschied zwischen der vaginal und der rektal erfassten Körpertemperatur feststellen, während BURFEIND et al. (2012) zwar eine hohe Korrelation zwischen der vaginal und rektal

gemessenen Temperatur beobachteten, die vaginal gemessene Temperatur aber geringfügig höher lag.

Über einen Pansenbolus kann zudem die **Vormagentemperatur** bestimmt werden. Hier liegt der ermittelte physiologische Wert bei 38,7 bis 38,9 °C (BEWLEY et al. 2008; AMMER et al. 2016; STONE et al. 2017). Bei dieser Messstelle ist zu beachten, dass Trinkvorgänge die Temperatur temporär senken und abhängig von der Wassertemperatur erst nach zwei Stunden die Ausgangstemperatur wieder erreicht ist (BEWLEY et al. 2008). SUTHAR et al. (2013) ermittelten dennoch eine hohe Übereinstimmung zwischen der vaginal und der ruminal gemessenen Temperatur.

Auch die **Oberflächentemperatur** der Tiere kann bestimmt werden. Hierzu dienen Infrarotthermometer (PENG et al. 2019; YAN et al. 2020) oder Wärmebildkameras (JORQUERA-CHAVEZ et al. 2019). Gemessen wird die Oberflächentemperatur an der Flanke, am Hals, am Euter, an der Wange, auf der Stirn oder am Auge, wobei sie sich je nach Lokalisation unterscheidet (ZÄHNER et al. 2004; GARNER et al. 2017; JORQUERA-CHAVEZ et al. 2019; PENG et al. 2019). Die Oberflächentemperatur hängt stark von den herrschenden Umweltbedingungen ab und ist daher hoch variabel (PENG et al. 2019). So liegt sie beispielsweise durch die fehlende Solarstrahlung nachts niedriger als tagsüber (ZÄHNER et al. 2004).

Insgesamt unterliegt die physiologische Körperkerntemperatur von Milchkühen unter thermoneutralen Bedingungen tageszeitlichen Schwankungen mit höheren Temperaturen am Nachmittag und Abend und niedrigeren Temperaturen in der Nacht und am Morgen (WEBSTER et al. 2008; KENDALL und WEBSTER 2009). Die Konstanzhaltung der Körpertemperatur ist ein Zusammenspiel aus Wärmeproduktion und Wärmeabgabe. Um die Körpertemperatur im physiologischen Bereich zu halten, können die einzelnen Faktoren der Wärmeproduktion und der Wärmeabgabe variiert werden. Übersteigt die Wärmeproduktion die Wärmeabgabe, kommt es zu einer Erhöhung der Körpertemperatur (SORIANI et al. 2013; VAN LAER et al. 2015), die sich z. B. auch in einer Erhöhung der Milchttemperatur widerspiegelt (WEST 2003).

### 3.1.2. Wärmeproduktion

Wärme wird im Körper einer Milchkuh hauptsächlich durch die Futterverwertung produziert (SUZUKI et al. 2014; HILDEBRANDT et al. 2021). Um die

Wärmeproduktion unter Hitzebelastung zu verringern, reduzieren Milchkühe ihre Futteraufnahme (GARNER et al. 2017). Die Wärmeproduktion in Milchkühen hängt zudem von ihrer Milchleistung ab. Je höher die Milchleistung, desto höher die Wärmeproduktion, was zum einen auf die erhöhte Futteraufnahme, aber auch auf die Entstehung von Wärme bei der Milchbildung selber zurückzuführen ist (PURWANTO et al. 1990). Auch beim Wiederkauen entsteht durch die Aktivität der Kaumuskulatur und der Speichelproduktion Wärme (SUZUKI et al. 2014), weshalb Milchkühe unter Hitzebelastung eine reduzierte Wiederkaudauer zeigen (SORIANI et al. 2013). Zudem wird auch durch die Muskeltätigkeit beim Gehen Wärme produziert (SCHÜTZ et al. 2011).

### 3.1.3. Wärmeabgabe

Ein weiterer Baustein in der Thermoregulation ist die Wärmeabgabe. Steigt die Wärmebelastung, so wird die Wärmeabgabe über verschiedene Mechanismen gesteigert. Bei der Wärmeabgabe unterscheidet man die trockene von der feuchten Abgabeform. Zur trockenen Wärmeabgabe gehören die Radiation, die Konduktion und die Konvektion. Die feuchte Wärmeabgabe bezeichnet man als Evaporation (HILDEBRANDT et al. 2021).

Bei der **Radiation** wird die Wärme in Form von Wärmestrahlung an die Umgebung abgegeben (HILDEBRANDT et al. 2021). Das wird bei Milchkühen anhand der unter Hitzebelastung steigenden Oberflächentemperatur deutlich (GARNER et al. 2017). Bei dieser Form der Wärmeabgabe ist die Oberfläche, die für die Wärmeabgabe zur Verfügung steht, entscheidend. Im Stehen ist eine größere Oberfläche für die Wärmeabgabe verfügbar, weshalb Milchkühe unter Hitzebelastung ihre Stehzeit auf Kosten der Liegezeit erhöhen. Die gesteigerte Wärmeabgabe im Stehen zeigt sich durch ein Absinken der Körpertemperatur und der Atemfrequenz, wenn die Tiere aufstehen (HILLMAN et al. 2005; ALLEN et al. 2015; ATKINS et al. 2018; NORDLUND et al. 2019).

Bei der **Konduktion** findet bei direktem Kontakt mit einem unbewegten Medium eine Wärmeübertragung statt. Hierbei kommt es auf die Wärmeleitfähigkeit des Mediums, den Temperaturunterschied zwischen Tierkörper und Medium, sowie die Größe der Kontaktfläche an (HILDEBRANDT et al. 2021). Konduktive Wärmeabgabe erfolgt bei Milchkühen beispielsweise im Liegen mit der Liegeoberfläche. Bei steigenden Temperaturen bevorzugen Milchkühe daher Liegeoberflächen, die eine

höhere konduktive Wärmeabgabe erlauben (PALO et al. 2006) und gekühlte Liegeoberflächen reduzieren die Körpertemperatur hitzebelasteter Kühe (ORTIZ et al. 2015). SOUSA et al. (2021) zeigten, dass Milchkühe auf der Weide das Aufsuchen von Schatten von der Oberflächentemperatur des Bodens abhängig machen.

Bei der **Konvektion** bewegt sich ein Medium über den Körper des Tieres hinweg und nimmt Wärme auf. Durch die Bewegung bleibt der Temperaturunterschied zwischen Tierkörper und Medium bestehen (HILDEBRANDT et al. 2021). Im Fall von Milchkühen ist das bewegte Medium in der Regel die Luft. Der Grad der Wärmeabgabe hängt von der Geschwindigkeit der Luftbewegung, der Temperatur der Luft, sowie der Ausrichtung des Tierkörpers zur Windrichtung ab (GEBREMEDHIN 1987; BERMAN 2005). Auch die Oberfläche, auf die die Bewegung wirken kann, ist entscheidend, weshalb Milchkühe unter Hitzebelastung vermehrt Stehen, statt zu Liegen (ALLEN et al. 2015). Im Stehen ist die Körperoberfläche zur konvektiven Wärmeabgabe größer, was sich in einer Reduktion der Körpertemperatur und der Atemfrequenz im Stehen zeigt (HILLMAN et al. 2005; ALLEN et al. 2015; ATKINS et al. 2018; NORDLUND et al. 2019). Zudem richten sich die Tiere unter Hitzebelastung parallel zum Wind aus (LEE und HILLMAN 2007).

Insgesamt hängt die Fähigkeit zur trockenen Wärmeabgabe von der Dicke der unter der Haut gelegenen Fettschicht, sowie der Dicke des Fells ab, die als Isolation zum Schutz vor Auskühlung dienen, gleichzeitig aber die Wärmeabgabe behindern (GEBREMEDHIN 1987; HILDEBRANDT et al. 2021). Zudem spielt die Herzfrequenz eine Rolle, da diese den Wärmetransport zwischen Haut und Körper beeinflusst (PURWANTO et al. 1990). Die Herzfrequenz ist unter Hitzebelastung erhöht (VIZZOTTO et al. 2015).

Neben der trockenen Wärmeabgabe kann überschüssige Wärme auch **evaporativ** (= feucht) abgegeben werden. Bei dieser effektiven, aber energiebedürftigen Abgabeform wird der Kühlungseffekt der Verdunstung genutzt. Evaporative Wärmeabgabe erfolgt bei der Milchkuh vor allem über die Atemluft. Die Anfeuchtung trockener Atemluft stellt eine Verdunstung dar, die dem Körper Wärme entzieht (HILDEBRANDT et al. 2021). Um die evaporative Wärmeabgabe über die Atemluft zu erhöhen, steigern Milchkühe unter Hitzebelastung ihre Atemfrequenz (BERMAN 2005; GARNER et al. 2017). Die Steigerung der

Atemfrequenz kann bis zum Hecheln gehen (LEES et al. 2018). Die Erhöhung der Atemfrequenz stellt die erste beobachtete Reaktion auf eine Hitzebelastung dar und ist ein effektives Mittel zur Konstanthaltung der Körpertemperatur (MCMANUS et al. 2014). Zur evaporativen Wärmeabgabe gehört zudem das Schwitzen, was bei Milchkühen periodisch gezeigt wird (GEBREMEDHIN et al. 2010). Die Schwitzrate steigt mit zunehmenden Temperaturen (BERMAN 2005) und hängt dabei vor allem von der Hauttemperatur ab (GEBREMEDHIN et al. 2010). Bei der evaporativen Wärmeabgabe spielt der Feuchtigkeitsgradient zwischen Atemluft bzw. Haut und der Umgebungsluft eine große Rolle. Eine hohe Luftfeuchte reduziert die Schwitzrate im Vergleich zu trockener Luft bei gleichbleibender Temperatur (GEBREMEDHIN et al. 2010) und die Atemfrequenz steigert sich bei steigenden Temperaturen bei hoher Luftfeuchtigkeit deutlicher als bei niedriger Luftfeuchtigkeit (BERMAN 2005). Luftbewegung steigert durch Abtransport der Feuchtigkeit den Gradienten, sodass bei höheren Windgeschwindigkeiten die Schwitzrate höher und die Atemfrequenz niedriger ist (BERMAN 2005). BLACK und KRAWCZEL (2016) beobachteten unter Hitzebelastung auf der Weide einen deutlicheren Anstieg der Atemfrequenz als im Stall. Durch die evaporative Wärmeabgabe erhöht sich der Wasserverlust der Tiere, was über eine gesteigerte Wasseraufnahme mit zunehmender Temperatur kompensiert wird (MEYER et al. 2004; GORNIK et al. 2014).

### **3.2. Messung einer Hitzebelastung über den Anstieg von Kortisolwerten**

Extreme Witterungsbedingungen und der damit steigende Anspruch an die Thermoregulationsmechanismen im Tierkörper stellen eine Belastungssituation dar. Um auf die Belastung zu reagieren bzw. nötige Anpassungen vorzunehmen, reagiert der Körper mit einer Veränderung des Hormonhaushalts (KLEINE und ROSSMANITH 2021). Im Rahmen dieser Änderungen kommt es zu einer Aktivierung der Hypothalamus-Hypophysen-Nebennieren-Achse. Im Hypothalamus wird zunächst, angeregt durch Katecholamine, die Freisetzung des Kortikotropin-Releasing-Hormons (CRH) gesteigert. CRH erhöht im Gehirn die Aufmerksamkeit und unterdrückt die Nahrungsaufnahme und das Sexualverhalten (KLEINE und ROSSMANITH 2021). Zudem fördert es in der Hypophyse die Freisetzung des adrenokortikotropen Hormons (ACTH), was wiederum die Ausschüttung von Kortisol aus der Nebennierenrinde anregt (HILDEBRANDT et al. 2021; KLEINE und ROSSMANITH 2021). Kortisol wirkt fördernd auf die Gluconeogenese und die

Fettmobilisation, wodurch es zu einem Anstieg des Glukosespiegels, sowie von freien Fettsäuren im Blut kommt. Diese dienen dem Körper als Energielieferanten, um mit der belastenden Situation umgehen zu können (HILDEBRANDT et al. 2021). Auf der anderen Seite wirkt Kortisol hemmend auf das Immunsystem (HILDEBRANDT et al. 2021; KLEINE und ROSSMANITH 2021).

Kortisol wird im Körper zu verschiedenen Kortisolmetaboliten abgebaut und nach unterschiedlichen Verzögerungszeiten über den Harn, den Kot, die Milch oder den Speichel ausgeschieden (PALME et al. 2005). Auch in den Haaren lagert sich Kortisol ab (BURNETT et al. 2014). Die Messung des Gehalts an Kortisol bzw. seiner Metaboliten im Blut bzw. den Körperflüssigkeiten, über die sie ausgeschieden werden, dient der Bestimmung einer Belastungssituation (PALME et al. 2005; PALME 2012). Unabhängig von der Messmethode schwankt der Basalkortisolgehalt zwischen den Tieren enorm (PALME et al. 1999), weshalb bei einem Vergleich verschiedener Kortisolwerte das Tier selbst als Referenz genutzt werden sollte (REES et al. 2016).

Im **Blutplasma** kann die Zirkulation von Kortisol bzw. seiner Metaboliten unmittelbar nachgewiesen werden (PALME et al. 1999). Der Plasmakortisolspiegel unterliegt allerdings tageszeitlichen Schwankungen mit einer erhöhten Ausscheidung am Morgen und einem Tief am Abend (HILDEBRANDT et al. 2021; KLEINE und ROSSMANITH 2021). Zudem kann insbesondere die wiederholte Blutabnahme selbst zur Erhöhung des Plasmakortisolgehalts führen (HOPSTER et al. 1999) und die gemessenen Werte so verfälschen. Dennoch konnten CHEN et al. (2018) bei Milchkühen unter Hitzebelastung einen Anstieg des Plasmakortisolspiegels feststellen.

Im **Speichel** erhöht sich die Kortisolkonzentration im Vergleich zum Blutplasma mit einer Verzögerung von zehn Minuten, weshalb diese Messmethode als Nachweis für akuten Stress gut geeignet ist (HERNANDEZ et al. 2014). Die Entnahme von Speichelproben ist bei Tieren aber sehr aufwändig (SHERIFF et al. 2011). KOVÁCS et al. (2019) entnahmen Speichelproben bei Milchkühen mit einem Wattetupfer und stellten bei der Analyse der Kortisolmetaboliten fest, dass Tiere, denen bei einer Hitzebelastung Schattenplätze zur Verfügung stehen, einen geringeren Kortisolmetabolitengehalt aufweisen.

Die Messung des in den **Haaren** abgelagerten Kortisols stellt eine nicht-invasive und leicht umsetzbare Methode dar. Allerdings gibt es, basierend auf Untersuchungen bei anderen Tierspezies, Hinweise darauf, dass der in den Haaren gemessene Kortisolwert durch lokal produziertes Kortisol variiert (KECKEIS et al. 2012). Zudem hängt der gemessene Kortisolwert bei Milchkühen von der für die Probennahme gewählten Körperstelle ab. Am Schwanz entnommene Proben weisen einen höheren Kortisolgehalt als im Schulterbereich gewonnene Proben auf (BURNETT et al. 2014). GHASSEMI NEJAD et al. (2017) nutzten den Haarkortisolgehalt von Milchkühen zum Nachweis, dass Tiere mit weißem Fell weniger von einer Hitzebelastung betroffen sind als Tiere mit schwarzem Fell.

Auch die Bestimmung des Kortisolgehalts in der **Milch** ist nicht-invasiv und kann im Rahmen der Melkroutine durchgeführt werden. Der Kortisolgehalt in der Milch hängt allerdings von der Rasse (SGORLON et al. 2015) und dem Gehalt an somatischen Zellen (GYGAX et al. 2006) ab. Zudem spiegelt sich die tageszeitliche Schwankung des Kortisolspiegels im Plasma auch in der Milch wider (GYGAX et al. 2006). ZÄHNER et al. (2004) und VEISSIER et al. (2018) bestätigten die tageszeitlichen Schwankungen, konnten aber über den Milchkortisolgehalt am Abend dennoch eine Belastung der Tiere durch die Witterung nachweisen.

Im **Urin** werden Schwankungen des Plasmakortisolgehalts mit einer Verzögerung von einer Stunde sichtbar, sodass sich diese Messmethode zur Bestimmung kurz- und mittelfristiger Belastungssituationen eignet (PALME et al. 1996; MORROW et al. 2000). Logistisch ist die Probennahme aber schwierig, insbesondere da die Urinausscheidung über den Tag verteilt stark schwankt (SHERIFF et al. 2011) und unter Hitzebelastung reduziert ist (EL-NOUTY et al. 1980).

Die Entnahme von **Kotproben** für den Nachweis von Kortisol ist nicht-invasiv und kann aufgrund der Passagezeit zeitverzögert zur Belastungssituation erfolgen (PALME 2012). Die Verzögerungszeit zwischen Plasmakortisol und Kot beträgt 9 bis 10 Stunden (PALME et al. 1999; PESENHOFER et al. 2006). Abhängig davon, ob eine akute oder länger anhaltende Belastungssituation gemessen werden soll, muss die Häufigkeit der Probennahme angepasst werden (PALME 2012). VEISSIER et al. (2018) entnahmen Milchkühen einmal täglich nach dem Morgenmelken eine Kotprobe zur Kortisolmetabolitenanalyse und beobachteten einen Anstieg an Tagen mit belastenden Witterungsbedingungen. REES et al. (2016) ermittelten einen

Anstieg der Kotkortisolmetaboliten unter Hitzebelastung sowohl im Vergleich der Tiere untereinander, als auch im Vergleich der Tiere mit sich selbst.

### 3.3. Folgen einer Hitzebelastung

Eine Belastung durch hohe Temperaturen hat zahlreiche Folgen für die Leistung, die Tiergesundheit und das Tierwohl von Milchkühen. Die Regulation des Wärmehaushalts kostet Energie. Dennoch reduzieren hitzebelastete Tiere über die Ausschüttung von Kortisol, die hemmend auf das Appetitzentrum wirkt, die Futtermittelaufnahme, um die mit der Futtermittelverwertung verbundene Wärmeproduktion zu reduzieren (HILDEBRANDT et al. 2021; KLEINE und ROSSMANITH 2021). Der vermehrte Energiebedarf in Kombination mit einer reduzierten Energiezufuhr, resultiert in einer Mobilisation von Energiereserven aus Körperfett und Skelettmuskulatur, was in einer Zunahme der nicht-veresterten Fettsäuren (engl.: non-esterified fatty acids, NEFA), von  $\beta$ -Hydroxybutyrat, sowie des Kreatiningehalts im Blut resultiert (SHEHAB-EL-DEEN et al. 2010; SORIANI et al. 2013; VAN LAER et al. 2015; GARNER et al. 2017). Eine Hitzebelastung versetzt Tiere in eine ungünstige metabolische Lage (SHEHAB-EL-DEEN et al. 2010; WHEELOCK et al. 2010).

Die gesenkte Futtermittelaufnahme und der erhöhte Nährstoff- und Energiebedarf für die Thermoregulation führen zu einer Reduktion der **Milchleistung**, die verzögert gezeigt werden kann und nach Ende der Belastung noch einige Tage andauert (VAN LAER et al. 2015; GARNER et al. 2017; WILDRIDGE et al. 2018; GANTNER et al. 2019). Neben der Milchleistung sinkt auch der **Milchfett- und Milchproteingehalt** (WHEELOCK et al. 2010; VAN LAER et al. 2015). BRÜGEMANN (2012) beobachtete zum Teil einen Anstieg des Milchfett- und Milchproteinanteils, was sie auf die starke Reduktion der Milchleistung zurückführte. Auch der **Milchlaktosegehalt** sinkt unter Hitzebelastung (WHEELOCK et al. 2010). Eine Hitzebelastung führt über einen längeren Zeitraum zu einer Abnahme des **Körpergewichts** (HILLMAN et al. 2005).

Die ungünstige metabolische Lage in Kombination mit einer hemmenden Wirkung von Kortisol auf das Immunsystem, steigern die Prävalenz von metabolischen Gesundheitsstörungen und Infektionen bei Tieren mit einer Hitzebelastung (DAS et al. 2016; HILDEBRANDT et al. 2021). So zeigen hitzebelastete Tiere häufiger eine **Pansenazidose** und je nachdem, in welcher Phase der Laktation die Hitzebelastung

einwirkt, auch eine erhöhte Prävalenz für eine **Ketose** (GANTNER et al. 2016). Eine Hitzebelastung steigert das Risiko für eine **Mastitis**, insbesondere verursacht durch tierassoziierte Erreger (VITALI et al. 2020). SANDERS et al. (2009) beobachteten ein gehäuftes Auftreten von **Klauenerkrankungen** in den Sommermonaten.

Auch auf die Reproduktionsleistung von Milchkühen wirkt die Hitzebelastung. So senkt eine Hitzebelastung die **Konzeptionsrate** von Milchkühen (SCHÜLLER et al. 2014). Der Effekt ist dabei unabhängig vom Zeitraum in Relation zum Tag der Brunst; am empfindlichsten sind die Tiere aber in den drei Wochen unmittelbar vor der Brunst. Die herabgesetzte Konzeptionsrate wird verursacht durch eine Kombination aus reduzierter Brunstdauer und -intensität (AKBAR et al. 2020) und einem verringerten Follikelwachstum (AGUIAR et al. 2020). Sind Milchkühe in der späten Phase der Trächtigkeit einer Hitzebelastung ausgesetzt, so reduziert sich das **Geburtsgewicht** der Kälber, die **Qualität des Kolostrums** und die Milchleistung ist in der Folgelaktation gesenkt (KARIMI et al. 2015).

Die herabgesetzte Leistung und die erhöhte Anfälligkeit für Erkrankungen machen eine Hitzebelastung zu einem wirtschaftlich hoch relevanten Thema (WANKAR et al. 2021). Gleichzeitig ist die mit einer Hitzebelastung verbundene Beeinträchtigung des Tierwohls von großer Bedeutung (POLSKY and KEYSERLINGK 2017).

### 3.4. Indices zur Definition einer Hitzebelastung

#### 3.4.1. Indices

Dass die Temperatur (RAGSDALE et al. 1950), und bei hohen Temperaturen auch die Luftfeuchte (RAGSDALE et al. 1953), einen Einfluss auf Milchkühe und ihre Leistung haben, ist schon lange Bestandteil der Forschung. Um die Entstehung bzw. den Schweregrad einer Hitzebelastung anhand der herrschenden Witterungsbedingungen zu beschreiben, wurden über die Zeit zahlreiche Indices entwickelt. Die Indices basieren auf dem von THOM (1958, 1959) für den Mensch entwickelten Discomfort Index (DI), auch **Temperature Humidity Index** (THI) genannt, der sich aus der gewichteten Trocken- und Feuchtkugeltemperatur zusammensetzt (siehe Tabelle 25). Die Trockenkugeltemperatur (engl.: dry-bulb temperature, DBT) stellt die Lufttemperatur frei von Einwirkungen von Luftfeuchte und Sonneneinstrahlung dar, während die Feuchtkugeltemperatur (engl.: wet-bulb

temperature, WBT) die tiefste durch Verdunstungskälte erreichbare Temperatur repräsentiert. Die WBT kann unter der Lufttemperatur liegen und hängt von der Luftfeuchte ab, bezieht diese also mit ein. BERRY et al. (1964) evaluierten die Anwendung des DI auf den witterungsbedingten Leistungsrückgang von Milchkühen und stellten fest, dass der Index, nach einer leichten Anpassung der Gewichtung, geeignet ist den Leistungsrückgang darzustellen (siehe Tabelle 25). Während die bisher genannten Indices mit Temperaturen in Grad Fahrenheit arbeiteten, stellte das NATIONAL RESEARCH COUNCIL (1971) einen THI auf, der die Temperatur in Grad Celsius berücksichtigt.

BRODY et al. (1954), STEWART und BRODY (1954) und LEE und HILLMAN (2007) stellten fest, dass sowohl im Stall als auch auf der Weide, die Windgeschwindigkeit und die Solarstrahlung einen Einfluss auf die Entwicklung einer Hitzebelastung bei Milchkühen haben. Wind sorgt über eine Erhöhung der konvektiven Wärmeabgabe für eine Reduktion der Hitzebelastung (HILDEBRANDT et al. 2021). Die Solarstrahlung erhöht die Hauttemperatur. Die an der Haut entstehende Wärme wird von der Oberfläche zum Körperkern transportiert, dessen Temperatur sich zeitverzögert erhöht (GEBREMEDHIN et al. 2010). BUFFINGTON et al. (1981) berücksichtigten die Windgeschwindigkeit und die Solarstrahlung, indem sie statt der DBT die Schwarzkugeltemperatur (engl.: black-globe temperature, BGT) berücksichtigten und den **Black Globe Humidity Index** (BGHI) aufstellten (siehe Tabelle 25). Dieser Index integriert zudem statt der WBT die Taupunkttemperatur (engl.: dew-point temperature), welche die Temperatur ist, die für die Wasserkondensation unterschritten werden muss. Die relative Luftfeuchte beträgt an diesem Punkt 100 %. BUFFINGTON et al. (1981) zeigten, dass der BGHI den Leistungsrückgang, die Erhöhung der Atemfrequenz und der Rektaltemperatur als Folgen der Witterung bei Milchkühen auf der Weide besser darstellen kann als der THI.

Auch MADER et al. (2006) passten den THI an und integrierten die Windgeschwindigkeit und die Solarstrahlung. Grundlage bzw. Referenz für die Aufstellung des **adjusted THI** (THIadj) war in dieser Studie der Hechelscore von Maststieren. Je ein THIadj für Stunden- und Tagesmittelwerte wurde aufgestellt (siehe Tabelle 25). YAN et al. (2020) testeten neben anderen Indices die Eignung des THIadj für die Beurteilung einer Hitzebelastung bei Milchkühen im Stall und ermittelten signifikante Korrelationen mit der Atemfrequenz, der

Vaginaltemperatur und der an verschiedenen Stellen gemessenen Oberflächentemperatur für Milchkühe im Stall. Währenddessen korrelierten der THI und BGHI lediglich mit der Vaginal- und Oberflächentemperatur (YAN et al. 2020).

GAUGHAN et al. (2008) stellten anhand des Hechelscores von Mastrindern einen **Heat Load Index** (HLI) auf. Da GAUGHAN et al. (2008) ab einer BGT von 25 °C einen signifikanten Anstieg des Hechelscores beobachteten, wurden zwei HLI-Formeln in Abhängigkeit von der BGT aufgestellt (siehe Tabelle 25). YAN et al. (2020) überprüften neben dem THIadj und anderen Indices auch den HLI auf seine Eignung zur Hitzebelastungseinschätzung bei Milchkühen im Stall. Dabei beobachteten sie zwar einen signifikanten Zusammenhang des HLI mit der an verschiedenen Stellen gemessenen Oberflächentemperatur, mit der Atemfrequenz und der Vaginaltemperatur korrelierte der HLI aber im Gegensatz zum THIadj nicht. SILVA et al. (2007) evaluierten den HLI bei Milchkühen auf der Weide und stellten anders als beim BGHI und THI eine signifikante Korrelation mit der Rektaltemperatur und der Atemfrequenz fest.

Die bisher aufgeführten Indices stellen nur eine Momentaufnahme oder Tagesmittelwerte dar, berücksichtigen aber weder die Dauer der Hitzebelastung noch den Abkühleffekt kühlerer Nachtstunden (KIM et al. 2010; GALÁN et al. 2018). Besteht über einen längeren Zeitraum eine Hitzebelastung, akkumuliert sich diese (HEINICKE et al. 2019). Das Auftreten kühler Stunden hingegen minimiert die Belastung (IGONO et al. 1992). Abhängig von der Fähigkeit der Tiere, die überschüssige entstehende Wärme an die Umgebung abzugeben, ermittelten GAUGHAN et al. (2008) Schwellenwerte und stellten anhand des HLI und der ermittelten Schwellenwerte zwei Formeln auf, um die **akkumulierte Hitzebelastung** (engl.: accumulated heat load, AHL) zu ermitteln (siehe Tabelle 25).

Um eine breitere Temperaturspanne abzudecken, entwickelten MADER et al. (2010) den **Comprehensive Climate Index** (CCI), der die gemessene Umgebungstemperatur um je einen Faktor für den THI, die Windgeschwindigkeit und die Solarstrahlung korrigiert (siehe Tabelle 25). Die Korrekturfaktoren integrieren die jahreszeitlich bedingten Unterschiede der drei Parameter, sodass der CCI in einem Temperaturbereich von -30 bis 45 °C einsetzbar ist (MADER et al.

2010). Als Referenzwerte dienten hier wie beim THIadj der Hechelscore sowie die TM-Aufnahme von Mastrindern. YAN et al. (2020) evaluierten den CCI für Milchkühe im Stall im Vergleich zu anderen Indices und beobachteten wie beim THIadj eine signifikante Korrelation mit der Atemfrequenz, der Vaginaltemperatur und der an verschiedenen Stellen gemessenen Oberflächentemperatur. ARIAS et al. (2021) stellten eine positive Korrelation zwischen CCI und Vaginaltemperatur für Milchkühe auf der Weide fest.

Einen auf eine breitere Temperaturspanne anwendbaren Index entwickelten auch LEES et al. (2018) mit dem **Dairy Heat Load Index (DHLI)**, der speziell für Milchkühe aufgestellt wurde (siehe Tabelle 25). Als Referenz diente hierfür die von GAUGHAN et al. (2008) und MADER et al. (2010) angewendeten Hechelscore-Kategorien. Der DHLI ist auf eine Temperaturspanne von -2,5 bis 60 °C, sowie eine Luftfeuchtigkeit von 0 bis 100 % anwendbar. Ji et al. (2020a) ermittelten keine Verbesserung der Einschätzung einer Hitzebelastung anhand des Milchleistungsabfalls bzw. des Milchtemperaturanstiegs durch den DHLI gegenüber anderen Indices (BGHI, HLI).

Auch WANG et al. (2018) entwickelten einen Index zur Einschätzung einer Hitzebelastung speziell für Milchkühe und zwar den **Equivalent Temperature Index for dairy cattle (ETIC)** (siehe Tabelle 25). Der ETIC besteht aus der Summe verschiedener, um die jeweiligen Witterungseinflüsse (Luftfeuchte, Windgeschwindigkeit und Solarstrahlung) korrigierter Temperaturen. YAN et al. (2020) ermittelten einen signifikanten Zusammenhang des ETIC mit der Vaginaltemperatur, nicht aber mit der Atemfrequenz. Gegenüber anderen Indices (BGHI, HLI) stellten Ji et al. (2020a) keine Verbesserung der Hitzebelastungseinschätzung fest.

Insgesamt wird bei Untersuchungen zur Hitzebelastung bei Milchkühen am häufigsten der THI betrachtet, wobei Indices, die die Solarstrahlung und die Windgeschwindigkeit mit einbeziehen, insbesondere auf der Weide, das Belastungsgeschehen besser abbilden (GALÁN et al. 2018).

**Tabelle 25: Formeln zur Berechnung der verschiedenen Witterungsindices, die zur Einschätzung der Hitzebelastung von Milchkühen Anwendung finden**

Indexformel <sup>1</sup>	Literaturquelle
$DI = 0,4 \times (DBT + WBT) + 15$	THOM 1959
$ALR = 3,009 + NL \times (6,404 - 0,08008 \times DBT - 0,1005 \times WBT + 0,001281 \times DBT \times WBT)$	BERRY et al. 1964
$THI = (1,8 \times DBT + 32) - (0,55 - 0,0055 \times RH) \times (1,8 \times DBT - 26)$	NATIONAL RESEARCH COUNCIL 1971
$BGHI = BGT + 0,36 \times DPT + 41,5$	BUFFINGTON et al. 1981
$THI_{adj} (h) = 4,51 + THI - (1,992 \times WS) + (0,0068 \times RAD)$	MADER et al. 2006
$THI_{adj} (d) = 6,8 + THI - (3,075 \times WS) + (0,0114 \times RAD)$	MADER et al. 2006
$CCI = T + THI \text{ CF} + WS \text{ CF} + RAD \text{ CF}$	MADER et al. 2010
$HLI_{BGT > 25^\circ C} = 8,62 + (0,38 \times RH) + (1,55 \times BGT) - (0,5 \times WS) + [e^{2,4 \times WS}]$ $HLI_{BGT < 25^\circ C} = 10,66 + (0,28 \times RH) + (1,3 \times BGT) - WS$	GAUGHAN et al. 2008
$AHL_{HLI_{acc} < 77} = (HLI_{acc} - HLI_{Lower \text{ Threshold}}) / M$ $AHL_{HLI_{acc} > 86} = (HLI_{acc} - HLI_{Upper \text{ Threshold}}) / M$	GAUGHAN et al. 2008
$DHLI = \frac{\left( \frac{1,681813}{(1 + e^{-(-8,50749 + 0,206159 + BGT + 4,088399 \times RH)})} \right)^{-0,0002}}{1,6812 - 0,0002} \times 100$	LEES et al. 2018
$ETIC = T + 0,0038 \times T \times (100 - RH) - 0,1173 \times WS^{0,707} \times (39,20 - T) + 1,86 \times 10^{-4} \times T \times RAD$	WANG et al. 2018

<sup>1</sup>DI = Discomfort Index, DBT = dry-bulb temperature, WBT = wet-bulb temperature, ALR = absoluter Leistungsrückgang, NL = Normalleistung, THI = Temperature-Humidity-Index, RH = relative Luftfeuchte, BGHI = Black-Globe-Humidity-Index, DPT = dew-point temperature, THI<sub>adj</sub> (h) = angepasster THI für Stundenmittelwerte, THI<sub>adj</sub> (d) = angepasster THI für Tagesmittelwerte, WS = Windgeschwindigkeit, RAD = Solarstrahlung, CCI = Comprehensive Climate Index, T = Umgebungstemperatur, CF = Korrekturfaktor, HLI = Heat Load Index, AHL = akkumulierte Hitzebelastung, M = Anzahl der Messungen pro Stunde, DHLI = Dairy HLI, ETIC = Equivalent Temperature Index for dairy cows

### 3.4.2. Schwellenwerte

Die Aufstellung eines Indexes zur Beurteilung der Hitzebelastung von Milchkühen allein reicht nicht. Zusätzlich müssen Grenzwerte festgelegt werden, ab denen man von einer Hitzebelastung ausgeht bzw. anhand derer man eine Einteilung in verschiedene Belastungsgrade vornehmen kann. Hierbei kommt es darauf an, welcher Referenzwert als Bestätigung der Hitzebelastung genutzt wird, da die Folgen im Verlauf einer Hitzebelastung zu unterschiedlichen Zeiten auftreten. In einigen Studien dient die Atemfrequenz bzw. der Hechelscore oder die Körpertemperatur als Referenz (MADER et al. 2006; GAUGHAN et al. 2008; MADER et al. 2010), andere betrachten den Abfall der Milchleistung (ZIMBELMAN et al. 2009; BRÜGEMANN 2012; GORNIK et al. 2014; GANTNER 2017; GARNER et al. 2017), den Rückgang der Futteraufnahme (GORNIK et al. 2014), die Reduktion der Konzeptionsrate (SCHÜLLER et al. 2014) oder Änderungen im Tierverhalten (COOK et al. 2007; HEINICKE et al. 2018; MÜSCHNER-SIEMENS et al. 2020). HAMMAMI et al. (2013) nutzten eine Kombination aus Milchleistung, Milchfett- und Milchproteingehalt, sowie den somatischen Zellscore als Referenz. Auch das Aufsuchen von Schattenplätzen wird als Referenz für die Einteilung der Indices genutzt (SVOTWA et al. 2007).

Eine der ersten Einteilungen des **THI** ist auf ARMSTRONG (1994) zurückzuführen, der von einer milden Hitzebelastung ab einem THI von 72, von einer moderaten Hitzebelastung ab einem THI von 78 und von einer schweren Hitzebelastung ab einem THI von 89 berichtete. ZIMBELMAN et al. (2009) stellten fest, dass insbesondere im Hinblick auf die steigende Milchleistung, der Schwellenwert für den Beginn einer Hitzebelastung deutlich niedriger liegt. Sie ermittelten einen THI von 68 als Schwellenwert für den Beginn des witterungsbedingten Milchleistungsabfalls. COOK et al. (2007) beobachteten ab einem THI von 68 Änderungen des Liege- und Stehverhaltens. Für Holsteinkühe der ersten Parität ermittelte GANTNER (2017) ebenfalls einen THI-Schwellenwert von 68 für den Abfall der Milchleistung, für Holsteinkühe in höherer Parität oder Simmentaler lag der Schwellenwert aber höher (69 bzw. 77). SCHÜLLER et al. (2014) beobachteten ab einem THI von 73 einen signifikanten Rückgang der Konzeptionsrate. Hierbei sorgte eine Überschreitung des Schwellenwerts in neun oder mehr Stunden am Tag für eine Reduktion. HAMMAMI et al. (2013) ermittelten für den THI, je nach betrachtetem Referenzwert (Veränderungen der Milchleistung, des Milchfett- und

Milchproteingehalts, des somatischen Zellscore), Schwellenwerte von 62 bis 66. In der Untersuchung von HEINICKE et al. (2018) begannen Veränderungen im Liegeverhalten ab einem THI von 67, während Änderungen im Stehverhalten schon ab einem THI von 47 auftraten.

BRÜGEMANN (2012) stellte fest, dass sich der THI-Schwellenwert, ab dem ein signifikanter Rückgang der Milchleistung beobachtet wird, je nach Region unterscheidet. Der THI-Schwellenwert, ab dem es in dieser Untersuchung zu einem signifikanten Leistungsrückgang kam, lag bei 60 bzw. 62. Einen THI-Schwellenwert von 60 beobachteten auch GORNIK et al. (2014) für den Rückgang der Futteraufnahme und der Milchleistung und MÜSCHNER-SIEMENS et al. (2020) beobachteten ab einem THI von 52 eine signifikante Reduktion der Wiederkaudauer. SVOTWA et al. (2007) stellten fest, dass sich der THI-Schwellenwert, ab dem die Tiere mit der Schattensuche beginnen, je nach Rasse unterscheidet.

BUFFINGTON et al. (1981) wendeten für den **BGHI** die auf ARMSTRONG (1994) beruhenden Schwellenwerte an. DALCIN et al. (2016) evaluierten den Einfluss des BGHI auf die Atemfrequenz verschiedener Milchkurassen und beobachteten einen Anstieg ab einem BGHI von 74 bis 76.

Auch für den **THIadj** wurden in verschiedenen Untersuchungen Schwellenwerte ermittelt. HAMMAMI et al. (2013) beobachteten ab einem THIadj von 64 einen Rückgang der Milchleistung und des Fett- und Proteingehalts, eine Steigung des somatischen Zellscores registrierten sie ab einem THIadj von 71.

Bei der Entwicklung des **HLI** für Mastrinder ermittelten GAUGHAN et al. (2008) einen Schwellenwert von 86, ab dem mehr als 20 % der Tiere einen Hechelscore von  $\geq 1$  hatten. Sie ermittelten zudem, um wieviel der Schwellenwert abhängig von z. B. der Rasse, der Fellfarbe, dem Gesundheitszustand, der Akklimatisierung, der Schattenverfügbarkeit oder der Trinkwassertemperatur nach oben oder nach unten korrigiert werden muss. HAMMAMI et al. (2013) betrachteten den HLI für Milchkühe und ermittelten je nach Referenzwert (Milchleistung, Fett- und Proteingehalt, somatischer Zellscore) Schwellenwerte von 80 bis 82.

Für die Berechnung der **AHL** legten GAUGHAN et al. (2008) als oberen Schwellenwert, ab dem die Körpertemperatur der Tiere steigt, den Schwellenwert

des HLI fest. Als unteren Schwellenwert, ab dem die Tiere keine Hitze mehr abgeben können, definierten sie für die Referenztiere (Mastrinder) einen HLI von 77 (GAUGHAN et al. 2008). VITALI et al. (2020) berichteten für Milchkühe von einem unteren HLI Schwellenwert von 79 und einem oberen HLI Schwellenwert von 82 für die Berechnung des AHL. Der AHL selbst wurde von GAUGHAN et al. (2008) basierend auf der Körpertemperatur und dem Hechelscore von Mastrindern in fünf Kategorien eingeteilt: thermoneutral – AHL < 1, mild – AHL 1 bis 10, warm – AHL 10,1 bis 20, heiß – AHL 20,1 bis 50, sehr heiß – AHL >50. VITALI et al. (2020) gingen ab einem AHL von > 0 von einer Belastungssituation für Milchkühe aus.

Der CCI wurde bei seiner Entwicklung von MADER et al. (2010) anhand des THI, des Hechelscores und der TM-Aufnahme von Mastrindern in folgende Kategorien unterteilt: keine Belastung – CCI < 25, milde Belastung – CCI 25 bis 30, moderate Belastung – CCI >30 bis 35, starke Belastung – CCI >35 bis 40, extreme Belastung – CCI >40 bis 45, starke Gefahr – CCI >45. HAMMAMI et al. (2013) beobachteten für Milchkühe ab einem CCI von 20 bzw. 23 einen Rückgang der Milchleistung und des Fett- und Proteingehalts bzw. einen Anstieg des somatischen Zellscores.

Der DHLI gibt den Anteil der Tiere wieder, die einen erhöhten Hechelscore zeigen und reicht von 0 (kein Tier hat einen Hechelscore >0) bis 100 (alle Tiere haben einen Hechelscore von 4,5) (LEES et al. 2018). Einen DHLI von 1, der den Beginn einer Hitzebelastung repräsentiert, erreichen Milchkühe laut LEES et al. (2018) ab einer Temperatur von -2,5 °C in Kombination mit einer relativen Luftfeuchte von 100 % bis hin zu einer Temperatur von 20 °C in Kombination mit einer Luftfeuchte von 0 %.

Zur Einteilung des ETIC korrigierten LEES et al. (2018) die für den THI genutzten Schwellenwerte und ermittelten folgende Kategorien: milde Hitzebelastung – ETIC 23 bis <26 °C, moderate Hitzebelastung – ETIC 26 bis <31 °C, starke Hitzebelastung – ETIC 31 bis <37 °C und Notfall – ETIC ≥37°C.

Neben ARMSTRONG (1994) stammt eine neuere Einteilung der Hitzebelastung in verschiedene Kategorien von JI et al. (2020b). Diese basiert auf der BGT und umfasst die thermoneutrale Zone (I; ≤ 9 °C), in der kein Einfluss der Temperatur besteht und die durch den signifikanten Anstieg der Milchttemperatur vom milden

Hitzebelastung (II; 9-11 °C) abgegrenzt wird. Fällt neben der steigenden Milchtemperatur zusätzlich die Milchleistung, gehen Ji et al. (2020b) von einer effektiven Hitzebelastung (III; 11-16 °C) aus, bei der die Tiere zusätzlich Energie zur Aufrechterhaltung der Körpertemperatur benötigen. Eine kritische Hitzebelastung (III;  $\geq 16$  °C) besteht nach Ji et al. (2020b), wenn sowohl die Milchtemperatur zunehmend signifikant steigt, als auch die Milchleistung zunehmend signifikant abfällt. In dieser Phase ist eine Abschwächung der Belastung über externe Maßnahmen, wie z. B. Kühlung nötig (Ji et al. 2020b).

Insgesamt zeigt sich, dass die in der Vergangenheit festgelegten Schwellenwerte, unabhängig vom genutzten Index, häufig nicht mehr passend sind. Insbesondere tierindividuelle Faktoren nehmen Einfluss auf den Beginn einer Hitzebelastung und diese Faktoren werden von auf Umweltparametern basierenden Indices nur bedingt berücksichtigt (GALÁN et al. 2018; HERBUT und ANGRECKA 2018; HOFFMANN et al. 2019).

### **3.5. Tierbezogene Einflussfaktoren auf die Entstehung einer Hitzebelastung**

Die Entstehung bzw. der Beginn einer Hitzebelastung hängt von zahlreichen tierindividuellen Einflussfaktoren ab (GALÁN et al. 2018).

Zunächst spielt die **Rasse** der Milchkühe eine Rolle bei der Entstehung einer Hitzebelastung. GANTNER (2017) ermittelte niedrigere THI-Schwellenwerte für den Rückgang der Milchleistung bei Holsteinern im Vergleich zu Simmental-Kühen, wobei der proportionale Abfall und die Dauer der Reduktion in einer anderen Untersuchung (GANTNER et al. 2019) bei Simmentalern höher war. Zudem war die Reduktion des Fett- und Proteingehalts bei Simmental-Kühen ausgeprägter (GANTNER 2017). MCMANUS et al. (2014) verglichen den Effekt einer Hitzebelastung auf die Atemfrequenz und die Milchleistung von Zebu-Kühen mit der von Zebu-Holstein- und Zebu-Simmental-Kreuzungen und stellten bei den Kreuzungen eine höhere Atemfrequenz und eine stärkere Reduktion der Milchleistung fest als bei den reinrassigen Zebu-Kühen. SRIKANDAKMAR und JOHNSON (2004) verglichen die Reaktion von Zebu-, Holstein- und Jersey-Kühen auf eine Hitzebelastung und beobachteten den höchsten Anstieg der Atemfrequenz bei Jersey-Kühen, gefolgt von den Holsteinern und den Zebu. Der Anstieg der Körpertemperatur war hingegen bei den Holstein-Kühen ausgeprägter als bei den

Jersey- und den Zebu-Kühen. VIZZOTTO et al. (2015) beobachteten beim Vergleich zwischen Holsteinern und Holstein-Jersey-Kreuzungen eine niedrigere Körpertemperatur und Atemfrequenz bei den Kreuzungstieren. Zudem kauten die Holstein-Jersey-Kühe mehr im Liegen wieder und verbrachten weniger Zeit mit Stehen. SVOTWA et al. (2007) stellten beim Vergleich von Simmental- mit Brahman- und Mashona-Kühen fest, das Simmentaler unter Hitzebelastung eine niedrigere Oberflächentemperatur entwickelten. Die mangelnde Wärmeabgabe resultierte bei den Tieren in einer höheren Atemfrequenz. Zudem begannen die Simmental-Kühe bei niedrigeren THI-Werten mit der Schattensuche (SVOTWA et al. 2007). Die Rasse der Tiere ist eng verbunden mit weiteren tierbezogenen Faktoren, die die Entstehung einer Hitzebelastung beeinflussen, wie z. B. die Fellfarbe oder die Milchleistung (GALÁN et al. 2018).

Die **Fellfarbe** spielt bei der Hitzebelastung insofern eine Rolle, dass Tiere mit dunklem Fell früher und stärker durch die Hitze belastet sind als Tiere mit hellem Fell, was sich in einer deutlicheren Steigerung der Körpertemperatur (LEE und HILLMAN 2007; GEBREMEDHIN et al. 2010) und einem erhöhten Haarkortisolgehalt bei Tieren mit schwarzem Fell zeigt (GHASSEMI NEJAD et al. 2017). Im Gegensatz zu weißem Fell, führt die Solarstrahlung bei schwarzem Fell zu einer (deutlicheren) Erhöhung der Oberflächentemperatur (GEBREMEDHIN et al. 2010; SCHÜTZ et al. 2011). Über den Wärmetransport hin zum Körperkern wird die Körperkerntemperatur zeitverzögert erhöht (GEBREMEDHIN et al. 2010). Die unterschiedliche Reaktion auf eine Hitzebelastung in Abhängigkeit von der Fellfarbe zeigt sich auch im Verhalten. Helle Tiere zeigen unter Hitzebelastung eine höhere Liegezeit als Tiere mit dunklem Fell (SCHÜTZ et al. 2009). Zudem verbringen Tiere mit dunklem Fell mehr Zeit im Schatten (TUCKER et al. 2008). Neben der Fellfarbe spielt auch die **Felldicke** eine Rolle. Tiere mit dickerem Fell zeigen im Vergleich zu Tieren mit weniger dichtem und langem Fell eine niedrigere Milchleistung und Körpergewichtszunahme (RASHID et al. 2019).

Der **Body Condition Score** (BCS) bzw. das **Körpergewicht** nehmen ebenfalls Einfluss auf die Entstehung einer Hitzebelastung. Tiere mit einem höheren BCS reagieren auf eine Hitzebelastung mit einer deutlicheren Erhöhung der Körpertemperatur und der Atemfrequenz und zeigen eine stärkere Reduktion der Milchleistung (CINCOVIĆ et al. 2011). Ji et al. (2020b) bestätigen die frühere und stärkere Reduktion der Milchleistung bei schweren Tieren im Vergleich zu leichten.

Auch das **Alter** bzw. die **Parität** sind entscheidend bei der Entstehung einer Hitzebelastung, wobei die ermittelten Unterschiede variieren. Während GANTNER (2017; 2019) bei Tieren der ersten Laktation einen stärkeren Leistungsabfall als bei Tieren der zweiten Laktation beobachtete, die ihre Milchleistung wiederum stärker reduzierten als Tiere ab der dritten Laktation, stellten JI et al. (2020b) mit zunehmendem Alter eine abnehmende Hitzeresistenz anhand der fallenden Milchleistung unter Hitzebelastung fest. MÜSCHNER-SIEMENS et al. (2020) stellten zudem bei Tieren in der ersten Laktation den geringsten Abfall der Wiederkaudauer fest, während Tiere in der dritten bzw. ab der vierten Laktation den höchsten Abfall zeigten.

Zusätzlich spielt der **Zeitpunkt in der Laktation** eine Rolle bei der Entstehung einer Hitzebelastung. Während Tiere in der Hoch- oder Plateauphase der Laktation eine Reduktion der Milchleistung zeigen, ist bei Tieren zu Beginn der Laktation nur eine geringere oder keine Reduktion zu beobachten (ABENI et al. 2007; ABENI und GALLI 2017). Zu Beginn der Laktation hängt die Milchleistung vor allem von der Mobilisation der Energiereserven ab, während später die Futteraufnahme die größte Rolle spielt, die unter Hitzebelastung reduziert ist. Tiere in der Hoch- und Plateauphase steigern ihre Aktivität und reduzieren ihre Wiederkaudauer und Liegedauer im Vergleich zu Tieren zu Beginn der Laktation vermehrt (ABENI und GALLI 2017; HEINICKE et al. 2019). CALAMARI et al. (2007) beobachteten, dass insbesondere Tiere in der Mitte der Laktation unter Hitzebelastung eine Steigerung der Atemfrequenz und der Rektaltemperatur zeigen. MÜSCHNER-SIEMENS et al. (2020) stellten bei Tieren in der späten Laktation einen deutlicheren Rückgang der Wiederkaudauer als bei Tieren in der frühen oder mittleren Laktation fest.

Neben dem Zeitpunkt in der Laktation spielt auch die **Milchleistung** der Tiere eine Rolle bei der Entstehung einer Hitzebelastung. So sind Tiere mit einer höheren Milchleistung mehr von einer Hitzebelastung betroffen (NAVRÁTIL et al. 2017). HEINICKE et al. (2018) beobachteten einen deutlicheren Abfall der Liegezeit und Anstieg der Stehzeit bei Tieren mit hoher Milchleistung im Vergleich zu Tieren mit mittlerer und niedriger Milchleistung. Der Anstieg der Schrittzahl war hingegen bei Tieren mit niedriger Milchleistung am höchsten. Auch die Reduktion der Wiederkaudauer ist bei Tieren mit einer hohen Milchleistung ausgeprägter (MÜSCHNER-SIEMENS et al. 2020).

Zusätzlich stellt die **Trächtigkeit** einen Risikofaktor für eine Hitzebelastung dar, da trächtige Tiere eine höhere Energieproduktion aufweisen als nicht-trächtige Tiere (FERRELL et al. 1976). Mit Fortschreiten der Trächtigkeit erhöht sich die Sensibilität gegenüber steigenden Temperaturen, was sich in einer gesteigerten Rektaltemperatur und Atemfrequenz zeigt (ABDELTALIF und ALAMEEN 2012). Die Darstellung des Einflusses der Trächtigkeit auf die Hitzebelastung ist im Hinblick auf die mit Fortschreiten der Trächtigkeit abnehmende Milchleistung aber generell schwierig (GALÁN et al. 2018).

Eine länger andauernde Hitzebelastung führt zu einer **Akklimatisierung** an die hohen Temperaturen, was sich in einer Abnahme der Atemfrequenz und einer Zunahme der Futteraufnahme zeigt (YADAV et al. 2021). Auch der Effekt auf das Verhalten reduziert sich bei länger andauernder Hitzebelastung (HEINICKE et al. 2019). Die Fähigkeit der Anpassung an extreme Witterungsbedingungen ist dabei ebenso tierindividuell wie die Entstehung einer Hitzebelastung (GALÁN et al. 2018).

### 3.6. Verhaltensänderungen unter Hitzebelastung

Ziel der Verhaltensänderungen unter Hitzebelastung ist die Reduktion der Wärmeproduktion und die Steigerung der Wärmeabgabe. Unter Hitzebelastung können sich zum einen die Hauptverhaltensweisen (Liegen, Stehen, Fressen, Grasen, Wiederkauen) und ihre Verteilung auf die Tageszeiten ändern, zum anderen zeigen die Tiere spezifische Verhaltensweisen wie das Aufsuchen von Orten mit weniger belastenden Witterungsbedingungen, z. B. von Schattenplätzen (HOFFMANN et al. 2019).

Die Veränderungen von **Liegen** und **Stehen** unter Hitzebelastung sind eng verknüpft. Hitzebelastete Tiere erhöhen auf Kosten der Liegedauer ihre Stehdauer (HEINICKE et al. 2018; NORDLUND et al. 2019), insbesondere tagsüber (ZÄHNER et al. 2004; ALLEN et al. 2015; HERBUT und ANGRECKA 2018). Stehen erhöht die für die Wärmeabgabe verfügbare Körperoberfläche und unterstützt die Senkung der Körpertemperatur (ALLEN et al. 2015; NORDLUND et al. 2019). Im Einklang mit einer sinkenden Liegedauer, nimmt auch die Liegeperiodendauer (ALLEN et al. 2015) und die Anzahl der Liegeperioden ab (HEINICKE et al. 2018). Auch die Synchronität des Liegeverhaltens ist mit zunehmender Temperatur reduziert (HERBUT und ANGRECKA 2018). Mit der Stehdauer steigt auch die Stehperiodendauer (ALLEN et al. 2015) und die Anzahl der Stehperioden (HEINICKE

et al. 2018). HEINICKE et al. (2018) beobachteten zudem einen Anstieg der **Schrittzahl**.

Unter Hitzebelastung reduzieren Milchkühe ihre TM-Aufnahme (KARIMI et al. 2015). Während KARIMI et al. (2015) eine Reduktion der Mahlzeitendauer bei gleichbleibender **Fresszeit** beobachteten, reduzierte sich in der Untersuchung von ESLAMIZAD et al. (2015) sowohl die tägliche Fressdauer als auch die Dauer einzelner Mahlzeiten, während die Frequenz der Mahlzeiten unverändert blieb. Hitzebelastete Milchkühe verlagern einen größeren Teil der Futteraufnahme in die kühleren Nachtstunden (GARNER et al. 2017).

Auf der Weide nimmt die Hitzebelastung Einfluss auf das Graseverhalten der Tiere. Während TUCKER et al. (2008) eine Reduktion der **Grasezeit** mit steigenden Temperaturen beobachteten, konnten FISHER et al. (2010) keinen Unterschied feststellen. FISHER et al. (2010) beobachteten das Verhalten dabei allerdings auch nur zweimal für je 24 h, während TUCKER et al. (2008) zehn 24 h-Perioden erfassten.

Tiere unter Hitzebelastung reduzieren ihre **Wiederkaudauer** (KARIMI et al. 2015), insbesondere tagsüber (SORIANI et al. 2013; ABENI und GALLI 2017; ARIAS et al. 2021). Die Wiederkauperioden sind verkürzt (KARIMI et al. 2015). ARIAS et al. (2021) beobachteten zum Teil eine Kompensation durch Erhöhung der Wiederkaudauer in den Nachtstunden.

Der Wasserbedarf hitzebelasteter Milchkühe ist durch den erhöhten Verlust über die evaporative Wärmeabgabe gesteigert, was in einer Reduktion des **Harnabsatzes** resultiert (EL-NOUTY et al. 1980). Gleichzeitig sind die Wasseraufnahme und damit die **Trinkdauer** unter Hitzebelastung erhöht (VIZZOTTO et al. 2015). HANUŠOVSKÝ et al. (2017) beobachteten eine Zunahme der Anzahl der Trinkevents mit Steigerung des THI.

Unter Hitzebelastung zeigen Milchkühe vermehrt **aggressive Interaktionen** (VIZZOTTO et al. 2015), insbesondere wenn Konkurrenz um Ressourcen wie Wasser (MCDONALD et al. 2020) oder Schatten besteht (SCHÜTZ et al. 2009).

Eine Hitzebelastung nimmt zudem Einfluss auf den **Aufenthaltsort** von Milchkühen. Im Stall werden unter Hitzebelastung Liegeboxen mit einer

Oberfläche gewählt, die eine hohe konduktive Wärmeabgabe ermöglichen (PALO et al. 2006; ORTIZ et al. 2015). Liegeboxen, die direkter Sonneneinstrahlung ausgesetzt sind, werden vermieden (ANGRECKA et al. 2017). Steht auf der Weide Schatten zur Verfügung, halten sich Milchkühe unter Hitzebelastung vermehrt dort auf (SCHÜTZ et al. 2008; VEISSIER et al. 2018). Haben die Tiere freie Wahl zwischen Stall und Weide, verbringen sie bei steigenden Temperaturen weniger Zeit auf der Weide (KETELAAR-DE LAUWERE et al. 1999; LEGRAND et al. 2009), insbesondere tagsüber (FALK et al. 2012). Im Vergleich zwischen Tag und Nacht verbringen die Tiere bei hohen Temperaturen nachts mehr Zeit auf der Weide als tagsüber (SMID et al. 2019).

### 3.7. Automatisierte Erfassung einer Hitzebelastung

Die automatisierte Erfassung einer Hitzebelastung basiert auf der Registrierung von Änderungen physiologischer Parameter und Variationen des Tierverhaltens, die mit der Belastung einhergehen. In den meisten Untersuchungen wird dabei jedoch nur überprüft, wie genau die automatisierte Erkennung der Parameter ist (z. B. JORQUERA-CHAVEZ et al. 2019; CARVALHO et al. 2021) und wie gut diese mit hitzebelastenden Witterungsparametern korrelieren (z. B. ATKINS et al. 2018; ISLAM et al. 2020; MÜSCHNER-SIEMENS et al. 2020). Wie gut eine Hitzebelastung über die jeweiligen automatisiert erfassten Parameter, bzw. eine Kombination aus ihnen, erkannt werden kann, wird dabei nur selten evaluiert (JI et al. 2020b; BECKER et al. 2021).

Unter Hitzebelastung kommt es zu einem Anstieg der **Körpertemperatur** von Milchkühen (SORIANI et al. 2013; VAN LAER et al. 2015). Automatisiert und über einen längeren Zeitraum kann die Körpertemperatur über eine Wärmebildkamera (OSEI-AMPONSAH et al. 2020), subkutan implantierte (CHUNG et al. 2020), vaginal (GARNER et al. 2017) oder rektal (REUTER et al. 2010) eingebrachte Temperaturdatenlogger, sowie einen Pansenbolus (AMMER et al. 2016) oder eine Ohrmarke (AL-QAISI und TIMMS 2017) gemessen und eine Erhöhung der Temperatur mit steigendem THI registriert werden.

Zur Erhöhung der evaporativen Wärmeabgabe steigern Milchkühe unter Hitzebelastung ihre **Atemfrequenz** (BERMAN 2005; GARNER et al. 2017). Die automatisierte Erfassung der Atemfrequenz kann mittels verschiedener Methoden erfolgen, zu denen beispielsweise die maschinelle Bildverarbeitung zur

Registrierung der Atembewegungen im Nasenbereich (JORQUERA-CHAVEZ et al. 2019), die Analyse von mit der Ein- und Ausatmung verbundenen Audiosignalen (CARVALHO et al. 2021), die Erfassung der Flankenbewegungen mittels Laserdistanzmesser (PASTELL et al. 2006) oder Drucksensor in einem Brustgurt (ATKINS et al. 2020) oder auch die mit einem Accelerometer registrierten Kopf- und Hals- bzw. Ohrbewegungen (BAR et al. 2019; DAVISON et al. 2020; ISLAM et al. 2020) dienen. ATKINS et al. (2020) stellten dabei eine hohe Übereinstimmung zwischen dem Verlauf der automatisiert erfassten Atemfrequenz und dem des THI fest. BAR et al. (2019), DAVISON et al. (2020) und ISLAM et al. (2020) untersuchten die Korrelation zwischen Witterungsparametern und automatisiert erfasstem Hechelscore und stellten hohe Übereinstimmungen fest.

Während die Temperatur- und Atemfrequenzmessung durch im Melkstand angebrachte Sensoren (PASTELL et al. 2006; JORQUERA-CHAVEZ et al. 2019) auf die Melkzeit beschränkt ist und Brustgurt- und Halfter-basierte Systeme (ATKINS et al. 2020; CARVALHO et al. 2020) vor allem in Versuchen Anwendung finden, sind Halsband- oder Ohrmarken-basierte (BAR et al. 2019; DAVISON et al. 2020; ISLAM et al. 2020) Systeme zur Atemfrequenzerfassung auch für die langfristige Anwendung in der täglichen Praxis geeignet (SHU et al. 2021).

In Folge einer Hitzebelastung kommt es zu einem Abfall der **Milchleistung** (GANTNER et al. 2019). JI et al. (2020b) entwickelten ein DT-Modell für die automatisierte Erkennung einer Hitzebelastung anhand des von einem AMS automatisiert erfassten Milchleistungsabfalls, aufgeteilt in Gruppen nach Alter, Körpergewicht und Laktationszeitpunkt und erzielten eine Genauigkeit in der Erkennung einer Hitzebelastung von 79 bis 94 %.

Eine Hitzebelastung führt zu **Verhaltensänderungen** (siehe Kapitel 3.6), die automatisiert erfasst werden können. Die automatisiert für die Untersuchung einer Hitzebelastung erfassten Parameter umfassen die Aktivität (ABENI und GALLI 2017), das Liegeverhalten (ALLEN et al. 2015; BLACK und KRAWCZEL 2016; HEINICKE et al. 2019; ATKINS et al. 2020), das Stehverhalten (ALLEN et al. 2015; HEINICKE et al. 2019), das Graseverhalten (ARIAS et al. 2021) und das Wiederkauverhalten (ABENI und GALLI 2017; MÜSCHNER-SIEMENS et al. 2020; ARIAS et al. 2021).

Für die automatisierte Erkennung einer Hitzebelastung werden zudem auch Kombinationen aus Parametern genutzt. BECKER et al. (2021) verglichen verschiedene maschinelle Lernmodelle (LoR, RF, NB), die auf ein Featureset bestehend aus physiologischen Parametern (u. a. Pansentemperatur und Atemfrequenz), Verhaltensparametern (u. a. Liegezeit und Liegeperiodenzahl) und Umweltparametern (THI und Windgeschwindigkeit) angewendet wurden, wobei das Featureset auch nicht-automatisiert erfasste Parameter beinhaltete (z. B. Hecheln mit geöffnetem Maul). Die verschiedenen Modelle erkannten eine Hitzebelastung mit einer Sensitivität von 84 bis 93 %, einer Spezifität von 81 bis 86 % und einer Genauigkeit von 82 bis 88 %.

### **3.8. Maßnahmen zur Reduktion einer Hitzebelastung**

Es stehen verschiedene Maßnahmen zur Reduktion einer Hitzebelastung zur Verfügung, die sowohl auf die Reduktion der Wärmeproduktion als auch auf die Steigerung der Wärmeabgabe abzielen. Die Maßnahmen lassen sich einteilen in bauliche Maßnahmen (z. B. Stallausrichtung, Isolation), technische Maßnahmen (z. B. Ventilatoren) und Managementmaßnahmen (z. B. Fütterung, Weidezeiten) und ihre Anwendungsmöglichkeit hängt vom Haltungssystem ab. Das nachfolgende Kapitel gibt einen Überblick über die verschiedenen Maßnahmen zur Reduktion einer Hitzebelastung bei Milchkühen, die im Stall und auf der Weide ergriffen werden können.

#### **3.8.1. Gegenmaßnahmen im Stall**

Im Stall spielen die **baulichen Eigenschaften des Stallgebäudes** bei der Entstehung von belastenden Witterungsbedingungen eine Rolle und sollten beim Bau eines neuen Stallgebäudes bzw. der Optimierung bestehender Stallgebäude berücksichtigt werden. Zu den relevanten baulichen Eigenschaften gehören unter anderem die Ausrichtung des Gebäudes in Relation zu Sonneneinstrahlung und Windrichtung, die Länge des Dachüberhangs, die Neigung des Daches, das Dachmaterial bzw. der Isolationsgrad des Dachmaterials, der Öffnungsgrad, sowie die Höhe der Seitenwände und des Firstes (SHOSHANI and HETZRONI 2013; MENCONI und GROHMANN 2014; BELLAGI et al. 2017; SIMON et al. 2018; MONDACA 2019). Diese Eigenschaften nehmen Einfluss auf die Sonneneinstrahlung in das Stallgebäude (ANGRECKA et al. 2017), sowie auf den Grad der natürlichen Lüftung (SIMON et al. 2018; MONDACA 2019). Letztere hängt

zum einen von der Firstöffnung des Stalls ab, über die die leichtere warme Luft nach oben hin entweichen kann und zum anderen von der Öffnung der Seitenwände, über die Wind in den Stall gelangen kann (MONDACA 2019).

Eine aktive Kühlung der Tiere im Stall kann durch den Einsatz von **Ventilatoren** erreicht werden. Diese erhöhen die Windgeschwindigkeit und damit die konvektive Wärmeabgabe (LEE und HILLMAN 2007). GEISCHEDER (2017) zeigte, dass der Einsatz von Ventilatoren eine signifikante Reduktion der Körpertemperatur und der Herzfrequenz von Milchkühen unter Hitzestress bewirkt. Bei der Verwendung von Ventilatoren spielt die Position dieser im Stall eine Rolle (PAKARI und GHANI 2021). Bewegliche Ventilatoren können die Bedingungen im Stall besser optimieren als stationäre Ventilatoren (ANDERSON et al. 2013). Auch die Windgeschwindigkeit, die der Einsatz von Ventilatoren bewirkt, ist entscheidend. ZAHNER (2020) gibt an, dass mindestens eine Windgeschwindigkeit von 2 m/s auf Tierhöhe erreicht werden muss, damit die Kühlungsmethode effektiv ist.

Auch **Sprinkler** können zur Kühlung von Milchkühen eingesetzt werden. Diese durchnässen das Fell der Tiere und erhöhen so die evaporative Wärmeabgabe über Verdunstung des Wassers aus dem Fell (RENAUDEAU et al. 2012). HILLMAN et al. (2005) untersuchten den Effekt einer Sprühkühlung in Liegeboxen und stellten fest, dass die vaginal gemessene Körpertemperatur der Tiere mit Sprühkühlung im Liegen weniger schnell anstieg als ohne. Zudem verbrachten die Tiere mit Sprühkühlung mehr Zeit mit Liegen. Die Kombination aus Sprinklerkühlung und Ventilatoren führt im Vergleich zu keiner Kühlung zu einer Reduktion der Körpertemperatur, der Atemfrequenz und der Stehzeit und zu einer Steigerung der Wiederkaudauer (KARIMI et al. 2015). Können die Tiere selbst über die Nutzung einer Kuhdusche entscheiden, variiert die Nutzung zwischen den Tieren stark, steigt aber mit zunehmendem THI (GRINTER 2019). Bei der Verwendung von Sprinklerkühlung spielen die Wasserflussrate (CHEN et al. 2016), sowie die Frequenz der Kühlzyklen eine Rolle (HONIG et al. 2012). Zudem muss bei dieser Art der Kühlung der hohe Wasserverbrauch in Betracht gezogen werden (XIONG und GATES 2017)

Neben Sprinklern nutzt auch die **Hochdruckvernebelungskühlung** die Effekte der evaporativen Wärmeabgabe (RENAUDEAU et al. 2012). Bei dieser Form der Kühlung wird Wasser unter Hochdruck so fein vernebelt, dass die Luft über

Verdunstung des Wassers gekühlt wird und so die Wärmebelastung durch die Witterungsbedingungen reduziert. Gleichzeitig erhöht diese Art der Kühlung allerdings die Luftfeuchtigkeit (BOONSANIT et al. 2012), was wiederum die evaporative Wärmeabgabe der Tiere einschränken kann (BERMAN 2005; GEBREMEDHIN et al. 2010). Hochdruckvernebelungsanlagen werden meist in Kombination mit Ventilatoren verwendet, die die gekühlte Luft durch den Stall befördern (FOURNEL et al. 2017). BUCKLIN et al. (2009) beobachteten niedrigere Körpertemperaturen bei Milchkühen in einem Stall mit Hochdruckvernebelungsanlage im Vergleich zu einem Stall ohne Kühlung. BOONSANIT et al. (2012) beobachteten ebenfalls eine Reduktion der Körpertemperatur durch Hochdruckvernebelungskühlung, sowie eine Abnahme der Atemfrequenz.

Die konduktive Wärmeabgabe kann bei Milchkühen über **gekühlte Liegeboxen** gesteigert werden (BASTIAN et al. 2003). ORTIZ et al. (2015) stellten fest, dass gekühlte Liegeoberflächen einen positiven Effekt auf die Körpertemperatur und die Atemfrequenz von hitzebelasteten Milchkühen haben.

### 3.8.2. Gegenmaßnahmen auf der Weide

Um den Einfluss der Solarstrahlung auf der Weide zu reduzieren, können Schattenkonstruktionen aufgestellt werden bzw. Zugang zu natürlichem **Schatten** durch Bäume ermöglicht werden (WEST 2003). An heißen Tagen haben Milchkühe auf der Weide ein hohes Bedürfnis danach, Schatten aufzusuchen (SCHÜTZ et al. 2008; VEISSIER et al. 2018). Milchkühe bevorzugen Schattenkonstruktionen mit einer hohen Blockade der Sonneneinstrahlung (TUCKER et al. 2008; SCHÜTZ et al. 2009). Das Angebot von Schatten kann nützlich für die Reduktion der Wärmebelastung sein, wobei es auf die Größe des verfügbaren Schattens ankommt (SCHÜTZ et al. 2010). VEISSIER et al. (2018) beobachteten einen weniger ausgeprägten Anstieg der Kotkortisolmetaboliten bei Tieren mit Zugang zu Schatten. KENDALL et al. (2006) beobachteten eine Reduktion der Vaginaltemperatur und VAN LAER et al. (2015) und VEISSIER et al. (2018) der Rektaltemperatur bei Tieren mit Schatten im Vergleich zu Tieren ohne Schatten. Zudem hatten die Tiere mit Schatten eine höhere Milchleistung (MCMANUS et al. 2014; VAN LAER et al. 2015), insbesondere morgens (KENDALL et al. 2006). VIZZOTTO et al. (2015) untersuchten den Einfluss von Schatten auf das Verhalten

unter Hitzebelastung und erfassten mehr Ruhezeit im Liegen und weniger Trinken bei Tieren mit Schatten im Vergleich zu Tieren ohne Schatten.

Steigen die Temperaturen und besteht kein ständiger Zugang zum Stall, wird eine **Verschiebung der Weidezeiten** auf die kühleren Stunden des Tages empfohlen (STEINWIDDER und GASTEINER 2017). Haben die Tiere freie Wahl zwischen Stall und Weide, verbringen sie bei steigenden Temperaturen weniger Zeit auf der Weide (KETELAAR-DE LAUWERE et al. 1999; LEGRAND et al. 2009). Im Vergleich zwischen Tag und Nacht verbringen die Tiere nachts mehr Zeit auf der Weide (SMID et al. 2019).

Auch auf der Weide kann **Ventilator- und Sprinklerkühlung** eingesetzt werden. VALTORTA and GALLARDO (2004) untersuchten den Effekt einer Kombination aus Ventilatoren und Sprinklern im Wartebereich zum Melken und beobachteten eine signifikante Reduktion der Atemfrequenz und der Körpertemperatur, sowie einen Anstieg der Milchleistung im Vergleich zu Tieren ohne Kühlung. Haben Milchkühe auf der Weide allerdings die Wahl zwischen Schatten und Sprinklern, bevorzugen sie den Schatten, obwohl die Sprinklerkühlung eine stärkere Reduktion der Atemfrequenz und der Körpertemperatur bewirkt. Die Präferenz verdeutlicht sich bei zunehmender Temperatur und Sonneneinstrahlung und nimmt mit zunehmender Luftfeuchte ab (SCHÜTZ et al. 2011).

### 3.8.3. **Haltungsübergreifende Gegenmaßnahmen**

Eine Hitzebelastung resultiert, durch erhöhte Verluste über evaporative Wärmeabgabe, in einem gesteigerten Wasserbedarf (MEYER et al. 2004; GORNIK et al. 2014), weshalb eine ausreichende **Wasserversorgung** essenziell ist (WEST 2003; RENAUDEAU et al. 2012). Für die zulängliche Versorgung der Tiere mit Wasser spielt die Wasserflussrate (ANDERSSON et al. 1984) und die Lokalisation der Tränken (DAROS et al. 2019) eine Rolle. Auch wenn Milchkühe unter Hitzebelastung kühles Wasser nicht bevorzugen, hat es einen positiven Effekt für die Körpertemperatur und die Atemfrequenz der Tiere (STERMER et al. 1986; GONZÁLEZ PEREYRA et al. 2010).

Auch die **Fütterung** und das **Fütterungsmanagement** spielen bei der Entstehung einer Hitzebelastung eine Rolle und können zur Milderung der Hitzebelastungsfolgen angepasst werden. Bei der Futtermittelverwertung entsteht

Wärme, sodass nach der Fütterung der Bedarf zur Wärmeabgabe am größten ist (PURWANTO et al. 1990). Eine Verschiebung der Fütterung vom Morgen auf den Abend reduziert die Intensität der Reaktionen, sowie die Folgen einer Hitzebelastung (NIKKHAH et al. 2011; CALAMARI et al. 2013). RENAUDEAU et al. (2012) schlagen zudem eine Aufteilung der Fütterung auf kleine Portionen vor. Die Erhöhung der Energiedichte über Ergänzung von Kraftfutter und Fett bei gleichzeitiger Reduktion des Fasergehalts, erhöht die Milchleistung unter Hitzebelastung (DRACKLEY et al. 2003). Auf der anderen Seite steigt dadurch aber das Risiko einer Pansenazidose (SZENCI et al. 2020). Durch das Schwitzen und die veränderte Stoffwechsellage verlieren Milchkühe vermehrt Mineralstoffe, sodass ein erhöhter Zusatz dieser über das Futter die Folgen einer Hitzebelastung abschwächen kann (MALLONÉE et al. 1985; SCHNEIDER et al. 1986).

## IV. TIERE, MATERIAL UND METHODEN

Die durchgeführten Untersuchungen waren Teil des Projekts „FutureIOT“ am Institut für Landtechnik und Tierhaltung der Bayerischen Landesanstalt für Landwirtschaft. Das Projekt wurde von einem Verbund aus zahlreichen Partnern aus der Forschung, sowie der Industrie durchgeführt. Am Institut für Landtechnik wurde dabei das Teilprojekt „Rindertracking“ in Zusammenarbeit mit dem Lehrstuhl für Tierschutz, Verhaltenskunde, Tierhygiene und Tierhaltung der tierärztlichen Fakultät der Ludwig-Maximilians-Universität, sowie dem Lehrstuhl für Informatik der Otto-Friedrich-Universität Bamberg bearbeitet. Als wirtschaftliche Projektpartner waren die Blaupunkt Telematics GmbH, die Evonik Nutrition & Care GmbH und die safactory GmbH vertreten. Gefördert wurde der Projektverbund von der Bayerischen Forschungstiftung (AZ 1301-17).

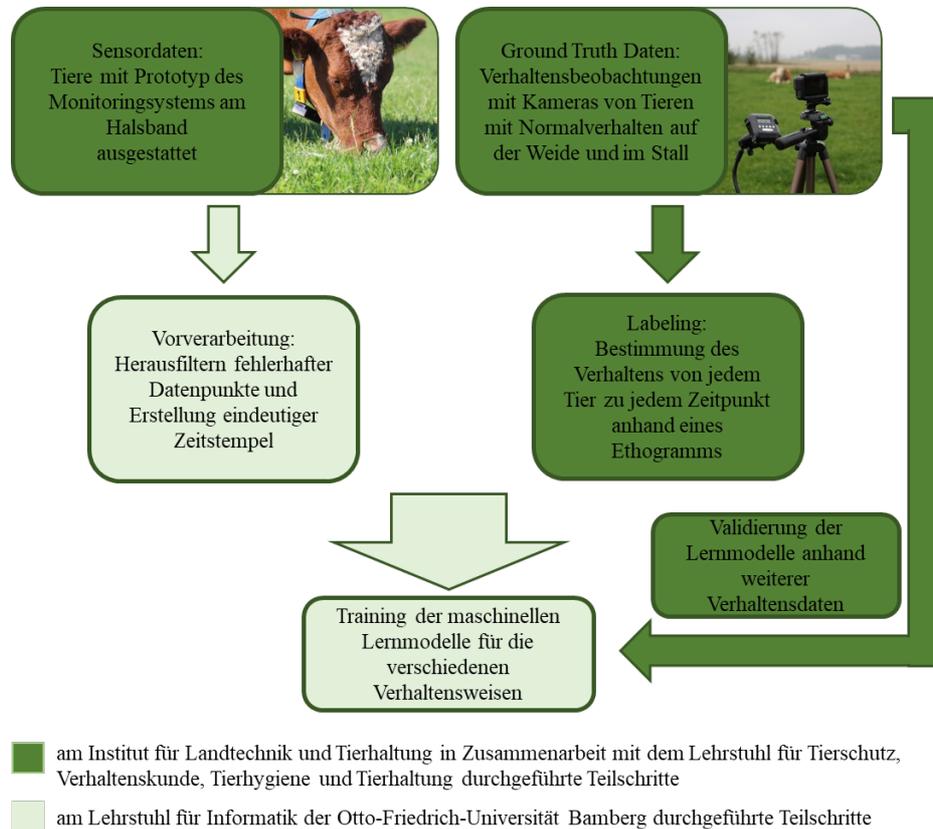
Ziel des Teilprojekts „Rindertracking“ und damit auch dieser Dissertation, war die Entwicklung und Validierung maschineller Lernmodelle für die automatisierte Verhaltenserkennung von Milchkühen im Stall und auf der Weide mit Hilfe eines Monitoringsystems. Der Prototyp des Systems stammte von der Blaupunkt Telematics GmbH (Hildesheim, Deutschland). Die für das Training der Modelle benötigten Verhaltensdaten wurden auf drei verschiedenen Praxisbetrieben mittels Videobeobachtung gesammelt. Die Videoaufzeichnungen wurden ausgewertet und dienten dem Lehrstuhl für Informatik an der Otto-Friedrich-Universität Bamberg für die Entwicklung der Lernmodelle. Die Modelle wurden im Anschluss anhand weiterer Verhaltensdaten auf ihre Genauigkeit hin evaluiert.

Ein weiteres Ziel war die Untersuchung einer beginnenden Hitzebelastung bei Milchkühen auf der Weide. Hierzu wurden auf einem der Praxisbetriebe verschiedene Parameter erfasst, die als Anzeichen für den Beginn einer belastenden Situation bedingt durch die Witterung bekannt sind. Zusätzlich wurde ein Teil der Tiere mit dem Prototyp des Monitoringsystems ausgestattet. Im Anschluss wurden die entwickelten Lernmodelle auf die vom System erfassten Sensordaten angewendet, um das Verhalten der Tiere unter beginnender Hitzebelastung zu untersuchen.

# 1. Entwicklung maschineller Lernmodelle zur Verhaltenserfassung bei Milchkühen auf der Weide

## 1.1. Übersicht über die Datenerfassung

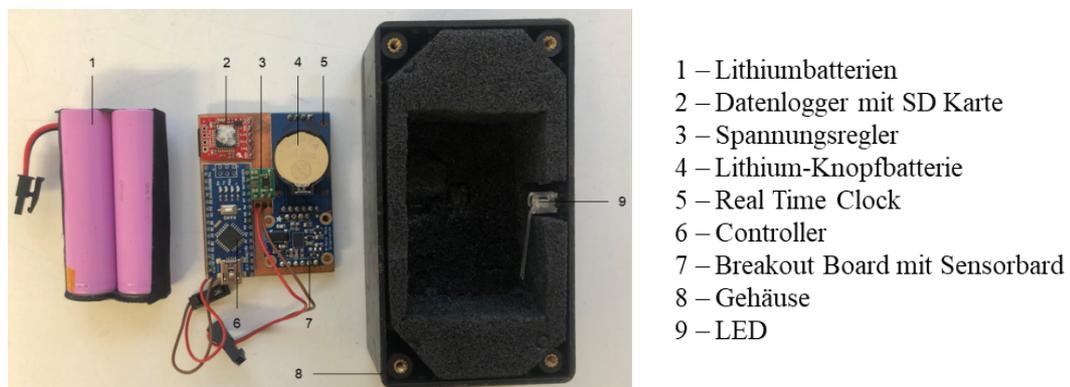
Abbildung 3 gibt einen Überblick über die im ersten Teil der Untersuchung zur Entwicklung maschineller Lernmodelle erfassten Daten.



### Abbildung 3: Übersicht über die Datenerfassung zur Entwicklung maschineller Lernmodelle für die automatisierte Verhaltenserfassung bei Milchkühen

Die Datenerfassung wurde auf drei verschiedenen Praxisbetrieben in Oberbayern in je zwei Durchgängen pro Betrieb durchgeführt. Auf allen Betrieben wurde eine Kombination aus Laufstallhaltung im Winter und Weidehaltung im Sommer praktiziert. Auf Betrieb 1 fanden die Beobachtungen im September und Oktober 2018 statt. Die Tiere hatten hier nur während der Melkzeiten Zugang zum Stall. Die Beobachtungen auf Betrieb 2 wurden im Juni und Juli 2019 durchgeführt. Hier bestand tagsüber für die Tiere ständiger Zugang zum Stall, während sie sich nachts auf einer kleineren Weide ohne Stallzugang befanden. Auf Betrieb 3 wurden die Beobachtungen im Februar und März 2019 ausschließlich im Stall durchgeführt.

Pro Betrieb wurden 7 bis 11 Tiere mit dem Prototyp des Monitoringsystems ausgestattet (siehe Tabelle 26). Die Prototypen des Systems (siehe Abbildung 4) wurde von der Firma Blaupunkt Telematics GmbH (Hildesheim, Deutschland) gestellt. Das System enthielt eine Platine, auf die das Sensorboard (BNO055; Bosch Sensortec GmbH, Reutlingen, Deutschland) montiert war, welches aus einem Beschleunigungssensor, einem Magnetometer und einem Gyroskop bestand. Die Einstellungen des Sensorboards wurden dabei so gewählt, dass die Beschleunigung (m/s) in drei Richtungen, sowie der Eulersche Winkel ( $^{\circ}$ ), der aus einer Kombination der drei Sensoren berechnet wird, mit einer Frequenz von 10 Hz erfasst wurden. Des Weiteren waren auf der Platine ein Datenlogger (SparFun OpenLog ATmega328; SparFun Electronics, Niwot, USA), der die Datenspeicherung auf der SD-Karte (SanDisk 32 GB; Western Digital Deutschland GmbH, Aschheim, Deutschland) sicherstellte, ein Spannungsregler (S18V20ALV; Pololu Robotics & Electronics, Las Vegas, USA), eine über eine Lithium-Knopfbatterie (CR2032; Varta Consumer Batteries GmbH & Co. KGaA, Ellwangen, Deutschland) betriebene Real Time Clock (DS3231; Maxim Integrated Products, Inc., San Jose, USA) als Zeitgeber, sowie ein Controller (Arduino Nano V3 with CH340; AZ-Delivery Vertriebs GmbH, Deggendorf, Detuschland) befestigt. Die Platine befand sich zusammen mit zwei Lithiumbatterien (ICR18650; Samsung Group, Seoul, Südkorea) in einem Plastikgehäuse (133x63x35 mm), in das eine LED eingebaut war, die die Funktionalität des Geräts von außen sichtbar machte. Insgesamt wog das System 220 g und wurde an einem für Rinder vorgesehenen Halsband befestigt.



**Abbildung 4: Aufbau des Monitoringsystems mit Lithiumbatterien, Sensorplatine und Gehäuse**

Nicht alle Sensorsysteme erfassten im gesamten Beobachtungszeitraum Daten. Die Anzahl der eingesetzten und gelaufenen Sensoren ist in Tabelle 26 aufgeführt. Die kurzen Laufzeiten waren auf eine eingeschränkte Batterielaufzeit zurückzuführen. Einige Systeme funktionierten aufgrund anderer technischer Probleme nicht.

**Tabelle 26: Übersicht über die Zahl der mit einem Monitoringsysteme ausgestatteten Tiere und Anzahl der davon gelaufenen Systeme auf den verschiedenen Betrieben je Durchgang und Tag**

Durchgang	Tag	Betrieb 1		Betrieb 2		Betrieb 3	
		ausg. <sup>1</sup>	funkt. <sup>2</sup>	ausg. <sup>1</sup>	funkt. <sup>2</sup>	ausg. <sup>1</sup>	funkt. <sup>2</sup>
1	1	5	5	12	10	9	4
	2	7	7	12	10	9	3
	3	- <sup>3</sup>	- <sup>3</sup>	12	9	9	2
	4	- <sup>3</sup>	- <sup>3</sup>	12	6	9	2
2	1	8	8	11	11	8	6
	2	8	8	11	11	11	9
	3	8	3	11	10	11	8
	4	- <sup>3</sup>	- <sup>3</sup>	- <sup>3</sup>	- <sup>3</sup>	11	8

<sup>1</sup>Anzahl der Tiere, die mit einem System ausgestattet wurden, <sup>2</sup>Anzahl der funktionstüchtigen Systeme, <sup>3</sup>an diesem Tag wurden auf dem jeweiligen Betrieb keine Daten erfasst

Die Verhaltensbeobachtungen wurden sowohl im Stall als auch auf der Weide mit Kameras (HERO5; GoPro Inc., San Mateo, USA) durchgeführt. Auf der Weide wurden vier bis fünf Kameras auf Stativen befestigt und von zwei bis vier Beobachtern in ausreichendem Abstand zu den Tieren aufgestellt und bei Bewegung der Herde mitgetragen (siehe Abbildung 5). Im Blickfeld der Kamera wurde eine Funkuhr (Hama GmbH & Co KG, Monheim, Deutschland) so platziert, dass die aktuelle Uhrzeit jederzeit sichtbar war. Im Stall wurden sieben Kameras außerhalb der Reichweite der Tiere an der Stalleinrichtung montiert. Während die Beobachtungen auf der Weide ausschließlich tagsüber bei Tageslicht durchgeführt wurden, erfassten die Kameras im Stall das Verhalten zum Teil auch nachts.



**Abbildung 5: Kameraaufbau für die Verhaltensbeobachtungen auf der Weide**

Im Anschluss an die Beobachtungen wurden die Videodaten anhand eines zuvor festgelegten Ethogramms (SCHMELING et al. 2021a) für die beobachteten Tiere zu jedem Zeitpunkt auf Sekundenbasis bestimmt (= gelabelt). Dabei wurden die Daten zum Teil detailliert gelabelt, zum Teil wurden nur die Verhaltensweisen Liegen und Nicht-Liegen gelabelt, um den Datensatz für die Entwicklung des Liegen-Modells zu erweitern. Tabelle 27 gibt einen Überblick über die Anzahl der Tiere pro Betrieb und Tag, deren Videodaten detailliert gelabelt wurden und in deren Daten Liegen und Nicht-Liegen gelabelt wurde. Die gelabelten Videodaten dienten für die Entwicklung der maschinellen Lernmodelle als Referenz, als sogenannte Ground Truth.

**Tabelle 27: Zahl der Tiere auf den verschiedenen Betrieben je Durchgang und Tag, deren Videodaten detailliert bzw. mit Liegen/Nicht-Liegen gelabelt wurden**

Durchgang	Tag	Betrieb 1		Betrieb 2		Betrieb 3	
		detailliert	L/NL <sup>1</sup>	detailliert	L/NL <sup>1</sup>	detailliert	L/NL <sup>1</sup>
1	1	5	0	0	0	0	4
	2	7	0	0	0	0	3
	3	- <sup>2</sup>	- <sup>2</sup>	0	0	0	2
	4	- <sup>2</sup>	- <sup>2</sup>	0	0	0	2
2	1	8	0	0	11	0	6
	2	8	0	3	8	0	9
	3	0	0	0	10	8	0
	4	- <sup>2</sup>	- <sup>2</sup>	- <sup>2</sup>	- <sup>2</sup>	0	8

<sup>1</sup>Liegen/Nicht-Liegen wurde gelabelt <sup>2</sup>an diesem Tag wurden auf dem jeweiligen Betrieb keine Daten erfasst

## 1.2. Entwicklung, Validierung und Anwendung der maschinellen Lernmodelle

Basierend auf den Verhaltens- und Sensordaten wurden am Lehrstuhl für Informatik der Otto-Friedrich-Universität Bamberg maschinelle Lernmodelle für die Verhaltensweisen Liegen, Grasens und Wiederkauens entwickelt und trainiert. Die Parameter der verschiedenen Modelle sind in Tabelle 28 aufgeführt.

**Tabelle 28: Übersicht über die für die verschiedenen Verhaltensweisen verwendeten Modelle inklusive ihrer Parameter**

Verhaltensweise	Algorithmus	Fenstergröße	Überlappung	Featureset	Filter
Liegen	Random Forest, binär	5 s	0 %	orientierungsunabhängig, 36 Features	60 s
Grasen	Random Forest, binär	5 s	50 %	orientierungsunabhängig, 26 Features	-
Wiederkauen	Random Forest, binär	5 s	0 %	orientierungsunabhängig, 26 Features	60 s

Die Modelle wurden alle anhand des Datensatzes dreier Tiere von Betrieb 1 und daher ausschließlich basierend auf Daten von der Weide trainiert. Der Datensatz umfasste 30,4 h. Die Modelle wurden dann anhand der nicht für das Training verwendeten Daten evaluiert. Im Anschluss an ihre Entwicklung und Validierung, wurden die Modelle auf die vorhandenen Sensordaten angewendet, um das Verhalten der Tiere während der Beobachtungsdurchgänge zu erfassen.

## 1.3. Erfassung von Einflussfaktoren auf das Tierverhalten

Das Tierverhalten wird sowohl auf der Weide als auch im Stall durch zahlreiche management- und umweltbezogene, sowie tierbezogene Faktoren beeinflusst. Zusätzlich zum Verhalten wurden die Witterung, sowie der Weidegrasaufwuchs bestimmt. Tierbezogene Faktoren beinhalteten neben dem Alter der Tiere, den Body Condition Score (BCS), sowie die Milchleistung inklusive der Milchinhaltsstoffe.

### **1.3.1. Witterung**

Die Witterung wurde mit einer Wetterstation erfasst. Diese bestand aus einem Wettermesswertgeber (WXT510; Vaisala Oyi, Helsinki, Finnland), der die Umgebungstemperatur (°C), die relative Luftfeuchte (%) und die Windgeschwindigkeit (m/s) und einem Pyranometer (CM11; OTT HydroMet B.V., Delft, Niederlande), das die Solarstrahlung (W/m<sup>2</sup>) registrierte. Alle Witterungswerte wurden in einem Intervall von zehn Minuten erfasst, die im Anschluss zu Stundenmittelwerten zusammengefasst wurden. Die Wetterstation lief dabei parallel zu den Verhaltensbeobachtungen nur tagsüber.

### **1.3.2. Body Condition Score**

Der BCS wurde für jedes mit einem Monitoringsystem ausgestattete Tier zu Beginn von jedem Beobachtungsdurchgang bestimmt. Die Bestimmung des BCS wurde anhand des von METZNER et al. (1993) modifizierten Scoringssystems von EDMONSON et al. (1988) vorgenommen.

### **1.3.3. Milchleistung und Milchinhaltsstoffe**

Auf Betrieb 1 wurde die Milchleistung mit Hilfe von für den Versuch in das Melksystem integrierten Lactocordern® (WMB AG, Balgach, Schweiz) bei je zwei Morgen- und Abendmelkungen bestimmt. An die Lactocorder® wurden für die Milchprobennahme Probenröhrchen angeschlossen, in die eine repräsentative Menge an Milch automatisiert abgeschieden wurde. Aufgrund von nicht behebbaren technischen Problemen der Lactocorder® konnte die Milchleistung beim zweiten Durchgang nicht erfasst und keine Milchproben genommen werden. Auf Betrieb 2 wurde die Milchleistung mittels für den Versuch in das Melksystem integrierten TruTestern (LKV Bayern e. V., München, Deutschland) bestimmt. Aus der hierbei repräsentativ abgeschiedenen Menge der Milch wurden Proben entnommen. Die Erfassung der Milchleistung und die Probennahme erfolgte bei jeder Melkung im Beobachtungszeitraum.

Auf Betrieb 3 war in das Melksystem dauerhaft ein Milchmengenmessgerät integriert, von dem die Milchleistung bei jeder Melkung im Beobachtungszeitraum abgelesen wurde. An einer dafür vorgesehen Stelle im Melksystem wurde ein Behälter angeschlossen, in den eine repräsentative Milchmenge automatisiert abgeschieden wurde. Aus diesem Behälter wurde eine Milchprobe entnommen.

Die Milchprobennahme erfolgte in mit dem Konservierungsmittel Azidiol ausgestattete Probenröhrchen. Die Proben wurden unmittelbar nach der Probennahme gekühlt an das Labor des Milchprüfrings Bayern e. V. (Wolnzach, Deutschland) geschickt und dort analysiert. Der Fett- und Proteingehalt wurden infrarotspektroskopisch analysiert. Die Wahl des Analyseverfahren basierte auf der RohMilchGütV (BUNDESMINISTERIUM FÜR ERNÄHRUNG UND LANDWIRTSCHAFT 2021).

#### **1.4. Auswertung und Statistik**

Die Performancebeurteilung der Modelle erfolgte auf Sekundenbasis. Die Klassifizierung der Modelle wurde mit den nicht für das Training genutzten gelabelten Videodaten verglichen. Dabei wurden die Sekunden, in denen richtigerweise die Verhaltensweise klassifiziert wurde als „true positive“ und die, in denen richtigerweise die Verhaltensweise nicht klassifiziert wurde als „true negative“ definiert. Wurde die Verhaltensweise fälschlicherweise klassifiziert oder fälschlicherweise nicht, so wurde das als „false positive“ bzw. „false negative“ eingeordnet. Die entstandenen Werte dienten der Berechnung der Sensitivität, der Spezifität und der Genauigkeit.

Für die Auswertung des Tierverhaltens bzw. den Vergleich des Verhaltens zwischen Betrieben, Milchleistungsgruppen und Haltungsumgebung wurde pro Betrieb und Durchgang das 24 h-Fenster mit den meisten vorhandenen Daten genutzt. Das Fenster umfasste die Zeit von 12 Uhr an einem Tag bis 12 Uhr des Folgetages. Verglichen wurden die Verhaltensdauern pro Tag, also pro 24 h-Fenster, sowie aufgeteilt für Tag und Nacht. Als Tag wurde die Zeit von 12 bis 18 Uhr plus die Zeit von 6 bis 12 Uhr des Folgetages betrachtet. Die Nacht umfasste die Zeit von 18 bis 6 Uhr des Folgetages.

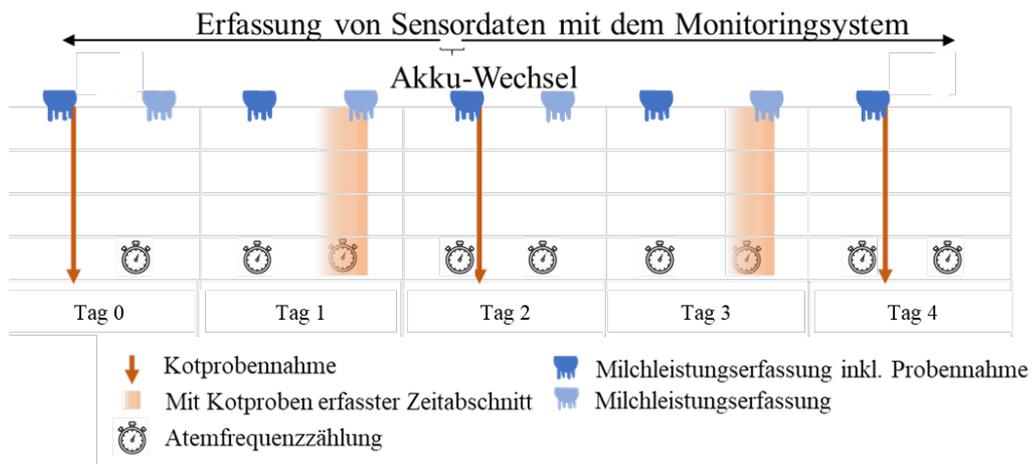
Die statistischen Auswertungen erfolgten mit RStudio 1.3 (RStudio, Inc., Bosten USA). Die Unterschiede zwischen den Durchgängen für die Dauer der einzelnen Verhaltensweisen über 24 h, sowie aufgeteilt auf Tag und Nacht, wurden mit einem generalisierten additiven Modell des Packages „mgcv“ gerechnet (WOOD 2011). Der Durchgang wurde dabei als fixer Effekt, das Tier als wiederholter Faktor integriert. Der Unterschied zwischen den Verhaltensdauern am Tag und in der Nacht für jeden Durchgang wurde mit einem Wilcoxon-Test betrachtet (BAUER 1972). Für die Darstellung der Synchronität wurde der Anteil der Tiere errechnet,

der in einer Stunde das entsprechende Verhalten für mehr als 50 % der Zeit zeigte. Das gleiche Kriterium wurde genutzt, um Fleiss' Kappa ( $\kappa_F$ ) zu berechnen (FLEISS 1971). Fleiss' Kappa ist ein statistisches Maß, das genutzt wird, um die Interrater-Reliabilität zu berechnen. Angelehnt an CRUMP et al. (2019) wurde das statistische Maß genutzt, um die Übereinstimmung (= Synchronität) des Tierverhaltens zu berechnen. Die Tiere werden dabei als Rater betrachtet. Ein  $\kappa_F$  von  $\leq 0,4$  wurde als geringgradige, von  $\leq 0,6$  als moderate, von  $\leq 0,8$  als erhebliche und von  $>0,8$  als nahezu perfekte Übereinstimmung gewertet (LANDIS und KOCH 1977). Der Zusammenhang zwischen der Parität, den Tagen in Milch, dem BCS und der Milchleistung mit der Liege-, Wiederkau- und Grasedauer wurde über die Berechnung einer Spearman-Korrelation betrachtet. Die Einteilung des Korrelationskoeffizienten ( $\varphi$ ) erfolgte nach COHEN (1988) in schwach ( $\leq 0,3$ ), mittel ( $\leq 0,5$ ) und stark ( $> 0,5$ ). Insgesamt wurden p-Werte  $< 0,05$  als signifikant und  $< 0,01$  als stark signifikant angesehen.

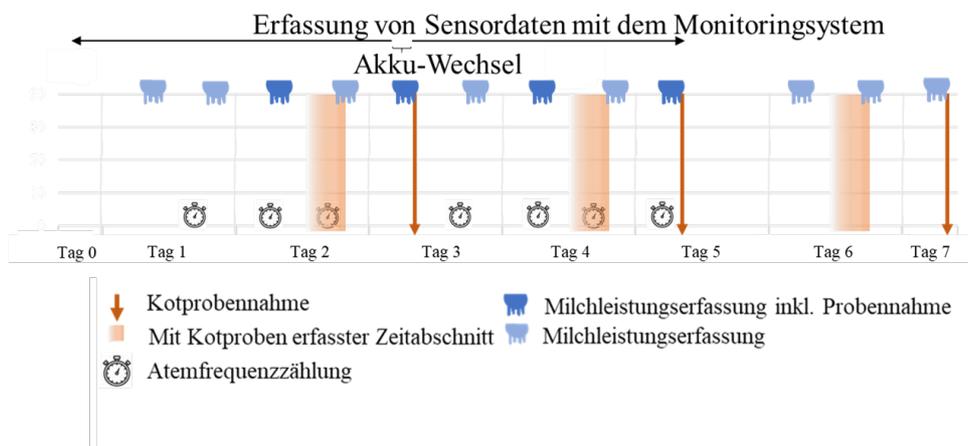
## **2. Untersuchung einer beginnenden Hitzebelastung bei Milchkühen auf der Weide**

### **2.1. Übersicht über die Datenerfassung**

Im zweiten Teil der Untersuchung sollten die mit einer Hitzebelastung einhergehenden Änderungen des Verhaltens und Abweichungen verschiedener physiologischer Parameter (Atemfrequenz, Milchleistung, Milchinhaltstoffe, Kotkortisolgehalt) im Zusammenhang mit hohen Temperaturen untersucht werden. Die Durchführung, die unter anderem die Entnahme von Kotproben umfasste, wurde von der Ethikkommission der tierärztlichen Fakultät der LMU München genehmigt (Protokoll-Nr.: 231-08-08-2020). Die Untersuchung wurde auf Betrieb 3 im Juni und August 2020 in zwei Durchgängen durchgeführt. Abbildung 6 und Abbildung 7 geben einen Überblick über die im Rahmen der Untersuchung erfassten Daten.



**Abbildung 6: Übersicht über die Datenerfassung in Durchgang 1 (Juni 2020) zur Untersuchung einer beginnenden Hitzebelastung**



**Abbildung 7: Übersicht über die Datenerfassung in Durchgang 2 (August 2020) zur Untersuchung einer beginnenden Hitzebelastung**

## V. ERSTE PUBLIKATION

Lara Schmeling<sup>1,2</sup>, Golnaz Elmamooz<sup>3</sup>, Phan Thai Hoang<sup>3</sup>, Anastasiia Kozar<sup>3</sup>, Daniela Nicklas<sup>3</sup>, Michael Sünkel<sup>3</sup>, Stefan Thurner<sup>1</sup> and Elke Rauch<sup>2</sup>

<sup>1</sup>Bavarian State Research Center, Institute for Agricultural Engineering and Animal Husbandry, Vöttingerstr. 38, 85354 Freising, Germany

<sup>2</sup>Animal Welfare, Ethology, Animal Hygiene and Animal Husbandry, Department of Veterinary Sciences, Faculty of Veterinary Medicine, Ludwig-Maximilians-University Munich, Veterinärstr. 13/R, 80539 Munich, Germany

<sup>3</sup>Mobile Systems, Faculty of Information Systems and Applied Computer Sciences, University of Bamberg, An der Weberei 5, 96047 Bamberg, Germany

### **Training and Validation a Machine Learning Model for the Sensor-Based Monitoring of Lying Behavior in Dairy Cows on Pasture and in the Barn**

Animals 2021, 11, 2660; DOI: <https://doi.org/10.3390/ani11092660>

Angenommen am 08. September 2021

Publiziert am 10. September 2021



Article

# Training and Validating a Machine Learning Model for the Sensor-Based Monitoring of Lying Behavior in Dairy Cows on Pasture and in the Barn

Lara Schmeling <sup>1,2,\*</sup>, Golnaz Elmamooz <sup>3</sup>, Phan Thai Hoang <sup>3</sup>, Anastasiia Kozar <sup>3</sup>, Daniela Nicklas <sup>3</sup>, Michael Sünkel <sup>3</sup>, Stefan Thurner <sup>1</sup> and Elke Rauch <sup>2</sup>

- <sup>1</sup> Bavarian State Research Center, Institute for Agricultural Engineering and Animal Husbandry, Vöttingerstr. 38, 85354 Freising, Germany; [stefan.thurner@lfl.bayern.de](mailto:stefan.thurner@lfl.bayern.de)
- <sup>2</sup> Animal Welfare, Ethology, Animal Hygiene and Animal Husbandry, Department of Veterinary Sciences, Faculty of Veterinary Medicine, Ludwig-Maximilians-University Munich, Veterinärstr. 13/R, 80539 Munich, Germany; [e.rauch@tierhyg.vetmed.uni-muenchen.de](mailto:e.rauch@tierhyg.vetmed.uni-muenchen.de)
- <sup>3</sup> Mobile Systems, Faculty of Information Systems and Applied Computer Sciences, University of Bamberg, An der Weberei 5, 96047 Bamberg, Germany; [golnaz.elmamooz@uni-bamberg.de](mailto:golnaz.elmamooz@uni-bamberg.de) (G.E.); [thai.hoang@uni-bamberg.de](mailto:thai.hoang@uni-bamberg.de) (P.T.H.); [anastasiia.kozar@tu-berlin.de](mailto:anastasiia.kozar@tu-berlin.de) (A.K.); [daniela.nicklas@uni-bamberg.de](mailto:daniela.nicklas@uni-bamberg.de) (D.N.); [michael.suenkel@uni-bamberg.de](mailto:michael.suenkel@uni-bamberg.de) (M.S.)
- \* Correspondence: [lara.schmeling@lfl.bayern.de](mailto:lara.schmeling@lfl.bayern.de)



**Citation:** Schmeling, L.; Elmamooz, G.; Hoang, P.T.; Kozar, A.; Nicklas, D.; Sünkel, M.; Thurner, S.; Rauch, E. Training and Validating a Machine Learning Model for the Sensor-Based Monitoring of Lying Behavior in Dairy Cows on Pasture and in the Barn. *Animals* **2021**, *11*, 2660. <https://doi.org/10.3390/ani11092660>

**Academic Editor:** Clive J. C. Phillips

Received: 14 July 2021  
Accepted: 8 September 2021  
Published: 10 September 2021

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



**Copyright:** © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

**Simple Summary:** There are various systems available for health monitoring and heat detection in dairy cows. By continuously monitoring different behavioral patterns (e.g., lying, ruminating, and feeding), these systems detect behavioral changes linked to health disorders and estrous. Most of the systems were developed for cows kept indoors, and only a few systems are available for pasture-based farms. The systems developed for the barn failed to detect the targeted behavior and thereby its changes on the pasture and vice versa. Therefore, our goal was to train and validate a machine learning model for the automated prediction of lying behavior in dairy cows kept on pastures, as well as indoors. Data collection was conducted on three dairy farms where cows were equipped with the collar-based prototype of the monitoring system and recorded with cameras in parallel. The derived dataset was used to develop the machine learning model. The model performed well in predicting lying behavior in dairy cows both on the pasture and in the barn. Therefore, the building of the model presents a successful first step towards the development of a monitoring system for dairy cows kept on pasture and in the barn.

**Abstract:** Monitoring systems assist farmers in monitoring the health of dairy cows by predicting behavioral patterns (e.g., lying) and their changes with machine learning models. However, the available systems were developed either for indoors or for pasture and fail to predict the behavior in other locations. Therefore, the goal of our study was to train and evaluate a model for the prediction of lying on a pasture and in the barn. On three farms, 7–11 dairy cows each were equipped with the prototype of the monitoring system containing an accelerometer, a magnetometer and a gyroscope. Video observations on the pasture and in the barn provided ground truth data. We used 34.5 h of datasets from pasture for training and 480.5 h from both locations for evaluating. In comparison, random forest, an orientation-independent feature set with 5 s windows without overlap, achieved the highest accuracy. Sensitivity, specificity and accuracy were 95.6%, 80.5% and 87.4%, respectively. Accuracy on the pasture (93.2%) exceeded accuracy in the barn (81.4%). Ruminating while standing was the most confused with lying. Out of individual lying bouts, 95.6 and 93.4% were identified on the pasture and in the barn, respectively. Adding a model for standing up events and lying down events could improve the prediction of lying in the barn.

**Keywords:** behavior recognition; classification; precision livestock farming; accelerometer; gyroscope; grazing

## 1. Introduction

Precision Livestock Farming (PLF) has gained importance in the dairy sector all over Europe over the last decade. The application of smart farming solutions offers great potential for improving productivity and management on dairy farms. Different studies investigated the automizing activity recognition of humans [1–3] or animals [4,5] in real environments. These studies are based on technologies such as smart environment, Internet of Things (IoT), machine learning and big data. The standard strategy applied in these studies is to use sensors and to classify the sensor data into desired activities or behavioral patterns by applying suitable machine learning models on the sensor data. This process is also used in monitoring systems for dairy cows in order to predict the behavior of animals continuously and individually. Triaxial accelerometers, e.g., combined with a magnetometer or a gyroscope, are the sensors widely used for this purpose. As the lifespan of the sensor's battery is crucial for the successful application of monitoring systems, adjusting the sampling rate can be beneficial [6,7]. As presented by Kamminga et al. [8] and Krause et al. [9], a combination of accelerometer, magnetometer and gyroscope data can provide an orientation-independent dataset that ensures sufficient accuracy of the model, even when a low sampling rate is applied.

Monitoring the health and welfare of dairy cows is time consuming. Increasing herd sizes reduces the amount of time available for the individual animal [10,11]. On a pasture, the control of animals is impeded by distances and environmental conditions. Monitoring systems assist the farmer in supervising the health and welfare of the animals and, thus, reduce the physical workload and increase schedule flexibility [12–14]. Based on behavior data, changes can be registered, and the corresponding alerts for the farmer can be generated through management software. Changes in behavior occur, e.g., during estrous and under extreme environmental conditions and with emerging health issues. Behavioral changes caused by diseases often arise before clinical symptoms appear, which allows earlier detection by using monitoring systems compared to visual examination of the animal [15–17]. The early identification of commencing health disorders enables timely treatment, resulting in minimized veterinary costs [18], reduced use of antibiotics [19,20] and rapid restoration of the welfare of the animals by limiting the pain and discomfort linked to diseases [21–23]. Identifying behavioral changes linked to extreme weather conditions enables the farmer to take preventive measurements in order to reduce the impact on the health and welfare of the animals. A reliable detection of estrous with monitoring systems results in an increased number of successful inseminations, reducing the expenses associated with missed heat events [24,25].

In addition to other behavioral patterns, lying behavior is one of the most significant indicators for estrous and health challenges including emerging health disorders and extreme environmental conditions. Total lying time, duration of lying bouts and the frequency of lying events can be either reduced or increased. On the day of estrous, e.g., dairy cows exhibit an increased level of activity at the expense of lying time [26]. Mayo et al. [27] also found a decrease in the number of lying bouts on the day of estrous. As heat dissipation is increased while standing compared to lying, animals reduce their lying time in favor of standing when temperatures are high [28,29]. Allen et al. [28] also found a decreased duration of lying bouts. Moreover, cows exposed to wet and cold weather conditions or suffering from mastitis lie down less [30,31]. On the other hand, Beer et al. [32] and Weigele et al. [33] found that lame cows show increased lying time and lying bout duration compared to sound cows. In the study of King et al. [16], dairy cows with displaced abomasum, metritis or pneumonia lie down more on the day before diagnosis, accompanied by an increased duration of lying bouts.

Apart from lying behavior, other behavioral patterns are affected by estrous, health disorders and extreme environmental conditions. The changes of those behaviors can serve as indicators used by monitoring systems as well. Reith and Hoy [34] found a relationship between decreased rumination time and estrous. Moreover, high temperatures affect rumination time, making it a useful indicator for heat load in dairy cows [35].

Barker et al. [36] used feeding time as an indicator for lameness. Reliable detections of estrous and early detection of health disorders and challenges are possible by assessing behavioral patterns and their changes individually, but combining multiple behaviors improves the information value and the detection rate. In the studies by Stangaferro et al. [21,22,23], various health disorders were detected before clinical diagnosis based on changes both in rumination time and activity.

In order to detect the behavioral patterns, e.g., lying behavior, monitoring systems can be applied to various parts of the cows' body. In the study of Borchers et al. [37], different pedometers predicted lying behavior with reasonable accuracy. Bikker et al. [38] showed that accelerometers integrated into an ear tag predicted lying in dairy cows reliably. Benaissa et al. [39] compared the performance of a leg-based and a neck-based system. Both systems performed well in predicting lying behavior, but considering other behavioral patterns, the accuracy of the neck-mounted system was higher.

Offering pastures to dairy cows is linked to various benefits. In addition to improving health [40], the animals' actions conform more to their natural behavior, expressed by an increased synchrony in feeding and lying behavior in grazing situations compared to the barn [41]. From the consumer perspective, farms with access to pastures reach higher levels of animal welfare [42]. Despite the benefits, in Europe as well as the US, the share of cows with access to pasture declined over the last years [43,44]. In addition to other region and farm specific factors, insufficient grassland constrains offering pasture to dairy cows [44]. Lack of a sufficient amount of grassland combined with rainy winters prevents year-round grazing in Central Europe [43,44]. Therefore, when offering pastures to dairy cows, a combined husbandry system of barn and pastures is practiced.

Most of the systems for monitoring dairy cows that are available on the global market have not been (properly) validated, and when the same sensor is validated in different husbandry systems, performance varies [45]. The models included in the systems for the automated prediction of different behavioral patterns, and their changes perform weakly when applied in the location they were not trained in [46,47]. The fact that offering pastures to dairy cows improves their welfare and that the demand for improved welfare increases while concurrently grazing in some parts of the world is only possible by combining the pasture and barn offers increasing market potential for hybrid monitoring solutions applicable both on pastures and in the barn [44,48].

Therefore, the goal of the presented study was to train and to evaluate a model for the automated prediction of lying behavior in dairy cows kept on pasture as well as indoors. Behavioral data derived from video observations served as ground truth. To build a reliable model, a promising combination of classifier, selected features and data segmentation, i.e., window size and stride, had to be found. The sample frequency was altered in order to reduce energy demand while maintaining high prediction accuracy. The training and validation of a model for the prediction of lying behavior are the first steps towards a system for dairy cows for automated monitoring of behavioral patterns, their changes and, thereby, the early prediction of conditions (e.g., diseases, heat load and estrous) causing those changes.

## 2. Materials and Methods

### 2.1. Data Collection and Labeling

Data were collected on three dairy farms in Upper Bavaria, Germany. All procedures performed followed the EU directive 2010/63/EU and the German Animal Welfare Act. The conducted procedures did not interfere with or deviate from regular farm practices. On all farms, the cows had access to the pasture in the summer (April to October), calving took place seasonally (November to March) and the pastures were managed continuously with the same area being available to the cows at all times.

### 2.1.1. Farm Management and Animals

On farm 1, the dairy herd consisted of 40 dairy cows that were exclusively Simmental. The mean milk yield in the preceding year was 7397 kg. Data collection was conducted in two rounds of two consecutive days, each in September and October 2018. During the trial, cows were kept on a pasture (17 ha; see Table 1) and milked twice daily at approximately 06.00 and 17.00 h in a herringbone milking parlor. For two hours around each milking time, the cows were given access to a freestall barn with deep straw-bedded cubicles ( $n = 40$ ). During morning milking, a negligible portion of grass or maize silage mixed with concentrate was fed in the barn. Water was supplied ad libitum via seven troughs on pasture and two in the barn. Several mineral lickstones were available on the pasture and in the barn. Five (round 1) and eight (round 2) lactating cows were randomly chosen from the herd. Only animals in the second to sixth lactation were selected. Cows were clinically healthy and free from lameness, changes in milk composition or any other clinical signs of health disorders. The average parity of the selected animals was  $3.4 \pm 0.5$  (mean  $\pm$  standard deviation; round 1) and  $3.5 \pm 1.2$  (round 2). The cows were  $227 \pm 28$  and  $285 \pm 40$  days in milk (DIM) on the first day of each round, respectively. The average Body Condition Score (BCS) was  $3.2 \pm 0.5$  and  $3.1 \pm 0.4$  on the first day of each round, respectively. BCS was defined based on the figure by Edmonson et al. [49] modified after Metzner et al. [50].

**Table 1.** Sward composition (grasses, herbs and legumes) of pastures on farm 1 and farm 2.

	Farm 1	Farm 2
Grasses (%)	64	30
- <i>Lolium perenne</i>	47	24
- <i>Poa pratensis</i>	9	5
- <i>Festuca pratensis</i>	8	1
- <i>Poa trivialis</i>	<1	<1
Legumes (%)	36	70
- <i>Trifolium repens</i>	36	70
Herbs (%)	3	2
- <i>Plantago major</i>	2	1
- <i>Taraxacum</i> sect. <i>Ruderalis</i>	<1	<1
- <i>Bellis perennis</i>	<1	<1

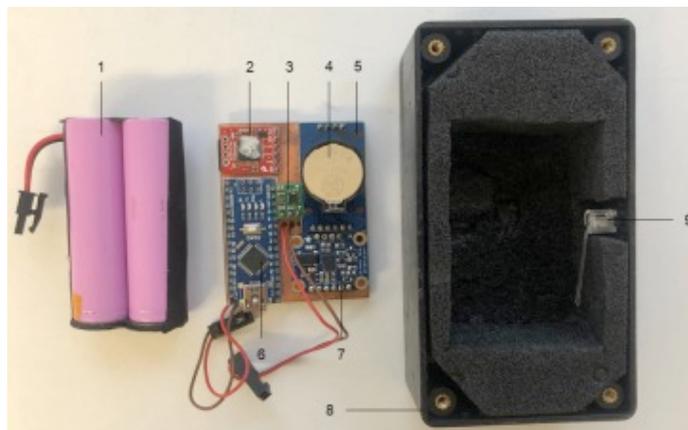
On farm 2, the dairy herd consisted of 34 dairy cows that were exclusively Simmental. The mean milk yield in the preceding year was 7437 kg. Data were collected on three consecutive days in July 2019. During the day, cows were kept on a pasture (12 ha; see Table 1) with permanent access to a freestall barn with deep litter cubicles ( $n = 34$ ). Between afternoon and morning milking, which was performed at 16.00 and 07.30 h, the cows were kept on a smaller pasture (3 ha; see Table 1) without access to the barn. Before each milking, a negligible portion of maize silage mixed with concentrate and minerals was fed. Water was supplied ad libitum via five troughs on the day pasture, one on the night pasture and two in the barn. Eleven lactating cows were randomly selected from the herd based on the same criteria applied on farm 1. The average parity of the selected cows was  $4.0 \pm 0.9$ , and they were  $273 \pm 16$  DIM on the first day of the trial. Average BCS was  $3.0 \pm 0.6$  on the first day of the trial.

On farm 3, the dairy herd consisted of 52 dairy cows that were mainly Simmental (46 Simmental, 3 Red HolsteinXSimmental, 1 Red Holstein, 1 German Black Pied and 1 German Red Pied). The mean milk yield in the preceding year was 8232 kg. Data were collected on four consecutive days in March 2019. Due to winter weather, the cows were kept in a freestall barn with high cubicles ( $n = 48$ ) equipped with rubber mattresses. The cows were milked twice a day in a tandem milking parlor at approximately 06.00 and 18.00 h. The cows were fed a mixed ration (containing maize and grass silage, concentrate and minerals) twice a day at approximately 10.00 h and during afternoon milking. Feed remains were removed before the next feeding. Additional concentrate was offered in a

computerized feeder to cows with a milk yield of  $\geq 35$  kg/d within the last five days. Water was supplied ad libitum via two troughs. Several mineral lickstones were available. Eleven lactating cows were randomly chosen from the herd based on the same criteria applied on the other farms. The average parity of the selected cows was  $3.8 \pm 1.4$ , and they were  $103 \pm 40$  DIM on the first day of the trial. The average BCS was  $3.8 \pm 0.4$  on the first day of the trial.

### 2.1.2. Collection of Sensor and Ground Truth Data

On all farms, the selected animals were equipped with the prototype of the monitoring system (see Figure 1;  $133 \times 63 \times 35$  mm; 220 g; Blaupunkt Telematics GmbH, Hildesheim, Germany) attached to a collar. The case was located at the lower neck of the animals (see Figure 2). The system contained a sensor from Bosch (BNO055; Bosch Sensortec GmbH, Reutlingen, Germany) including a three-dimensional (3D) accelerometer, a 3D magnetometer and a 3D gyroscope. The settings were selected to measure the linear acceleration ( $m/s^2$ ) with the accelerometer and the Euler angle ( $^\circ$ ) by fusing the values from all nine axes (=NDOF operating mode). Data collection frequency was set to 10 Hz. Raw data were stored on an integrated SD memory card (32 GB; SanDisk; Western Digital Deutschland GmbH, Aschheim, Germany) and downloaded after each round. Two rechargeable lithium batteries (Samsung ICR18650 26H; Samsung Group, Seoul, South Korea) served as a power supply. A General Positioning System (GPS) sensor (NEO-6; u-blox Holding AG, Thalwil, Schweiz) (farm 1) and a real-time clock (RTC; DS3231; Maxim Integrated Products, Inc., San Jose, CA, USA) (farm 2 and 3) were used for time synchronization of the sensor system.



**Figure 1.** Composition of the prototype of the monitoring system from Blaupunkt Telematics GmbH (Hildesheim, Germany) and the included sensor board: 1—lithium batteries (Samsung ICR18650 26H; Samsung Group, Seoul, South Korea); 2—data logger (SparFun OpenLog ATmega328; SparFun Electronics, Niwot, CO, USA) containing a Secure Digital Memory Card (32 GB; SanDisk; Western Digital Deutschland GmbH, Aschheim, Germany); 3—voltage regulator (S18V20ALV; Pololu Robotics & Electronics, Las Vegas, NV, USA); 4—lithium button cell (CR2032; Varta Consumer Batteries GmbH & Co. KGaA, Ellwangen, Germany); 5—real time clock (DS3231; Maxim Integrated Products, Inc., San Jose, CA, USA); 6—controller (Arduino Nano V3 with CH340; AZ-Delivery Vertriebs GmbH, Deggendorf, Germany); 7—breakout board (9-DOF Absolute Orientation IMU Fusion Breakout; Adafruit, New York, NY, USA) containing the system in the package (BNO055; Bosch Sensortec GmbH, Reutlingen, Germany) combining a 3D accelerometer, a 3D magnetometer and a 3D gyroscope; 8—case of the prototype (Hammond 1591;  $133 \times 63 \times 35$  mm; Hammond Manufacturing™, Frankfurt am Main, Germany) with handmade foam; 9—LED to show functionality of the system.

In order to collect ground truth data, the behavior of the animals was recorded with cameras (GoPro HERO5; GoPro, Inc., San Mateo, CA, USA). Superview, 1920 × 1080 pixel and 60 frames per second were set for the recordings. In order to allow continuous recording of the selected animals on pasture, four to five cameras were attached to tripods and repositioned frequently by two to four observers. In order to avoid behavioral disturbance, observers remained at adequate distances from the herd. In the barn, seven cameras were installed at fixed positions. The time of the videos was synchronized with radio-controlled clocks (Hama GmbH & Co KG, Monheim, Germany) that were visible in the camera image. Since the animals on all three farms became used to wearing the collar with the prototype very quickly, the observation begun around one hour after attachment.



**Figure 2.** Prototype of the monitoring system (Blaupunkt Telematics GmbH; Hildesheim, Germany) mounted on the collar of a Simmental cow grazing pasture.

Following the observations, the videos were labeled, i.e., the behavior of the observed cows was defined at all times based on an ethogram (see Table 2) by one trained observer. The ethogram consisted of exclusive behavioral patterns such as lying down, standing up, standing, walking, grazing and activities that overlapped with behaviors such as feeding, chewing, ruminating, drinking and others. Behavior definitions were derived from Martiskainen et al. [51], Reiter et al. [52] and Werner et al. [53]. In order to identify the animals in the video, numbers were sprayed on the flank, and the individual coat patterns were used. Data from all animals on all days from farm 1, all animals on one day from farm 3 and three animals on one day from farm 2 were labeled in detail. For the remaining data, differentiation was only made for lying and non-lying, with non-lying including all behaviors except for lying. Labeled video data were regarded as ground truth. Labeling was performed by one observer exclusively. In order to assess observer reliability, 20% (=26 h) of video data from farm 1 were labeled twice by the same observer. Time frames of ten minutes were randomly distributed among rounds, days, animals and time of day. The outputs of both labeling processes were compared second by second.

**Table 2.** Ethogram of dairy cow behavior used for labeling the video data in order to generate ground truth data. Definitions were derived from Martiskainen et al. [51], Reiter et al. [52] and Werner et al. [53].

Behavior	Definition
Lying	The body of the animal is not supported by any limb. The sternum and/or the belly are/is in contact with the ground. The limbs are bent or stretched out.
Lying down	The transition from standing/walking to lying. From bending one forelimb to completely lying.
Standing up	The transition from lying to standing/walking. From stretching the shoulders to standing on four limbs/walking.
Lying bout	Time between a lying down and a standing up event.
Standing - In the cubicle; - In the alley; - At the feeding table; - In the feeder.	The body of the animal is supported by at least three limbs: - At least two feet are located in the cubicle; - At least three feet are located in the alley; - The head is above the feeding table; - All four feet are located within the area of the feeder.
Walking	The animal moves forward or backwards at walking pace and makes two or more consecutive steps in one direction.
Grazing	The animal bites off grass, chews and swallows it and moves forward with a lowered head. From the first grip of grass to the lifting of the head higher than the carpal joint.
Feeding	The muzzle of the animal is located beneath the lower margin of the feeding fence and in the feed.
Chewing	The animal moves its lower jaw in a grinding movement without having regurgitated before.
Ruminating	The animal regurgitates food bolus, chews and swallows it. From regurgitating the first bolus to swallowing the last bolus.
Drinking	The muzzle of the animal is located below the outer margin of the trough consuming water.
Other	Social, comfort, exploration and fly repellent behavior.
Idle time	The animal is not visible in the video image or covered by another animal.

## 2.2. General Process of Data Acquisition and Model Development

The main goal of the developed prediction framework is to build behavior recognition models in order to analyze the dairy cows' behavior. This framework includes two phases: training and validation. In this paper, we focus on lying behavior, but the framework can generally recognize a bigger variety of the dairy cows' behavior. The goal of the training phase (Figure 3) is to create supervised prediction models that can be applied to new sensor data, which are unknown to the model. In this phase, the sensor data from a field experiment are labeled by a domain expert who observed the videos that were made during the experiment.



**Figure 3.** Procedure of the training phase that consists of two steps: preprocessing and model training. The goal of this step is to create prediction models that can be applied to new sensor data.

The training phase consists of two main steps: preprocessing and model training. Since the data coming from sensors contain noisy data or inconsistent timestamps, they require the application of preprocessing techniques. These techniques, e.g., noise reduction and time synchronization, etc., are needed to create necessary datasets for training and to enhance the accuracy of the learned models. During the training of the model, the data are classified by a learning algorithm where the classes are the different behavioral patterns of dairy cows (=labels). The output of the training phase consists of learned models, which were created after the model training. These models comprise training dataset specifications, e.g., training time and number of cows, which include the following: which preprocessing techniques were applied, what should be predicted (e.g., lying vs. non-lying), which learning algorithm is executed (e.g., random forest with defined parameters), which dataset is used for testing, which evaluation metrics are used (e.g., accuracy and recall, etc. and the result achieved (e.g., 90% accuracy). The accuracy was measured as a ratio between all correct outcomes and all possible outcomes using the Python 3 package scikit-learn 0.22.2 (<https://scikit-learn.org/0.22/>, accessed on 2 September 2021).

During the prediction phase (Figure 4), new sensor data are applied to the learned models in order to obtain useful reports for the end user. The goal of this phase is to check the validity of the trained models which were created in the previous phase. Therefore, new unlabeled data will be applied to the learned models in order to create insights. These insights will be cross-checked by a domain expert in order to determine the validity of the trained model's outcome. Valid reports will be classified as useful and sent to the end user. In case no useful reports can be developed, the model will be redirected to the first phase, where either new or improved models will be created. In this study, we evaluated whether the behavior recognition is suitable for higher level behavior analytics. Thus, in Figure 4, the steps "behavior analytics" and "specification of useful reports", which are marked white, were performed only partially (only the learned model was evaluated but not the reports) or were disregarded (no reports were created because there was no end user).



**Figure 4.** Procedure of the prediction phase, which includes applying new data to the trained models for validation of their prediction performance.

### 2.3. Feature Selection and Model Development

The selection of a model or the combination of a feature set with a corresponding classifier is perhaps the most important phase in building a behavior recognition system, as it was also shown by Bersch et al. [54].

#### 2.3.1. Feature Selection

For behavior recognition problems, which rely on time-series sensor data, data segmentation is the most common approach for partitioning a data stream into time-based windows. Those data segments are used for feature extraction and selection. In our study, instead of classifying every data point from the sensor data stream, a segmentation technique was used to divide the data into windows of data points from which the features were computed. The selection of the right segmentation technique, in terms of window size and stride, is crucial to the systems' performance. At the level of a time-based window, the length of window indicates the volume, while the frequency of a window update (stride length) reflects the velocity in collecting the sensor data. In order to find the best segmentation strategy, we assessed window sizes from 1 to 20 s, with strides from 25 to

100%. A feature was derived by applying a mathematical function on a series of values of a sensor axis (or derived axis) over a window of data (Equation (1)).

$$\underbrace{\{x_1, x_2, \dots, x_n\}}_{\text{Window}} \xrightarrow{f} \text{Feature} \quad (1)$$

Generally, features in the field of behavior recognition can be grouped into three major types (time-domain, frequency-domain and discrete-domain), which were presented in Figo et al. [55]. Out of the three types, time-domain and frequency-domain are most commonly used in research concerning behavior recognition [2,3,7].

The problem of sensor orientation has been recognized in many studies which showed that the variability in sensor orientation attached to dairy cows brings about significant errors in classifier performance. A notable research study, which also tackled this problem, is the one from Kamminga et al. [8], where a feature set that is robust relative to the sensor orientation was explored and evaluated using various classifiers.

The effect of sensor data with different orientation on the various classifiers' performance was verified by implementing two feature sets. The first set was known to be sensitive to sensor orientation and comprised 24 features, which were formed by applying four functions, i.e., max, mean, median and standard deviation over the six axes of the two sensors. The second set was insensitive to sensor orientation and was constructed by applying 18 functions, namely min, max, mean, median, standard deviation, interquartile range, root mean square, mean crossing rate, kurtosis, skewness, spectral energy, peak frequency, frequency domain entropy and the first five feature frequency profile components on two derived axes: the magnitudes of the 3D accelerometer and the NDOF vector, respectively. Features were selected based on their importance by using the Python 3 scikit-learn 0.22.2 package (<https://scikit-learn.org/0.22/>, accessed on 2 September 2021).

### 2.3.2. Model Selection and Development

During the model selection process, random forest, decision tree, support vector machine and naive Bayes were selected (Table 3) for the experiment based on their previous success in the prediction of cow behavior, including lying [39,51,56,57]. The features used were consistent between the models.

**Table 3.** Classifiers with corresponding selected hyperparameters. The hyperparameters were tuned by an exhaustive grid search method in order to find the optimized parameters for each model.

Classifier	Hyperparameters
Random Forest	Number of trees: 95 Criterion: Gini (calculates the probability of a specific feature classified incorrectly when selected randomly) Splitter: choose the best split at each node Maximum depth of tree: 25 Minimum number of samples required to split an internal node: 2 Minimum number of samples required to be a leaf node: 1 Maximum number of features used at each split: 6
Decision Tree	Criterion: Gini Maximum depth of the tree: 5 Minimum number of samples required to split an internal node: 2 Minimum number of samples required to be a leaf node: 1
Support Vector Machine	Kernel: Radial Basis Function—RBF Regularisation parameter: 10 Kernel Coefficient (gamma): Scale
Naive Bayes	Type: Gaussian

Table 3 shows the classifiers together with the corresponding selected hyperparameters. The hyperparameters were tuned by exhaustive grid search method in order to find the optimized parameters for each model. A 10-fold cross-validation was used to estimate the performance of the model in the train-validation phase. The framework implementation and model parameter comparison were implemented using Python 3 and its scikit-learn 0.22.2 package (<https://scikit-learn.org/0.22/>, accessed on 2 September 2021).

#### 2.4. Postprocessing

Filtering is a crucial part of data postprocessing. It displays a clear sequence of procedures or steps that must be followed in order to obtain reasonable and understandable results. The data that are the result of a knowledge acquisition (prediction) algorithm are usually noisy and sometimes inconsistent. In the case of the mentioned framework, filtering was applied to avoid unnecessary small breaks between similar or same activities. From an ethological point of view, filtering is supported by the fact that behavior that occurs in bouts, such as lying behavior, requires an interbout criterion [58]. An interbout criterion separates short interruptions of a behavioral pattern between events from interruptions between bouts. After extensive parameter comparison, the decision was made towards 60 s time period. For example, if lying lasted for a considerable amount of time after the prediction part the behavior then stopped for less than 60 s and then started again, it was likely that it was either a prediction mistake or an unnecessary small side behavior (noise) that could have been emitted. By applying the filter, sequences of lying or non-lying, with duration less than 60 s, were filtered and added to the behavior predicted for the time period preceding the sequence. The filter not only helps specifying individual lying bouts but also improves overall prediction accuracy.

#### 2.5. Evaluation of the Model and Statistical Analysis

Data which were not used for the training of the model served as a basis for the evaluation. In order to assess performance, the outputs of the model and the ground truth were compared per second. Pure data (i.e., without overlapping) and data points with overlapping behaviors were used for the evaluation of the model. Data points (=seconds) correctly identified as lying behavior were defined as true positive (TP), and data points correctly identified as non-lying behavior as true negative (TN). Data points of lying behavior that were classified as non-lying behavior by the model were considered as false positive (FP), and data points of non-lying behavior that were classified as lying by the model were considered as false negative (FN). Sensitivity, specificity and accuracy, as well as positive and negative predictive values, were calculated according to the following equations.

$$\text{Sensitivity} = \frac{\text{TP}}{(\text{TP} + \text{FN})} \quad (2)$$

$$\text{Specificity} = \frac{\text{TN}}{(\text{TN} + \text{FP})} \quad (3)$$

$$\text{Accuracy} = \frac{(\text{TP} + \text{TN})}{(\text{TP} + \text{TN} + \text{FN} + \text{FP})} \quad (4)$$

$$\text{Positive predictive value} = \frac{\text{TP}}{(\text{TP} + \text{FP})} \quad (5)$$

$$\text{Negative predictive value} = \frac{\text{TN}}{(\text{TN} + \text{FN})} \quad (6)$$

Performance parameters were calculated in total as well as for every animal on every day separately. Lying bouts were considered as identified when an overlap between ground truth and the model output occurred. Regarding duration, only lying bouts without interruption caused by missing visibility in the video image or a gap in the sensor data

were considered. Only bouts completely recorded both in ground truth and model output were compared.

The influence of animal, day, farm and location (pasture vs. barn) on the sensitivity, specificity and accuracy of the model was analyzed with generalized additive models by using the *mgcv* package in RStudio 1.3 (RStudio, Inc., Boston, MA, USA; [59]):

$$Y_{ijkl} = f_i + d_j + l_k + a_l + e_{ijkl} \quad (7)$$

where

$Y_{ijkl}$  = value of performance (sensitivity, specificity and accuracy);

$f_i$  = fixed effect for farm;

$d_j$  = fixed effect for day;

$l_k$  = fixed effect for location (pasture/barn);

$a_l$  = repeated effect for animal;

$e_{ijkl}$  = random residual.

Farm, day and location were set as fixed effects. The animal was set as a random effect. In order to further analyze the influence of the day within one farm, the same model was used, leaving out farm and location as fixed effects. The difference between the duration of lying bouts in ground truth and model output and the difference between performance during the day compared to the night was evaluated using Wilcoxon test. Kendall's correlation coefficient was calculated to assess the relation between standing time and accuracy, sensitivity and specificity. The correlation coefficient was categorized as follows: 1 = perfect; 0.9 to 0.7 = strong; 0.6 to 0.4 = moderate; and <0.4 = weak correlation.

In order to evaluate the duration of lying behavior over 24 h and the differences between husbandry system, the model was applied to one day (the day with the most data available) on each farm. Only animals with <10% of missing sensor data according to Elischer et al. [47] were included in the evaluation. For the comparison of lying time between husbandry systems, a one-sided ANOVA [60] and a post hoc test with Bonferroni correction was performed [61]. In order to verify homogeneity of variances, a Levene's test [62] was performed and residuals' distribution was tested for normality by Shapiro–Wilk test [63]. With a Wilcoxon test, we compared the lying duration during the day (06.00 to 18.00 h) and the night (18.00 to 06.00 h) for each farm separately. Analysis of differences in lying time between husbandry systems was performed in RStudio 1.3 (RStudio, Inc., Boston, MA, USA). Where applicable, *p*-values < 0.05 were considered as significant.

### 3. Results

#### 3.1. Collected Data

In total, 1864.0 h of sensor data and 542.2 h of ground truth data were collected, resulting in 538.7 h of complete datasets with concurrent sensor and ground truth data. The data from one animal, each on farm 1 and farm 3, were disregarded because the cows showed symptoms of estrous within the observation round. The data from three animals from farm 1 were used for the training of the model (see Table 4). Regarding training data, only pure data, i.e., without other activities (e.g., ruminating and social behavior) overlapping, were used. Disregarding the data from the animals in heat and the three animals from farm 1, which were used for training of the model, 476.2 h of datasets were left for the evaluation of the model. The performance of the model on pasture and in the barn was assessed separately. On pasture, 238.7 h of datasets were collected (farm 1 and farm 3), and 237.5 h of datasets were collected in the barn (farm 2 and farm 3). The amount of collected data differed between farms, rounds and days (see Table 5) due to different availability and runtime of sensor systems. On farm 1 and 2, all data were collected during the day, i.e., in the time period from 06.00 to 18.00 h. On farm 3, 24.6 h of data were collected in the time period between 18.00 and 06.00 h, and the remaining data were collected during the day.

**Table 4.** Behavior instances distribution used for training the model. The training dataset contains the data of three animals from farm 1.

	Amount of Instances	Instances (%)
Grazing	778,867	51.0
Lying	491,522	32.2
Walking	116,175	7.6
Standing	139,707	9.2
Total	1,526,271	100.0

**Table 5.** Amount of datasets collected for the evaluation of the model. Differences in amount of collected datasets are based on different availability and runtime of sensors between farms, rounds and days.

	Farm Location	1		2		3	
		Pasture	Pasture	Barn	Barn	Barn	Barn
Total (h)		106.0	132.7	51.4	186.2		
Round 1	Day 1 (h) (no. of cows)	14.4 (3)	32.2 (11)	23.3 (10)	20.2 (4)		
	Day 2 (h) (no. of cows)	27.5 (5)	44.8 (11)	25.9 (10)	41.2 (7)		
	Day 3 (h) (no. of cows)	-	55.7 (10)	2.2 (3)	65.7 (8)		
	Day 4 (h) (no. of cows)	-	-	-	59.1 (7)		
Round 2	Day 1 (h) (no. of cows)	36.1 (6)	-	-	-		
	Day 2 (h) (no. of cows)	28.0 (6)	-	-	-		

### 3.2. Observer Reliability

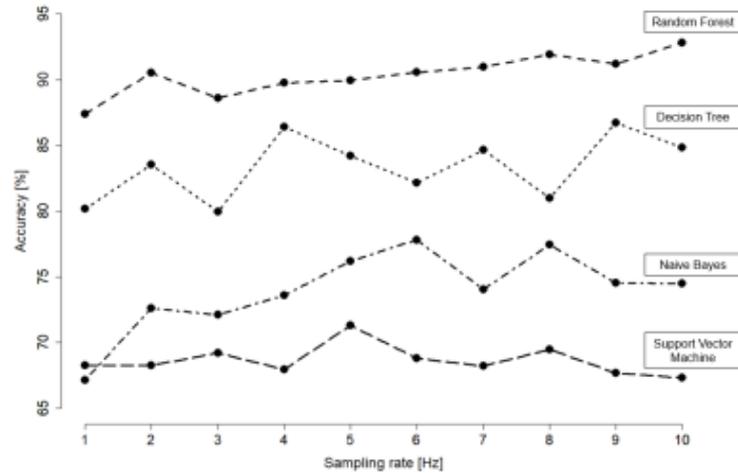
Of all data, 20% (equalling 26 h) of data from farm 1 were coded twice. The agreement between the first labeling and the second labeling was 94.8% for detailed labeling and 100% for lying and non-lying.

### 3.3. Model

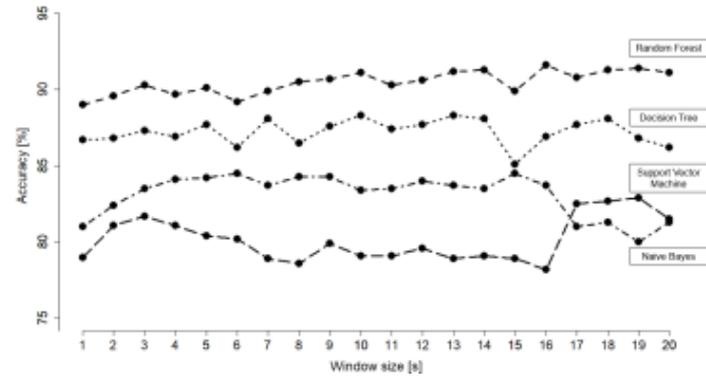
In order to evaluate the four classifiers (random forest, decision tree, naive Bayes and support vector machine) selected from Section 2.3.2, the sensor data from six dairy cows from two different farms (three from farm 1 and three from farm 2) were used to train and evaluate the models. Data distribution can be observed in Table 4. Since the orientation of the sensors used on the first farm was different from the second farm, the datasets were mixed so that it was possible to create training and testing datasets, which contained different orientation sensor data.

The comparison that can be observed in Figures 5 and 6 showed that random forest was the classifier that yielded the highest accuracy in comparison to the other three classifiers. Since the sampling rate has effects on the energy consumption of the sensor system, we studied the effects of reducing the sampling frequency in the data from its original rate of 10 Hz down to 1 Hz. However, from Figure 5 we can observe that 10 Hz proved to be the most effective sampling rate, which brought the highest accuracy for random forest. Hence, we used the original rate in further works.

The comparison of the different window sizes can be found in Figure 6. The window size parameter was chosen to be 5 s as a trade-off between the accuracy and the prediction latency.



**Figure 5.** Accuracy comparison of the different classifiers (random forest, decision tree, naive Bayes and support vector machine) based on different sampling rates (1–10 Hz). The postprocessing filter was not applied for this comparison.



**Figure 6.** Accuracy comparison of the different classifiers (random forest, decision tree, naive Bayes and support vector machine) based on different window sizes (1–20 s). The postprocessing filter was not applied for this comparison.

In addition to window size, the stride of windows had to be defined. We compared a stride of 25, 50 and 100% (results not shown), and 100% was found to be the most accurate for random forest and a window size of 5 s.

The two sets of features combined with four classifiers presented previously brought eight different models for the experiment. Since it was found to achieve the highest accuracy, the following section will present the result that was obtained using the random forest classifier. The two sets of features selected in Section 2.3.1 combined with random forest created the following two models (see Table 6).

**Table 6.** The two selected models based on the random forest classifier with two different sets of features (orientation-dependent/orientation-independent).

	<b>Model 1</b>	<b>Model 2</b>
Classifier	Random Forest	Random Forest
Window size	5 s	5 s
Feature set	24 features	36 features
	This model is predicted to be sensor orientation sensitive	This model is known to be insensitive to sensor orientation

Firstly, we used the data of six dairy cows in order to implement the subject cross-validation to observe how different orientation sensor data affect the model's performance. The training and testing data were set up for evaluation in the following manner: only the cows that did not participate in training were allowed to participate in the testing process.

The following result was obtained when the two models were both trained and tested on data from farm 1 (=sensor data with the same orientation). From Table 7, it can be concluded that model 1 experienced overfitting and instability, unlike model 2. However, both models produced fairly high accuracy.

**Table 7.** Accuracy of the two models with different feature sets (orientation-dependent/orientation-independent) when both trained and tested on farm 1 (=same sensor orientation).

		<b>Model 1 (%)</b>	<b>Model 2 (%)</b>
Train-valid accuracy	Mean	95.8	92.2
	SD	0.5	0.8
Test accuracy	Mean	88.7	92.0
	SD	5.6	2.8

Table 8 shows the performance of the two models when they were trained on data from farm 1 but tested on data from farm 2 (different sensor orientation). It is clear that the test accuracy produced by model 1 was experiencing both considerable decrease and instability while, model 2 remained stable in performance. This result once again confirmed the robustness of the model having an orientation-independent 36 feature set, which was derived by applying 18 functions over the magnitudes of the accelerometer and the NDOF vector as described in Section 2.3.1. This 36 feature set was, therefore, selected as the feature set for the following evaluation.

**Table 8.** Accuracy of the two models with different feature sets (orientation-dependent/orientation-independent) when trained on farm 1 and tested on farm 2 (=different sensor orientation).

		<b>Model 1 (%)</b>	<b>Model 2 (%)</b>
Train-cross accuracy	Mean	95.7	92.1
	SD	0.5	0.7
Test accuracy	Mean	73.9	91.1
	SD	20.8	4.3

The conducted experiment resulted in two datasets with data from different sensor orientation. This experiment showed slight improvement in the overall accuracy for the selected model. Moreover, it was found that the training data from only three dairy cows were enough for the model to gain sufficient generalization. In further experiments, we found that selecting more than three cows did not improve the accuracy of the model (data not shown). As a result, the most feasible model was obtained by training the 36 feature random forest model with the sensor data from three dairy cows from the same farm (farm 1).

### 3.4. Performance of the Model

Overall sensitivity, specificity and accuracy of the model with applied filter were 95.6%, 80.1% and 87.3%, respectively. Lying behavior was predicted with a positive predictive value of 80.5% and a negative predictive value of 95.5%. Overall accuracy on pasture (93.1%) was higher than the accuracy in the barn (81.4%). Within farm 2, the model predicted lying behavior with an accuracy of 91.0% on pasture and 86.3% in the barn.

Total median accuracy per animal and day was 91.7%. Median accuracy per animal and day on pasture and in the barn was 95.3% and 84.4%, respectively. Median accuracy per animal and day on pasture was significantly higher than in the barn ( $p < 0.01$ ). In total, the farm had a significant effect on the median accuracy per animal per day ( $p < 0.01$ ). Highest accuracy was achieved on farm 1, followed by farm 2. On farm 3, the lowest accuracy was attained. Although there were differences in accuracy between animals, there was no significant effect of the animal on the accuracy per animal and day ( $p = 0.31$ ).

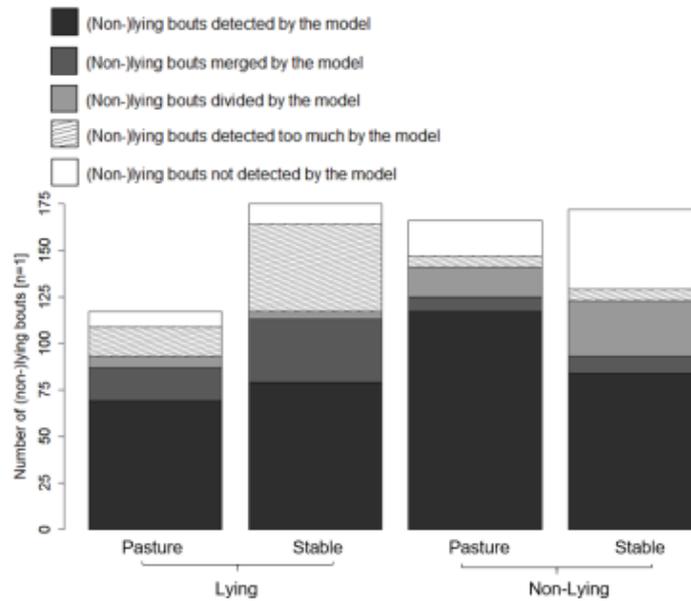
In general, the day had a significant effect on the accuracy per animal and day ( $p < 0.05$ ). The comparison between the performance of the model within one farm showed significant differences between days on farm 1 and 3. On farm 1, the accuracy per animal on day 2 was significantly lower than on day 1 and day 4 ( $p < 0.05$ ). There were no significant differences between the other days. On farm 3, accuracy per animal on day 1 was significantly lower than on day 2 ( $p < 0.05$ ). There were no significant differences between the other days.

On farm 3, a part of the data was collected in the time period between 18.00 and 06.00 h. No difference was found between the accuracy per animal and day during the night and during the day ( $p = 0.46$ ). In general, the model overestimated lying time at the expense of non-lying time. In total, 54.7% of the observed time was classified as lying by the model, while lying time shared 46.1% in ground truth.

Lying behavior falsely classified as non-lying (FN) amounted to 5.5 h on pasture and 4.2 h in the barn, equaling 2.3 and 1.8% of the observed time. Of non-lying behavior, 11.0 (4.5%) and 40.0 h (16.8%) were misclassified as lying (FP) outdoors and indoors, respectively. Of the FP time recorded on pasture and in the barn, 4.0 and 11.1 h of the FP were labeled and evaluated in detail. On pasture, 1.8 h of the FP time was located before, after or in between lying periods. The remaining 2.2 h could not be linked to a lying event. With 58.8%, ruminating while standing was the behavioral pattern confused the most with lying, followed by standing and walking with 20.0 and 8.9%. In the barn, 6.9 h of the FP time was located before, after or in between lying periods. The remaining 4.2 h could not be linked to a lying event. With 53.8%, ruminating while standing was the behavioral pattern confused the most with lying as well. Standing in the cubicle (without ruminating) was the second most common pattern falsely classified as lying with 25.6%.

Since standing (in the cubicle) was the behavior confused the most with lying, specificity as well as accuracy per animal and day was negatively correlated ( $r = -0.53$  and  $r = -0.60$ ;  $p < 0.01$ ) with the share of standing behavior of the observed time. While standing shared 9.9% of the total observed time on pasture, 47.6% standing time occurred in the barn.

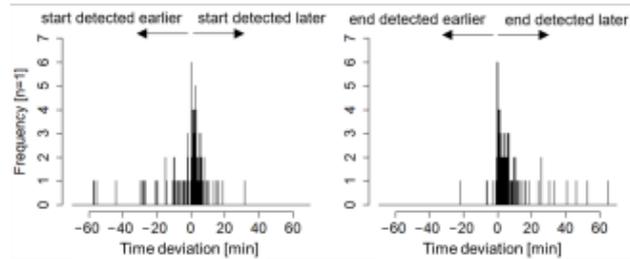
The detection of individual lying bouts and non-lying bouts by the model is presented in Figure 7. Of the lying bouts, 93.3% and 96.4% and 88.7% and 75.7% of the non-lying bouts were identified by the model on the pasture and in the barn, respectively. Three of the lying bouts on pasture, one of the lying bouts in the barn and one non-lying bout on pasture lasted  $< 60$  s, i.e., the duration was lower than the filter of 60 s that was applied to the sensor data. The median duration of the lying bouts and the non-lying bouts that were not detected by the model was 3.0 min and 4.0 min, respectively. Median duration of lying bouts and non-lying bouts that were detected too much by the model was 6.5 min and 5.0 min, respectively.



**Figure 7.** Detection of individual lying bouts and non-lying bouts including detected, merged, divided, missed and added bouts.

On pasture, 44 lying bouts were classified correctly by the model and identified without interruption, both in ground truth and model output. Thus, those lying bouts could be compared regarding their duration. Median duration of the lying bouts did not differ between ground truth and model output (57.7 vs. 56.6 min) on pasture. In the barn, 37 lying bouts could be compared regarding their duration. Duration of lying bouts differed significantly ( $p < 0.01$ ) between ground truth and model output (42.3 vs. 58.2 min).

In total, the beginning of 159 and the ending of 161 lying bouts was assessed in detail. Only eight beginnings and six endings were correctly identified by the model within  $\pm 4$  s compared to ground truth, but 88.6% of the beginnings and 84.4% of the endings were detected within  $\pm 10$  min (see Figure 8). Most beginnings ( $n = 116$ ) and endings ( $n = 129$ ) were detected too late by the model with a median deviation in time of 2.3 and 4.1 min.



**Figure 8.** Deviation in detected beginnings (left) and endings (right) of lying bouts by the model compared to Ground Truth.

### 3.5. Lying Behavior in Different Husbandry Systems

For comparison of lying behavior over 24 h between husbandry systems (=farms), one day of each farm was chosen based on the availability of sensor data. The lying time of four (farm 1), nine (farm 2) and eight (farm 3) animals was included in the comparison. The mean ( $\pm$ standard deviation) for each farm can be observed in Table 9. The lying time on farm 3 was significantly higher than on farm 1 and farm 2 ( $p < 0.05$ ). On farm 1 and farm 2, lying time did not differ significantly ( $p = 1.0$ ). Although numerically higher during the night, lying time did not differ significantly ( $p = 0.20$ ) between daytime and nighttime (4.8 vs. 7.1 h). On farm 2, lying time during the day and during the night was similar (6.2 vs. 6.8 h;  $p = 0.48$ ). Lying time during the day was numerically but not statistically higher than during the night on farm 3 (8.2 vs. 7.8 h;  $p = 0.18$ ).

**Table 9.** Comparison of lying times (mean  $\pm$  standard deviation) over 24 h and during daytime (06.00 to 18.00 h) and nighttime (18.00 to 06.00 h) between the different farms (=husbandry systems).

	Farm 1	Farm 2	Farm 3
lying time/d (h)	12.3 ( $\pm 0.8$ )	12.2 ( $\pm 0.6$ )	15.6 ( $\pm 1.3$ )
lying time daytime (h)	4.8 ( $\pm 0.6$ )	6.2 ( $\pm 0.5$ )	8.2 ( $\pm 0.6$ )
lying time nighttime (h)	7.1 ( $\pm 1.9$ )	6.8 ( $\pm 1.3$ )	7.8 ( $\pm 1.0$ )

## 4. Discussion

Behavior prediction from sensor data in order to improve welfare has been the center of previous studies. A 3D accelerometer is widely used to classify moving and non-moving behaviors such as lying and non-lying for cows [64]. Using only one sensor resulted in relatively low sensitivity and precision of collar-based systems in the studies of Martiskainen et al. [51] and Vázquez Diosdado et al. [56], but using additional sensors resolves the ambiguity between classified activities and improves prediction. Spink et al. [65] and Hanson and Mo [13] complemented accelerometer data with data from GPS sensors in order to calculate the distance travelled by cows. Based on the study from González et al. [66], GPS data can improve the accuracy of prediction; however, the frequency of data sampling plays an important role as high frequencies result in high battery consumption. In order to extract enough knowledge, in some behavior recognition systems, the magnetometer and gyroscope data are used as a complement to accelerometer data as well. Based on the related work performed by Mansbridge et al. [7] on sheep and Kamminga et al. [8] on goats where reliable prediction of animal behavior was achieved, the combination of accelerometer, magnetometer and gyroscope was chosen in our study.

In addition to the choice of sensors, defining the best sampling rate is another important step towards acquiring sensor data. High sampling rates can result in higher accuracies but reduce the battery lifespan [6]. As presented in human activity recognition studies [54,67–69], the goal is to reduce the sampling rate to save battery while ensuring a high classification accuracy. In order to explore sampling rate reduction in the process of model development, the sampling rate was set to 10 Hz according to previous studies [51,70]. As the further reduction in sampling rate resulted in a considerable drop in accuracy for random forest, we retained 10 Hz for the final model.

For data acquisition, we used the prototype of a monitoring system with provisional casing (see Figure 1). The casing was sufficiently robust for the temporal use within our study. For an extended application, the robustness needs to be improved. Weight and measurements—especially in relation to the animal—are notable factors in the development and validation of monitoring systems [71]. As cows with different body weights and heights were used in our study, varying systems relative to animal relations were included in the training and validation of our model. As weight and measurements will only marginally change with replacing the case, we expect no limitation to the applicability of our model afterwards.

For the training and the following evaluation of the model, ground truth data were needed. Reiter et al. [52] found a high correlation between visual and video observation for rumination behavior, proving that video observation is a reliable method for behavior data acquisition. In contrast to visual observation, more than one animal can be observed at the same time, resulting in a greater amount of data in relation to workload. In our study, the cameras on the pasture had to be moved around to capture the behavior of the moving cows without interruption, resulting in data acquisition being more laborious and requiring more operators than in the barn where the cameras were installed in fixed positions. Even though operators were present during the observation on pasture, disturbance was reduced to a minimum. Using high resolution cameras allowed the operators to keep sufficient distance from the animals. Data collection on pasture was limited to daytime as cameras without a night vision feature were used. In the barn, artificial lighting enabled acquisition of behavior data also at night. However, as there was no difference detected in performance of the model between day and night in the barn, it can be assumed that lying behavior presents equally in the sensor data independent from the time of day.

In order to generate behavior data, videos were labeled based on an ethogram, which was developed following previously published studies to ensure comparability of the results [37,51,72]. The process of labeling is time consuming, impeded by animals obscuring each other and impeded by the movement of the cameras on pasture. Detailed labeling of a subset of data allowed deeper assessment of the falsely classified time and provided data for the model development for other behavioral patterns. Using only one observer for video labeling eliminates deviations that occur between different observers. Observer reliability was satisfactory and comparable to the one obtained in the study of Ambriz-Vilchis et al. [46]. The chosen methods provided reliable and profound datasets for the development and evaluation of the model.

In the process of model development, a suitable segmentation strategy for the sensor data, i.e., an appropriate window size, must be chosen. Breaking the data into smaller window sizes can improve the classification accuracy but causes redundancy and waste of resources [6]. Walton et al. [69] investigated different window sizes in behavior prediction in sheep and found only a slight improvement of accuracy between a window size of 3 s compared to 5 s. In our study, there were only marginal differences in performance of the model between different window sizes. Due to that, 5 s were chosen as a trade-off between the accuracy and the prediction latency. A stride of 100% proved to be the most accurate for random forest. That is in line with the findings of Dehghani et al. [73], where a quantitative comparison between overlapping and non-overlapping windows showed that overlapping windows require more resources while hardly impacting the subject-independent cross-validation.

From the chosen windows, the features for the model were computed. As in our study the sensor orientation changed between farms, features independent from orientation proved to be suitable. Kamminga et al. [8] stated that sensors on animals are exposed to shifting in general and showed that models based on features independent from orientation provide high accuracy values in behavior recognition in animals.

As the last step of model development, the choice of classifier is one of the crucial parameters for animal behavior recognition. In our study, random forest scored the highest accuracy compared with decision tree, support vector machine and naive Bayes. Vázquez Diosdado et al. [56] showed that the accuracy of the decision tree is comparable with other classifiers (not including random forest), while the computational complexity is lower. Although a decision tree can perform accurately and fast on large datasets, it is prone to overfitting. Mansbridge et al. [7] compared random forest, support vector machine, k-nearest neighbor and adaptive boosting in classifying sheep behavior and showed that random forest has the highest overall accuracy. Other studies such as Rahman et al. [57] have also used the random forest classifier for behavior recognition in dairy cows. Our finding that random forest performs best is in line with the mentioned studies.

Since data resulting from the prediction model were noisy, a filter of 60 s was applied. All sequences of lying and non-lying behavior in the sensor data with shorter duration were disregarded and added to the behavior predicted before. According to González et al. [66], as lying and non-lying behavior occurs in bouts, the accuracy should be improved by considering the behavior classified before and after a sequence. In our study, only five lying bouts lasted  $\leq 60$  s and were thereby disregarded because of the filter. With representing only 1.7% of the total lying bouts, the amounts of lying bouts and the lying time were hardly affected, but the accuracy in predicting individual lying bouts improved substantially. Kok et al. [74] showed that applying a threshold of 33 s achieved the highest performance values for the detection of lying bouts while hardly affecting the measured lying time.

In general, our final model predicted lying behavior in dairy cows with a reasonable overall accuracy of 87.3%. The model was trained with data from pasture, where a higher accuracy was achieved compared to the barn (93.1 vs. 81.4%). The lower accuracy indoors is mainly based on a lower specificity. Standing (in the cubicle) was the behavior confused the most with lying by the model. Moreover, in the studies of Vázquez Diosdado et al. [56] and Martiskainen et al. [51], standing was the behavior most misclassified as lying and the other way around. The similar posture of the head and the lack of movement both while standing and lying resulted in a similar presentation of both behaviors in the sensor data and explained the difficulty of the model to distinguish precisely between the two behavioral patterns [51,75]. In addition to providing additional information on the dairy cow behavior in general [56], the training of a model for the prediction of standing up and lying down, i.e., the transition between standing and lying, could improve the distinction between lying and standing. The reduced performance in the barn can be explained by a higher standing time compared to pasture. This is supported by the negative correlation between standing time and specificity as well as accuracy per animal per day (for the days where labeling was performed in detail). Moreover, the differences in performance between the different days and the different animals can be explained with variation in standing time. In addition to heat or health disorders, dairy cows show an increased standing time when ambient temperatures are high [28]. The increase in standing time caused by heat load varies between animals. Another reason for the disparity of performance in the different cows could be a variation in movement patterns of the head and neck in between animals. The interpretation of performance values for different days and animals is limited by the fact that not all animals within one farm were observed on all observation days. On the one hand, performance per day is influenced by the performance of the model on the animals observed on that day. On the other hand, if animals were observed on days with more standing time in general, the overall performance on those animals is worse.

There are various monitoring systems available that predict different behavioral patterns in cows, including lying, with reasonable accuracy either in the barn or on pasture exclusively. Table 10 shows that our model performed well in predicting lying behavior compared to other models. However, when comparing the results, methodological differences have to be considered. In contrast to our study and the other papers, steers instead of dairy cows were used in the study of González et al. [66]. Only the system evaluated by Molfino et al. [76] achieved a higher specificity and precision than our model. Lying was merged with standing in this study, which was the behavioral pattern confused the most with lying by our model. By merging the two behaviors, the misclassification rate is reduced and the performance increases. Unlike our system, the sensors in other studies were located at the top of the neck where a counterweight is needed for the sensor to stay in its position. Additionally, the sensor is more exposed to external forces, e.g., by the feeding fence when mounted to the top of the cows' neck. In contrast to our model, the training and the evaluation of the systems' models were conducted on data from the same farm. Only Molfino et al. [76] evaluated a system that was developed before and thereby trained on a different farm than where the evaluation was performed. However, the training of the model is not part of the study. Evaluating the performance of a model

on data from a different farm than where the data for the development were collected on proves that, in order to apply the monitoring system on a new farm, no additional training is needed. Differences in performance between animals were assessed in the study of González et al. [66]. Variation in sensitivity was wider, but smaller variation was found in precision compared to our study. Vázquez Diosdado et al. [56] did not assess deviation in performance between animals but discovered large variations in movement patterns, i.e., in the sensor data between the animals.

In all studies presented in Table 10, the models were trained in the barn and evaluated in the barn or trained on pasture and evaluated on pasture. To our knowledge, this is the first study developing and evaluating a model for a (collar-based) monitoring system for dairy cows that predicts the behavior of dairy cows reliably on pasture as well as in the barn.

**Table 10.** Performance of the model compared to the results of other model evaluations. <sup>a</sup> Martiskainen et al. [51]. <sup>b</sup> Vázquez Diosdado et al. [56]. <sup>c</sup> Molfino et al. [76]. <sup>d</sup> González et al. [66]. <sup>e</sup> Lying behavior includes ruminating while lying, but excludes standing. <sup>f</sup> Lying behavior excludes ruminating and standing. <sup>g</sup> Lying behavior includes standing, but excludes ruminating. <sup>h</sup> Training not included in the paper (=conducted on different farm). <sup>i</sup> Variation due to different classifiers and different window sizes.

	Our Model		1 <sup>a</sup>	2 <sup>b</sup>	3 <sup>c</sup>	4 <sup>d</sup>
Husbandry system	Pasture	Barn	Barn	Barn	Pasture	Pasture
Definition lying behavior	1 <sup>e</sup>	2 <sup>f</sup>	2 <sup>f</sup>	1 <sup>e</sup>	3 <sup>g</sup>	3 <sup>g</sup>
Sensor(s)	Accelerometer + Magnetometer + Gyroscope		Accelerometer	Accelerometer	Accelerometer	Accelerometer + GPS
Sensor position	Lower neck		Top of the neck	Top of the neck	Top of the neck	Top of the neck
Training data	One farm		One farm	One farm	- <sup>h</sup>	One farm
Evaluation data	Same farm + two others		Same farm	Same farm	One farm	Same farm
Sensitivity	95.6%	80%	80%	55.4–92.9% <sup>i</sup>	77%	86.3%
Specificity	80.1%	-	-	-	99%	94.8%
Precision	80.5%	83%	83%	85.4–96.6% <sup>i</sup>	93%	-
Accuracy	93.1%	81.4%	84%	-	-	92.5%

Ambriz-Vilchis et al. [46] evaluated the performance of a rumination collar on cows kept in a freestall barn as well as on cows kept on pasture. Rumination times predicted by the system agreed with rumination time measured by visual and video observation on cows kept indoors. However, major differences in rumination time were found for pasture. The results are confirmed by Elischer et al. [47], who assessed the performance of a neck collar predicting feeding behavior as well as rumination behavior on cows on pasture with access to a barn. In this study, the performance was tested on the same animals inside as well as outdoors. Only moderate correlations were observed between the collar output and visual observation.

A reasonable amount of lying bouts (95.12%) was detected correctly by our model. In the study of Kok et al. [74], 99.2% of the lying bouts were detected correctly, i.e., by both the pedometers attached to one cow. In contrast to our study, lying bouts in ground truth data with a duration of less than 33 s were discarded. In the study of Ledgerwood et al. [77] a pedometer detected 99.3% of the lying bouts that were observed in ground truth without applying any filter and by using a window size of 6 s. In the presented study, a few lying bouts were not identified correctly by the model, but as the median duration of those bouts was short (3.02 min), the effect on total lying time is small. To our knowledge, there were no studies conducted on the performance of a model in detecting the beginnings and endings of individual lying bouts.

Lying time on pasture (farm 1: 12.3 h) was significantly lower than in the barn (farm 3: 15.6 h). This finding is in line with the results from Black and Krawczel [78] and Legrand et al. [79], who observed higher lying times in the barn than on pasture as well. Lower lying times on pasture are likely based on the prolonged duration of feed intake (=grazing) on pasture com-

pared to the barn. While in the barn, dairy cows spend 3.9 to 4.2 h feeding [80,81], and grazing time occupies 10.6 to 11.1 h a day [82]. Although higher inaccuracy of our model in the barn resulted, the use of lying time predicted over 24 h in the barn has to be treated with caution. Only numerical differences were detected between lying time during the day and during the night, which is in contrast to the findings of Herbut and Angrecka [83] who observed longer lying times during the night on pasture compared to daytime. Their finding is supported by Winckler et al. [84], who had the same conclusion for lying time distribution in the barn.

## 5. Conclusions and Future Work

In conclusion, we could show that by using machine learning methods on sensor data from a motion unit, it is possible to predict lying behavior with reasonable accuracy compared to other available models and monitoring systems, especially regarding the fact that the model was applied both on data from pasture and the barn.

The models that have been trained and compared for this study were produced by state-of-the-art machine learning algorithms. The choice of these algorithms was based on related research from literature on activity recognition. We then compared the models produced by the best-performing algorithm and came to similar results that random forest models achieve the best accuracy for the given use case.

Prediction must be enhanced, particularly in the barn, in order to enable the identification of behavioral changes caused, e.g., by heat, health disorders or extreme weather conditions. To improve the performance of the model in predicting lying behavior, standing up and lying down events could be studied. By adding models for the prediction of other behavioral patterns, especially standing, the prediction of lying behavior could be improved by reducing the falsely classified data points. Additionally, more information is generated in order to relate the behavioral changes to different health challenges or estrous. The collected data can be used for the development of further models. In addition to data from the accelerometer, magnetometer and gyroscope, data from other sensors could be used. Partial GPS data have been collected from dairy cows on farm 1 where the GPS sensor functioned as the timer for the sensor data.

### Future Work

In the future, context-aware location data and GPS data could be used to improve the accuracy of our model.

The data that needs to be managed in an IoT ecosystem steadily grew in all of its three big data dimensions: volume, velocity and variety. The volume increases due to the elevating amount of data generating devices [85,86] and velocity by advances in communication technologies such as 5G [87]. Kaur et al. [88] even calls it the Internet-of-Big-data.

The processing of this huge amount of data utilizes many resources. Current IoT platforms are mainly centralized and lack the feature of resource-aware processing in the sense of edge and fog processing [89]. Centralized processing is generally suboptimal since it uses the Wide Area Network (WAN) bandwidth highly inefficiently due to sending all data to the cloud in order to process it there. Furthermore, cloud computing induces high latency, high energy consumption and privacy concerns arise. Properly positioning the processing along the process from the data sources to the sinks is the intended strategy. Enabling edge and fog processing is crucial for being resource efficient and for real-time low latency applications. Data processing in IoT is geographically distributed by the nature of the ecosystem [90,91].

**Author Contributions:** Conceptualization, D.N., S.T. and E.R.; data Curation, L.S. and M.S.; formal analysis, L.S. and A.K.; funding acquisition, D.N. and S.T.; investigation, L.S.; methodology, S.T., D.N., E.R., L.S., A.K. and P.T.H.; project administration, D.N. and S.T.; resources, D.N. and S.T.; software, A.K. and P.T.H.; supervision, G.E., M.S., D.N., S.T. and E.R.; validation, L.S. and A.K.; visualization, L.S.; writing—original draft, L.S., A.K., G.E. and P.T.H.; writing—review and editing, D.N., S.T. and E.R. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research was funded by the Bavarian Research Foundation (grant number 1301-17).

**Institutional Review Board Statement:** All procedures performed followed the EU directive 2010/63 /EU and the German Animal Welfare Act.

**Informed Consent Statement:** Not applicable.

**Data Availability Statement:** Data is contained within the article.

**Acknowledgments:** We would like to thank the farmers and their families for allowing us to conduct the observations on their farms and for their effort in helping us with the animal-related aspects of our experiments. Furthermore, we are grateful for the help of Alexander Süsse from Blaupunkt Telematics GmbH who provided us with the prototypes of the system and for the help of Anna Hofbauer who supported us with the data evaluation.

**Conflicts of Interest:** The authors declare no conflict of interest.

### Abbreviations

The following abbreviations are used in this manuscript:

PLF	Precision Livestock Farming;
IoT	Internet of Things;
DIM	Days in milk;
BCS	Body condition score;
3D	three-dimensional;
GPS	General Positioning System;
RTC	Real-time clock;
TP	True positive;
TN	True negative;
FP	False positive;
FN	False negative.

### References

- Lara, O.D.; Labrador, M.A. A Survey on Human Activity Recognition using Wearable Sensors. *IEEE Commun. Surv. Tutor.* **2013**, *15*, 1192–1209, doi:10.1109/SURV.2012.110112.00192.
- Guo, H.; Chen, L.; Peng, L.; Chen, G. Wearable sensor based multimodal human activity recognition exploiting the diversity of classifier ensemble. In Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing, Heidelberg, Germany, 12–16 September 2016; pp. 1112–1123, doi:10.1145/2971648.2971708.
- Jordao, A.; Nazare, A.C., Jr.; Sena, J.; Schwartz, W.R. Human Activity Recognition Based on Wearable Sensor Data: A Standardization of the State-of-the-Art. *arXiv* **2019**, arXiv:1806.05226.
- Arcidiacono, C.; Porto, S.M.C.; Mancino, M.; Cascone, G. Development of a threshold-based classifier for real-time recognition of cow feeding and standing behavioural activities from accelerometer data. *Comput. Electron. Agric.* **2017**, *134*, 124–134, doi:10.1016/j.compag.2017.01.021.
- Jukan, A.; Masip-Bruin, X.; Amla, N. Smart Computing and Sensing Technologies for Animal Welfare: A Systematic Review. *ACM Comput. Surv.* **2017**, *50*, 10:1–10:27, doi:10.1145/3041960.
- Khan, A.; Hammerla, N.; Mellor, S.; Plötz, T. Optimising sampling rates for accelerometer-based human activity recognition. *Pattern Recognit. Lett.* **2016**, *73*, 33–40, doi:10.1016/j.patrec.2016.01.001.
- Mansbridge, N.; Mitsch, J.; Bollard, N.; Ellis, K.; Miguel-Pacheco, G.G.; Dottorini, T.; Kaler, J. Feature Selection and Comparison of Machine Learning Algorithms in Classification of Grazing and Ruminant Behaviour in Sheep. *Sensors* **2018**, *18*, 3532, doi:10.3390/s18103532.
- Kammaing, J.W.; Le, D.V.; Meijers, J.P.; Bisby, H.; Meratnia, N.; Havinga, P.J. Robust Sensor-Oriented-Independent Feature Selection for Animal Activity Recognition on Collar Tags. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.* **2018**, *2*, 15:1–15:27, doi:10.1145/3191747.
- Krause, A.; Ihmig, M.; Rankin, E.; Leong, D.; Smriti Gupta.; Siewiorek, D.; Smailagic, A.; Deisher, M.; Sengupta, U. Trading off prediction accuracy and power consumption for context-aware wearable computing. In Proceedings of the Ninth IEEE International Symposium on Wearable Computers, Osaka, Japan, 18–21 October 2005; pp. 20–26, doi:10.1109/ISWC.2005.52.
- von Keyserlingk, M.A.G.; Rushen, J.; de Passillé, A.M.; Weary, D.M. Invited review: The welfare of dairy cattle—Key concepts and the role of science. *J. Dairy Sci.* **2009**, *92*, 4101–4111, doi:10.3168/jds.2009-2326.
- Berckmans, D. Precision livestock farming technologies for welfare management in intensive livestock systems. *Rev. Sci. Tech. Int. Off. Epizoot.* **2014**, *33*, 189–196, doi:10.20506/rst.33.1.2273.
- Jago, J.; Eastwood, C.; Kerrisk, K.; Yule, I. Precision dairy farming in Australasia: Adoption, risks and opportunities. *Anim. Prod. Sci.* **2013**, *53*, 907–916, doi:10.1071/AN12330.

13. Hanson, D.; Mo, C. Monitoring Cattle Motion using 3-axis Acceleration and GPS Data. *J. Res. Agric. Anim. Sci.* **2014**, *2*, 8.
14. Hostiou, N.; Fagon, J.; Chauvat, S.; Turlot, A.; Kling-Eveillard, F.; Boivin, X.; Allain, C. Impact of precision livestock farming on work and human-animal interactions on dairy farms. A review. *Biotechnol. Agron. Soc. Environ.* **2017**, *21*, 268–275, doi:10.25518/1780-4507.13706.
15. Gáspárdy, A.; Efrat, G.; Bajcsy, A.C.; Fekete, S.G. Electronic monitoring of rumination activity as an indicator of health status and production traits in high-yielding dairy cows. *Acta Vet. Hung.* **2014**, *62*, 452–462, doi:10.1556/AVet.2014.026.
16. King, M.T.M.; Dancy, K.M.; LeBlanc, S.J.; Pajor, E.A.; DeVries, T.J. Deviations in behavior and productivity data before diagnosis of health disorders in cows milked with an automated system. *J. Dairy Sci.* **2017**, *100*, 8358–8371, doi:10.3168/jds.2017-12723.
17. King, M.T.M.; DeVries, T.J. Graduate Student Literature Review: Detecting health disorders using data from automatic milking systems and associated technologies. *J. Dairy Sci.* **2018**, *101*, 8605–8614, doi:10.3168/jds.2018-14521.
18. Kaneene, J.B.; Scott Hurd, H. The national animal health monitoring system in Michigan. III. Cost estimates of selected dairy cattle diseases. *Prev. Vet. Med.* **1990**, *8*, 127–140, doi:10.1016/0167-5877(90)90006-4.
19. Milner, P.; Page, K.L.; Hillerton, J.E. The Effects of Early Antibiotic Treatment Following Diagnosis of Mastitis Detected by a Change in the Electrical Conductivity of Milk. *J. Dairy Sci.* **1997**, *80*, 859–863, doi:10.3168/jds.S0022-0302(97)76008-9.
20. Trevisi, E.; Zecconi, A.; Cogrossi, S.; Razzuoli, E.; Grossi, P.; Amadori, M. Strategies for reduced antibiotic usage in dairy cattle farms. *Res. Vet. Sci.* **2014**, *96*, 229–233, doi:10.1016/j.rvsc.2014.01.001.
21. Stangaferro, M.L.; Wijma, R.; Caixeta, L.S.; Al-Abri, M.A.; Giordano, J.O. Use of rumination and activity monitoring for the identification of dairy cows with health disorders: Part I. Metabolic and digestive disorders. *J. Dairy Sci.* **2016**, *99*, 7395–7410, doi:10.3168/jds.2016-10907.
22. Stangaferro, M.L.; Wijma, R.; Caixeta, L.S.; Al-Abri, M.A.; Giordano, J.O. Use of rumination and activity monitoring for the identification of dairy cows with health disorders: Part II. Mastitis. *J. Dairy Sci.* **2016**, *99*, 7411–7421, doi:10.3168/jds.2016-10908.
23. Stangaferro, M.L.; Wijma, R.; Caixeta, L.S.; Al-Abri, M.A.; Giordano, J.O. Use of rumination and activity monitoring for the identification of dairy cows with health disorders: Part III. Metritis. *J. Dairy Sci.* **2016**, *99*, 7422–7433, doi:10.3168/jds.2016-11352.
24. Shalloo, L.; Cromie, A.; McHugh, N. Effect of fertility on the economics of pasture-based dairy systems. *Animal* **2014**, *8*, 222–231, doi:10.1017/S1751731114000615.
25. Dolecheck, K.A.; Heersche, G.; Bewley, J.M. Retention payoff-based cost per day open regression equations: Application in a user-friendly decision support tool for investment analysis of automated estrus detection technologies. *J. Dairy Sci.* **2016**, *99*, 10182–10193, doi:10.3168/jds.2015-10364.
26. Kerbrat, S.; Disenhaus, C. A proposition for an updated behavioural characterisation of the oestrus period in dairy cows. *Appl. Anim. Behav. Sci.* **2004**, *87*, 223–238, doi:10.1016/j.applanim.2003.12.001.
27. Mayo, L.M.; Silvia, W.J.; Ray, D.L.; Jones, B.W.; Stone, A.E.; Tsai, I.C.; Clark, J.D.; Bewley, J.M.; Heersche, G. Automated estrous detection using multiple commercial precision dairy monitoring technologies in synchronized dairy cows. *J. Dairy Sci.* **2019**, *102*, 2645–2656, doi:10.3168/jds.2018-14738.
28. Allen, J.D.; Hall, L.W.; Collier, R.J.; Smith, J.F. Effect of core body temperature, time of day, and climate conditions on behavioral patterns of lactating dairy cows experiencing mild to moderate heat stress. *J. Dairy Sci.* **2015**, *98*, 118–127, doi:10.3168/jds.2013-7704.
29. Herbut, P.; Angrecka, S. The effect of heat stress on time spent lying by cows in a housing system. *Ann. Anim. Sci.* **2018**, *18*, 825–833, doi:10.2478/aoas-2018-0018.
30. Webster, J.R.; Stewart, M.; Rogers, A.R.; Verkerk, G.A. Assessment of welfare from physiological and behavioural responses of New Zealand dairy cows exposed to cold and wet conditions. *Anim. Welf.* **2008**, *17*, 19–26.
31. Fogsgaard, K.K.; Bennedsgaard, T.W.; Herskin, M.S. Behavioral changes in freestall-housed dairy cows with naturally occurring clinical mastitis. *J. Dairy Sci.* **2015**, *98*, 1730–1738, doi:10.3168/jds.2014-8347.
32. Beer, G.; Alsaad, M.; Starke, A.; Schuepbach-Regula, G.; Müller, H.; Kohler, P.; Steiner, A. Use of Extended Characteristics of Locomotion and Feeding Behavior for Automated Identification of Lamé Dairy Cows. *PLoS ONE* **2016**, *11*, e0155796, doi:10.1371/journal.pone.0155796.
33. Weiglele, H.C.; Gygax, L.; Steiner, A.; Wechsler, B.; Burla, J.B. Moderate lameness leads to marked behavioral changes in dairy cows. *J. Dairy Sci.* **2018**, *101*, 2370–2382, doi:10.3168/jds.2017-13120.
34. Reith, S.; Hoy, S. Relationship between daily rumination time and estrus of dairy cows. *J. Dairy Sci.* **2012**, *95*, 6416–6420, doi:10.3168/jds.2012-5316.
35. Soriani, N.; Panella, G.; Calamari, L. Rumination time during the summer season and its relationships with metabolic conditions and milk production. *J. Dairy Sci.* **2013**, *96*, 5082–5094, doi:10.3168/jds.2013-6620.
36. Barker, Z.E.; Vázquez Diosdado, J.A.; Codling, E.A.; Bell, N.J.; Hodges, H.R.; Croft, D.P.; Amory, J.R. Use of novel sensors combining local positioning and acceleration to measure feeding behavior differences associated with lameness in dairy cattle. *J. Dairy Sci.* **2018**, *101*, 6310–6321, doi:10.3168/jds.2016-12172.
37. Borchers, M.R.; Chang, Y.M.; Tsai, I.C.; Wadsworth, B.A.; Bewley, J.M. A validation of technologies monitoring dairy cow feeding, ruminating, and lying behaviors. *J. Dairy Sci.* **2016**, *99*, 7458–7466, doi:10.3168/jds.2015-10843.
38. Bikker, J.P.; van Laar, H.; Rump, P.; Doorenbos, J.; van Meurs, K.; Griffioen, G.M.; Dijkstra, J. Technical note: Evaluation of an ear-attached movement sensor to record cow feeding behavior and activity. *J. Dairy Sci.* **2014**, *97*, 2974–2979, doi:10.3168/jds.2013-7560.

39. Benaissa, S.; Tuytens, F.A.M.; Plets, D.; de Pessemer, T.; Trogh, J.; Tanghe, E.; Martens, L.; Vandaele, L.; Van Nuffel, A.; Joseph, W.; et al. On the use of on-cow accelerometers for the classification of behaviours in dairy barns. *Res. Vet. Sci.* **2019**, *125*, 425–433. doi:10.1016/j.rvsc.2017.10.005.
40. Hernandez-Mendo, O.; von Keyserlingk, M.A.G.; Veira, D.M.; Weary, D.M. Effects of Pasture on Lameness in Dairy Cows. *J. Dairy Sci.* **2007**, *90*, 1209–1214. doi:10.3168/jds.S0022-0302(07)71608-9.
41. Flury, R.; Gygax, L. Daily patterns of synchrony in lying and feeding of cows: Quasi-natural state and (anti-) synchrony factors. *Behav. Process.* **2016**, *133*, 56–61. doi:10.1016/j.beproc.2016.11.004.
42. Cardoso, C.S.; Hötzel, M.J.; Weary, D.M.; Robbins, J.A.; von Keyserlingk, M.A.G. Imagining the ideal dairy farm. *J. Dairy Sci.* **2016**, *99*, 1663–1671. doi:10.3168/jds.2015-9925.
43. Smid, A.M.C.; Weary, D.M.; von Keyserlingk, M.A.G. The Influence of Different Types of Outdoor Access on Dairy Cattle Behavior. *Front. Vet. Sci.* **2020**, *7*, 257. doi:10.3389/fvets.2020.00257.
44. van den Pol-van Dasselaar, A.; Hennessy, D.; Isselstein, J. Grazing of Dairy Cows in Europe—An In-Depth Analysis Based on the Perception of Grassland Experts. *Sustainability* **2020**, *12*, 1098. doi:10.3390/su12031098.
45. Stygar, A.H.; Gómez, Y.; Berteselli, G.V.; Dalla Costa, E.; Canali, E.; Niemi, J.K.; Llonch, P.; Pastell, M. A Systematic Review on Commercially Available and Validated Sensor Technologies for Welfare Assessment of Dairy Cattle. *Front. Vet. Sci.* **2021**, *8*, 177. doi:10.3389/fvets.2021.634338.
46. Ambríz-Vilchis, V.; Jessop, N.S.; Fawcett, R.H.; Shaw, D.J.; Macrae, A.I. Comparison of rumination activity measured using rumination collars against direct visual observations and analysis of video recordings of dairy cows in commercial farm environments. *J. Dairy Sci.* **2015**, *98*, 1750–1758. doi:10.3168/jds.2014-8565.
47. Elischer, M.F.; Arceo, M.E.; Karcher, E.L.; Siegford, J.M. Validating the accuracy of activity and rumination monitor data from dairy cows housed in a pasture-based automatic milking system. *J. Dairy Sci.* **2013**, *96*, 6412–6422. doi:10.3168/jds.2013-6790.
48. French, P.; O'Brien, B.; Shalloo, L. Development and adoption of new technologies to increase the efficiency and sustainability of pasture-based systems. *Anim. Prod. Sci.* **2015**, *55*, 931–935. doi:10.1071/AN14896.
49. Edmonson, A.J.; Lean, I.J.; Weaver, L.D.; Farver, T.; Webster, G. A Body Condition Scoring Chart for Holstein Dairy Cows. *J. Dairy Sci.* **1989**, *72*, 68–78. doi:10.3168/jds.S0022-0302(89)79081-0.
50. Metzner, M.; Heuwieser, W.; Klee, W. Die Beurteilung der Körperkondition (Body condition scoring) im Herdenmanagement. *Prakt. Tierarzt* **1993**, *74*, 991–998.
51. Martiskainen, P.; Järvinen, M.; Skön, J.P.; Tiirikainen, J.; Kolehmainen, M.; Mononen, J. Cow behaviour pattern recognition using a three-dimensional accelerometer and support vector machines. *Appl. Anim. Behav. Sci.* **2009**, *119*, 32–38. doi:10.1016/j.applanim.2009.03.005.
52. Reiter, S.; Sattlecker, G.; Lidauer, L.; Kickingler, F.; Öhlschuster, M.; Auer, W.; Schweinzer, V.; Klein-Jöbstl, D.; Drillich, M.; Iwersen, M. Evaluation of an ear-tag-based accelerometer for monitoring rumination in dairy cows. *J. Dairy Sci.* **2018**, *101*, 3398–3411. doi:10.3168/jds.2017-12686.
53. Werner, J.; Leso, L.; Umstätter, C.; Niederhauser, J.; Kennedy, E.; Geoghegan, A.; Shalloo, L.; Schick, M.; O'Brien, B. Evaluation of the RumiWatchSystem for measuring grazing behaviour of cows-ScienceDirect. *J. Neurosci. Methods* **2018**, *300*, 138–146. doi:10.1016/j.jneumeth.2017.08.022.
54. Bersch, S.D.; Azzi, D.; Khusainov, R.; Achumba, I.E.; Ries, J. Sensor Data Acquisition and Processing Parameters for Human Activity Classification. *Sensors* **2014**, *14*, 4239–4270. doi:10.3390/s140304239.
55. Figo, D.; Diniz, P.C.; Ferreira, D.R.; Cardoso, J.M.P. Preprocessing techniques for context recognition from accelerometer data. *Pers. Ubiquitous Comput.* **2010**, *14*, 645–662. doi:10.1007/s00779-010-0293-9.
56. Vázquez Diosdado, J.A.; Barker, Z.E.; Hodges, H.R.; Amory, J.R.; Croft, D.P.; Bell, N.J.; Codling, E.A. Classification of behaviour in housed dairy cows using an accelerometer-based activity monitoring system. *Anim. Biotelem.* **2015**, *3*, 15. doi:10.1186/s40317-015-0045-8.
57. Rahman, A.; Smith, D.V.; Little, B.; Ingham, A.B.; Greenwood, P.L.; Bishop-Hurley, G.J. Cattle behaviour classification from collar, halter, and ear tag sensors. *Inf. Process. Agric.* **2018**, *5*, 124–133. doi:10.1016/j.inpa.2017.10.001.
58. Tolkamp, B.J.; Kyriazakis, I. To split behaviour into bouts, log-transform the intervals. *Anim. Behav.* **1999**, *57*, 807–817. doi:10.1006/anbe.1998.1022.
59. Wood, S.N. Fast stable restricted maximum likelihood and marginal likelihood estimation of semiparametric generalized linear models. *J. R. Stat. Soc. Ser. B Stat. Methodol.* **2011**, *73*, 3–36. doi:10.1111/j.1467-9868.2010.00749.x.
60. Chambers, J.M.; Hastie, T., Eds. *Statistical Models in S*; Wadsworth & Brooks/Cole Computer Science Series; Wadsworth & Brooks/Cole Advanced Books & Software: Pacific Grove, CA, USA, 1992.
61. Benjamini, Y.; Yekutieli, D. The control of the false discovery rate in multiple testing under dependency. *Ann. Stat.* **2001**, *29*, 1165–1188. doi:10.1214/aos/1013699998.
62. Fox, J.; Weisberg, S. *An R Companion to Applied Regression*; SAGE Publications: New York, NY, USA, 2018.
63. Royston, P. Remark AS R94: A Remark on Algorithm AS 181: The W-test for Normality. *J. R. Stat. Soc. Ser. C Appl. Stat.* **1995**, *44*, 547–551. doi:10.2307/2986146.
64. Haladjian, J.; Haug, J.; Nüske, S.; Bruegge, B. A Wearable Sensor System for Lameness Detection in Dairy Cattle. *Multimodal Technol. Interact.* **2018**, *2*, 27. doi:10.3390/mti2020027.

65. Spink, A.; Cresswell, B.; Kölzsch, A.; Langevelde, F.V.; Neeffes, M.; Noldus, L.P.J.J.; Oeveren, H.V.; Prins, H.H.T.; Wal, T.V.D.; Weerd, N.D.; et al. Animal behaviour analysis with GPS and 3D accelerometers. In Proceedings of the 6th European Conference on Precision Livestock Farming, Leuven, Belgium, 10–12 September 2013; pp. 229–239.
66. González, L.A.; Bishop-Hurley, G.J.; Handcock, R.N.; Crossman, C. Behavioral classification of data from collars containing motion sensors in grazing cattle. *Comput. Electron. Agric.* **2015**, *110*, 91–102, doi:10.1016/j.compag.2014.10.018.
67. Niazi, A.H.; Yazdanehpas, D.; Gay, J.L.; Maier, F.W.; Ramaswamy, L.; Rasheed, K.; Buman, M. Statistical analysis of window sizes and sampling rates in human activity recognition. In Proceedings of the 10th International Conference on Health Informatics, Proceedings, Lisbon, Portugal, 17–18 July 2017; pp. 319–325, doi:10.5220/0006148503190325.
68. Twomey, N.; Diethel, T.; Fafoutis, X.; Elsts, A.; McConville, R.; Flach, P.; Craddock, I. A Comprehensive Study of Activity Recognition Using Accelerometers. *Informatics* **2018**, *5*, 27, doi:10.3390/informatics5020027.
69. Walton, E.; Casey, C.; Mitsch, J.; Vázquez-Diosdado, J.A.; Yan, J.; Dottorini, T.; Ellis, K.A.; Winterlich, A.; Kaler, J. Evaluation of sampling frequency, window size and sensor position for classification of sheep behaviour. *R. Soc. Open Sci.* **2018**, *5*, 171442, doi:10.1098/rsos.171442.
70. Alsaad, M.; Niederhauser, J.J.; Beer, G.; Zehner, N.; Schuepbach-Regula, G.; Steiner, A. Development and validation of a novel pedometer algorithm to quantify extended characteristics of the locomotor behavior of dairy cows. *J. Dairy Sci.* **2015**, *98*, 6236–6242, doi:10.3168/jds.2015-9657.
71. Bouchon, M.; Bach, A.; Meunier, B.; Ternman, E.; Van Reenen, K.; Veissier, I.; Munksgaard, L. In *A Checklist to Validate Sensor Output for the Recording of Cattle Behaviour*; PUBLISSO: Cologne, Germany, 2021; doi:10.5680/mcpb014.
72. Nielsen, P.P. Automatic registration of grazing behaviour in dairy cows using 3D activity loggers. *Appl. Anim. Behav. Sci.* **2013**, *148*, 179–184, doi:10.1016/j.applanim.2013.09.001.
73. Dehghani, A.; Glatard, T.; Shihab, E. Subject Cross Validation in Human Activity Recognition. *arXiv* **2019**, arXiv:1904.02666.
74. Kok, A.; van Kneegsel, A.T.M.; van Middelaar, C.E.; Hogeveen, H.; Kemp, B.; de Boer, I.J.M. Technical note: Validation of sensor-recorded lying bouts in lactating dairy cows using a 2-sensor approach. *J. Dairy Sci.* **2015**, *98*, 7911–7916, doi:10.3168/jds.2015-9554.
75. Krohn, C.C.; Munksgaard, L. Behaviour of dairy cows kept in extensive (loose housing/pasture) or intensive (tie stall) environments II. Lying and lying-down behaviour. *Appl. Anim. Behav. Sci.* **1993**, *37*, 1–16, doi:10.1016/0168-1591(93)90066-X.
76. Molino, J.; Clark, C.E.F.; Kerrisk, K.L.; García, S.C. Evaluation of an activity and rumination monitor in dairy cattle grazing two types of forages. *Anim. Prod. Sci.* **2017**, *57*, 1557–1562, doi:10.1071/AN16514.
77. Ledgerwood, D.N.; Winckler, C.; Tucker, C.B. Evaluation of data loggers, sampling intervals, and editing techniques for measuring the lying behavior of dairy cattle. *J. Dairy Sci.* **2010**, *93*, 5129–5139, doi:10.3168/jds.2009-2945.
78. Black, R.A.; Krawczel, P.D. A Case Study of Behaviour and Performance of Confined or Pastured Cows during the Dry Period. *Anim. Open Access J.* **2016**, *6*, 41, doi:10.3390/ani6070041.
79. Legrand, A.L.; von Keyserlingk, M.A.G.; Weary, D.M. Preference and usage of pasture versus free-stall housing by lactating dairy cattle. *J. Dairy Sci.* **2009**, *92*, 3651–3658, doi:10.3168/jds.2008-1733.
80. Schirmann, K.; Chapinal, N.; Weary, D.M.; Heuwieser, W.; von Keyserlingk, M.A.G. Short-term effects of regrouping on behavior of prepartum dairy cows. *J. Dairy Sci.* **2011**, *94*, 2312–2319, doi:10.3168/jds.2010-3639.
81. Miguel-Pacheco, G.G.; Kaler, J.; Remnant, J.; Cheyne, L.; Abbott, C.; French, A.P.; Pridmore, T.P.; Huxley, J.N. Behavioural changes in dairy cows with lameness in an automatic milking system. *Appl. Anim. Behav. Sci.* **2014**, *150*, 1–8, doi:10.1016/j.applanim.2013.11.003.
82. Prendiville, R.; Lewis, E.; Pierce, K.M.; Buckley, F. Comparative grazing behavior of lactating Holstein-Friesian, Jersey, and Jersey × Holstein-Friesian dairy cows and its association with intake capacity and production efficiency. *J. Dairy Sci.* **2010**, *93*, 764–774, doi:10.3168/jds.2009-2659.
83. Herbut, P.; Angrecka, S. Relationship between THI level and dairy cows' behaviour during summer period. *Ital. J. Anim. Sci.* **2018**, *17*, 226–233, doi:10.1080/1828051X.2017.1333892.
84. Winckler, C.; Tucker, C.B.; Weary, D.M. Effects of under- and overstocking freestalls on dairy cattle behaviour. *Appl. Anim. Behav. Sci.* **2015**, *170*, 14–19, doi:10.1016/j.applanim.2015.06.003.
85. Atzori, L.; Iera, A.; Morabito, G. The Internet of Things: A survey. *Comput. Netw.* **2010**, *54*, 2787–2805, doi:10.1016/j.comnet.2010.05.010.
86. Gubbi, J.; Buyya, R.; Marusic, S.; Palaniswami, M. Internet of Things (IoT): A vision, architectural elements, and future directions. *Future Gener. Comput. Syst.* **2013**, *29*, 1645–1660, doi:10.1016/j.future.2013.01.010.
87. Rath, D.K.; Kumar, A. A Primer on Internet of Things Ecosystem and 5G Networks. In Proceedings of the 2018 International Conference on Information Technology, Hong Kong, China, 29–31 December 2018; pp. 233–238, doi:10.1109/ICIT.2018.00055.
88. Kaur, N.; Sood, S.K.; Verma, P. Cloud resource management using 3Vs of Internet of Big data streams. *Computing* **2020**, *102*, 1463–1485, doi:10.1007/s00607-019-00732-5.
89. Mineraud, J.; Mazhelis, O.; Su, X.; Tarkoma, S. A gap analysis of Internet-of-Things platforms. *Comput. Commun.* **2016**, *89–90*, 5–16, doi:10.1016/j.comcom.2016.03.015.
90. Heintz, B.; Chandra, A.; Sitaraman, R.K. Optimizing Grouped Aggregation in Geo-Distributed Streaming Analytics. In Proceedings of the 24th International Symposium on High-Performance Parallel and Distributed Computing, Portland, OR, USA, 15–19 June 2015; pp. 133–144, doi:10.1145/2749246.2749276.
91. Chandra, A.; Heintz, B.; Sitaraman, R. Optimizing Geo-Distributed Streaming Analytics. In *Encyclopedia of Big Data Technologies*; Sakr, S., Zomaya, A., Eds.; Springer International Publishing: Cham, Switzerland, 2018; pp. 1–5.

## VI. ZWEITE PUBLIKATION

Lara Schmeling<sup>1,2</sup>, Stefan Thurner<sup>1</sup>, Michael Erhard<sup>2</sup> and Elke Rauch<sup>2</sup>

<sup>1</sup>Institute for Agricultural Engineering and Animal Husbandry, Bavarian State Research Center, Vöttingerstr. 38, 85354 Freising, Germany

<sup>2</sup>Chair of Animal Welfare, Ethology, Animal Hygiene and Animal Husbandry, Department of Veterinary Sciences, Faculty of Veterinary Medicine, Ludwig-Maximilians-University Munich, Veterinärstr. 13/R, 80539 Munich, Germany

### **Physiological and behavioral reactions of Simmental dairy cows to increasing heat load on pasture**

Ruminants 2022, 2 (2), 157-172; DOI: <https://doi.org/10.3390/ruminants2020010>

Angenommen am 28. März 2022

Publiziert am 31. März 2022



Article

# Physiological and Behavioral Reactions of Simmental Dairy Cows to Increasing Heat Load on Pasture

Lara Schmeling <sup>1,2,\*</sup> , Stefan Thurner <sup>1</sup> , Michael Erhard <sup>2</sup> and Elke Rauch <sup>2</sup> 

<sup>1</sup> Institute for Agricultural Engineering and Animal Husbandry, Bavarian State Research Center, Vöttingerstr. 36, 85354 Freising, Germany; stefan.thurner@fl.bayern.de

<sup>2</sup> Chair of Animal Welfare, Ethology, Animal Hygiene and Animal Husbandry, Department of Veterinary Sciences, Faculty of Veterinary Medicine, Ludwig-Maximilians-University Munich, Veterinärstr. 13/R, 80539 Munich, Germany; m.erhard@tierhyg.vetmed.uni-muenchen.de (M.E.); rauch@lmu.de (E.R.)

\* Correspondence: laraschmeling@hotmail.de

**Abstract:** Climate change is accompanied by temperatures exceeding the thermal comfort zone of dairy cows, resulting in numerous consequences for production and welfare. Early detection of heat load enables taking countermeasures and can be realized using monitoring systems. We aimed at investigating heat load-induced changes in the behavior and physiology of grazing Simmental cows. Data were collected on five (round 1; r1) and eight (round 2; r2) consecutive days on a dairy farm combining a freestall barn with permanent access to pasture. Weather data, respiration rate, milk yield, milk composition, and fecal cortisol of eleven (r1) and thirteen (r2) cows were collected. The behavior of five animals was recorded with collar-based monitoring systems. Previously reported thresholds of different weather indices were exceeded on two days in r1 and on four days in r2. Under heat load, respiration rate and somatic cell count increased. Fecal cortisol did not change in r1 but increased steadily in r2. Grazing time decreased in r1. Rumination mainly occurred at night in both rounds, and its synchrony decreased in r2. Although limited by sample size, our results give a first impression on heat load induced physiological and behavioral reactions of Simmental dairy cows on pasture.

**Keywords:** dairy cows; heat load; monitoring system; animal welfare; pasture; precision livestock farming (PLF)



**Citation:** Schmeling, L.; Thurner, S.; Erhard, M.; Rauch, E. Physiological and Behavioral Reactions of Simmental Dairy Cows to Increasing Heat Load on Pasture. *Ruminants* **2022**, *2*, 157–172. <https://doi.org/10.3390/ruminants2020010>

Academic Editor: Brian J. Leury

Received: 16 December 2021

Accepted: 28 March 2022

Published: 31 March 2022

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



**Copyright:** © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

## 1. Introduction

The upper critical value of the thermal comfort zone of dairy cows is defined at 16 to 18 °C [1,2]. With global warming, the number of days with temperatures above these thresholds increases [3]. Therefore, heat load is highly relevant for dairy industry regarding economic losses [4] and animal welfare [5]. Heat load has numerous consequences, including a reduction in milk yield [6] and conception rate [7], as well as an increased risk for diseases, such as ruminal acidosis [8], mastitis [9], and hoof disorders [10].

Various heat load indices, based on the Temperature Humidity Index (THI) developed by Thom [11] for humans, were established in order to define heat load in dairy cows. In contrast to the THI, which only includes the influence of dry-bulb temperature (DBT) and relative humidity (RH), the Black Globe Humidity Index (BGHI) also considers wind speed (WS) and solar radiation (RAD) by including the black globe temperature (BGT). Compared to THI, the BGHI better reflects the effects of heat load on grazing dairy cattle [12]. Various thresholds were defined for the indices based on different physiological parameters in order to classify heat load in dairy cows [1,2].

Heat load prediction based on environmental factors is limited, as the beginning of burdening weather conditions highly depends on various animal-related factors, including breed [6], coat color [13], coat thickness [14], body weight [15], parity [16], lactation stage [17], milk yield [18,19], gestation period [20], and acclimatization [21].

Heat-burdened dairy cows show physiological and behavioral reactions that aim at decreasing heat production, while increasing heat dissipation. If adaptation is insufficient, body temperature rises [22], and the burdening situation results in the activation of the hypothalamus-hypophysis-adrenal axis, which leads to an increased plasma level of cortisol [23]. Physiological reactions include a rise in respiration, heart, and sweating rates [13,24,25]. Behavioral changes involve an increase in standing time at the expense of lying [26], a rise in drinking time [25], and a reduction in feeding and grazing time [27,28], as well as rumination time [17]. Physiological and behavioral reactions to heat load can be allocated to the three constructs of animal welfare defined by Fraser et al. [29] and modified by Keyserlingk et al. [30], biological functioning and health, affective state, and natural living [5], underlining the relevance of heat load and its abatement regarding the welfare of dairy cows.

Changes in behavior can be automatically detected with monitoring systems. The application of technical solutions gathering animal-related data with sensors for improving animal management is part of Precision Livestock Farming (PLF) [31]. The behaviors regarded for the examination of heat load include lying and standing [21,32], grazing [33], and ruminating [17,33]. Additionally, combinations of physiological, productional, and behavioral reactions are used [34]. Countermeasures can be taken timely and are more effective when heat load is detected early. Measurements include the use of fans and sprinklers [35], misters [36], or chilled lying stalls [37]. On pasture, dairy cows benefit from shaded areas [38]. Additionally, management can be altered to mitigate heat load, including the shift of feeding and grazing times to the evening or nighttime [39,40].

Most of the studies conducted on heat load in dairy cows, focus on the reactions of high-yielding Holstein cows; pasture-related behaviors are rarely investigated [41]. Therefore, the goal of our study was to assess the behavioral and physiological responses of dual-purpose Simmental cows on pasture to increasing heat load.

## 2. Materials and Methods

All conducted procedures of the study were approved by the ethics committee from the Faculty of Veterinary Medicine of Ludwig-Maximilians-University Munich (protocol no.: 231-08-08-2020) and were in accordance with EU directive 2010/63/EU and the German Animal Welfare Act.

### 2.1. Farm Management and Animals

The experiment was undertaken in 2020 on a conventional dairy farm in Bavaria, Germany, and was conducted in two rounds of five days in June (r1) and eight days in August (r2). The herd consisted of 52 dairy cows (94% Simmental, 4% German Black Pied, 2% German Red Pied) with a main milk yield of 8496 kg in the preceding year. The cows had permanent access to pasture (14 ha) as well as to a free stall barn with high cubicles ( $n = 48$ ) equipped with rubber mattresses. The pasture was managed continuously, with the same area being available to the cows at all times. Access to pasture was granted all days long from April to October, excluding 2 h around each milking (6:00–8:00 h and 18:00–20:00 h). The cows were milked twice daily in a tandem milking parlor, approximately starting at 06:30 h and 18:30 h. Forage was supplied by pasture, exclusively. Feed lime was offered on the feeding table in the barn two times a day before milking. Several mineral lick stones were available on the feeding table, too. Cows yielding  $\geq 35$  kg/d received concentrate from a transponder-controlled computerized feeder. Water was supplied ad libitum via two troughs in the barn and nine troughs on pasture.

Eleven (r1) and thirteen (r2) lactating cows were randomly selected from the herd based on the following criteria: second to fifth lactation, lactating (not dried off), freedom from lameness, changes in milk composition, and any other signs of health disorders. Some animals were selected in both rounds, and some were unique to each round. In the first round, average parity of the chosen cows ( $n = 11$ ) was  $3.6 \pm 1.3$  (mean  $\pm$  standard deviation), and the animals were  $205 \pm 51$  days in milk (DIM; range: 122–304 DIM) on

the first day of the round. In the second round, average parity of the chosen cows ( $n = 13$ ) was  $3.5 \pm 1.3$  and the animals were  $258 \pm 34$  DIM (range: 193–299 DIM). Mean milk yield was  $19.1 \pm 7.0$  kg (range: 6.6–26.7 kg) in r1 and  $18.9 \pm 4.4$  kg (range: 11.2–28.3 kg) in r2. Due to technical issues of the monitoring systems, behavior data from only five animals per round was available. Average parity of the cows of which behavior data was recorded ( $n = 5$ ) was  $3.2 \pm 1.2$  in the first round and  $4.4 \pm 1.1$  in the second round. The animals were  $194 \pm 42$  and  $243 \pm 34$  DIM on the first day of each round, respectively. Mean milk yield was  $20.8 \pm 5.5$  kg (range: 15.5–26.7 kg) in r1 and  $19.8 \pm 3.8$  kg (range: 13.5–28.3 kg) in r2.

## 2.2. Data Collection and Sampling

Data were collected on five (r1) and eight (r2) consecutive days (d). On d0, measurement technologies (as described in the following) were installed, and data collection started, with d1 marking the first day with 24 h of data. In r1, data collection began with morning milking; in r2, data collection started with evening milking. On d4 (r1) and d7 (r2), data collection was ended by removing the technologies.

### 2.2.1. Weather Conditions

A weather station was built and set up on a part of the pasture that was fenced off. Data on DBT ( $^{\circ}\text{C}$ ), RH (%) and WS (m/s) were collected every ten minutes by a weather transmitter (WXT510; Vaisala Oyj, Helsinki, Finland). RAD ( $\text{W}/\text{m}^2$ ) was measured every ten minutes by a pyranometer (CM11; OTT HydroMet B.V., Delft, The Netherlands). Hourly means were computed for every measurement from the weather station used to calculate the THI (1) according to the National Research Council [42] and the BGHI (2) according to Buffington et al. [12] for the data from the weather station using the following equations with DBT ( $^{\circ}\text{C}$ ), RH (%), BGT ( $^{\circ}\text{C}$ ), dew point temperature (DPT;  $^{\circ}\text{C}$ ), WS (m/s), and RAD ( $\text{W}/\text{m}^2$ ):

$$\text{THI} = (1.8 \times \text{DBT} + 32) - (0.55 - 0.0055 \times \text{RH}) \times (1.8 \times \text{DBT} - 26) \quad (1)$$

$$\text{BGHI} = \text{BGT} + 0.36 \times \text{DPT} + 41.5 \quad (2)$$

As only DBT was collected, BGT (3) and DPT (4) were calculated with the formulas proposed by Hajizadeh et al. [43] and Lawrence [44], respectively:

$$\text{BGT} = 0.01498 \times \text{RAD} + 1.184 \times \text{DBT} - 0.0789 \times \text{RH} - 2.739 \quad (3)$$

$$\text{DPT} = \text{DBT} - \left( \frac{100 - \text{RH}}{5} \right) \quad (4)$$

Weather data collection started on d0 and ended on d4 in r1 and started on d0 and ended on d7 in r2. From the hourly means, the average per 6 h period (06:00–12:00, 12:00–18:00, 18:00–24:00 and 00:00–06:00 h) as well as for 24 h (06:00–06:00 h) was calculated.

### 2.2.2. Behavior Data (Monitoring System)

On d0, the selected animals were equipped with the prototype of a monitoring system ( $133 \times 63 \times 35$  mm; 220 g; Blaupunkt Telematics GmbH, Hildesheim, Germany) attached to a collar. The same prototype was previously used in the studies of Schmeling et al. [45,46]. The system contained a sensor board (BNO055; Bosch Sensortec GmbH, Reutlingen, Germany) consisting of a 3D accelerometer, a 3D magnetometer, and a 3D gyroscope. The sensor was set to measure the raw acceleration (m/s) in three axes as well as the Euler angle ( $^{\circ}$ ) with a frequency of 10 Hz. Power was supplied by two lithium batteries. The batteries were changed once during each round (r1: d2, r2: d3). Data were stored on a Secure Digital Memory Card (SanDisk 32 GB; Western Digital Deutschland GmbH, Aschheim, Germany) and downloaded after each round. Following the experiment, two binary models were applied to the sensor data in order to predict different behaviors from the movement of the animals' neck and head. Both models were based on a random forest algorithm. One

model was used for the distinction of grazing and non-grazing and one for the distinction of ruminating and non-ruminating. The models were previously validated in combination with the same monitoring system prototype. The model for grazing behavior achieved an accuracy of 92% [46]. The ruminating model predicted rumination behavior with an accuracy of 98% on pasture and 97% in the barn [45].

### 2.2.3. Milk Yield and Milk Composition

Milk yield was automatically recorded with a milk meter integrated into the milking parlor at each milking. Daily milk yield was calculated as the sum of milk yield at morning and evening milking. Milk yield was recorded on five days (d0 to d4) in r1, and seven days (d1 to d7) in r2. During five (d0 to d4) and four (d2 to d5) morning milking in r1 and r2, respectively, a container was attached at a predesigned position in the milk pipe at each milking station, and a representative amount of milk was automatically separated into the container. From the container, a sample was taken and inserted into a sample tube containing the preserving agent Azidiol. Milk samples were cooled immediately and sent to the Milchprüfing Bayern e. V. (Wolnzach, Germany). Milk samples were analyzed for fat and protein content using infrared spectroscopy. To assess somatic cell count, a flow cytometry was performed. Analysis procedures were chosen according to the RohMilchGütV from the German Federal Ministry of Food and Agriculture [47]. Starting milk sampling on d2 in r2 instead of d0 as in r1 aimed at regarding a delay of two days in changes in milk composition caused by heat load [2].

### 2.2.4. Respiration Rate

Respiration rate was recorded during morning milking in the milking parlor (r1: d1 to d4; r2: d2, d4, d5) and in the afternoon on pasture or in the stable (14:00 to 17:00 h; r1: d0 to d4; r2: d1 to d4) by a trained observer. Flank movements were counted for 30 s, and the value was multiplied by two to receive respiration rate per minute, as conducted by Abeni et al. [48]. If the respiration rate of one animal was recorded more than once within the afternoon, the average was calculated. Respiration rate was only recorded while animals were lying ( $\pm$ ruminating) or standing ( $\pm$ ruminating). When animals were performing other behaviors (walking, grazing, social, or grooming behavior), the count was postponed.

### 2.2.5. Fecal Cortisol

A fresh fecal sample was taken from the selected cows every second day (r1: d0, d2, d4; r2: d3, d5, d7) after morning milking between 08:30 h and 09:00 h to determine the concentration of the cortisol metabolite 11,17-Dioxoandrostone (11,17 DOA). About 10 to 15 g were collected manually from the rectum or from freshly eliminated feces and filled into fecal sample tubes (17 mL; Dieckhoff and Ratschow Praxisdienst GmbH & Co. KG, Longuich, Germany). Samples were stored on ice immediately after collection and frozen to  $-18^{\circ}\text{C}$  within two hours. Sampling time was chosen because fecal cortisol level rises with a time delay of about 9 to 12 h after stressors occur and remains elevated for 18 to 44 h [49–51]. Cortisol metabolite content in the morning reflects the accumulated stress level from the preceding day [52]. After the experiment, the samples were processed at the laboratory of the Chair of Animal Welfare, Ethology, Animal Hygiene and Animal Husbandry of LMU Munich, Germany. After thawing and homogenization of the samples, 0.5 g were mixed with 1 mL of water and 4 mL of ethanol (80%) following Palme and Möstl [53]. The dispersion was centrifuged, and the supernatant was frozen at  $-18^{\circ}\text{C}$  and sent to the laboratory of the Institute for Medical Biochemistry of Vetmeduni Vienna, Austria, where the concentration of 11,17-DOA was determined using an 11-oxoetiocholanolone Enzyme Immunoassay previously validated for cattle [50].

### 2.3. Statistical Analysis

Data were assessed comparing different time periods. A day reflects the time from 6:00 h to 6:00 h the next day. Daytime considers the behavior from 6:00 to 18:00 h, while nighttime represents the time from 18:00 to 6:00 h the next day. For behavior data, a loss of 10% per considered time interval was tolerated according to Elischer et al. [54]. Due to technical issues of the monitoring systems, the data from only five animals per round could be used to evaluate the behavior under increasing heat load. Only days with a total of 24 h were considered in the comparison of behavior, which was true for d1 to d3 in r1 and d1 to d4 in r2.

All statistical analyses were conducted with RStudio 1.3 (RStudio, Inc., Boston, MA, USA). Additional packages used were *pgirmess* [55] and *DescTools* [56]. Differences in respiration rate on pasture and in the stable were assessed with a two-sided *t*-test. A Friedman test with post hoc multiple comparison was used to compare the respiration rate, milk yield, milk composition, somatic cell count, and fecal cortisol content between the different days for all observed cows. The difference between the change in fecal cortisol content was assessed with a *t*-test for paired samples in r1 and—due to lack of normal distribution—with a Wilcoxon test in r2. For the comparison of grazing and rumination behavior from five animals between the different days for 24 h, as well as for day and night, a Friedman test with post hoc multiple comparison was used as well. General differences between night and day rumination and grazing time were assessed with a two-sided *t*-test. Due to a lack of normal distribution, the differences per day between night and day rumination and grazing time were investigated with a Wilcoxon test. Following Crump et al. [57], Fleiss' Kappa coefficient of agreement ( $\kappa_F$ ) was used to calculate synchrony for the different behaviors during the day and during daytime and nighttime. Fleiss' Kappa is a test for the interrater reliability of more than two raters [58]. In our calculation, cows were considered raters, and the agreement (=synchrony) within the five cows for each behavior was calculated per hour. Within one hour, a behavior was considered to be shown when more than 50% of the time, equaling > 0.5 h, was spent on the behavior.  $\kappa_F$  was classified as <0 = poor, 0–0.2 = slight, 0.21–0.4 = fair, 0.41–0.6 = moderate, 0.61–0.8 = substantial, and 0.81–1 = almost perfect, according to Landis and Koch [59]. Where applicable, values were considered significant at  $p < 0.05$  and highly significant at  $p < 0.01$ .

## 3. Results

### 3.1. Weather Data

The mean values for DBT, RH, RAD, and WS and the different weather indices (THI, BGHI) per 6 h period and per day are depicted in Table 1 for r1 and Table 2 for r2. In both rounds, highest DBT, RAD, and index values within each day were observed in the period between 12:00 and 18:00 h on most days. On d5 in r2, however, highest mean values occurred from 06:00 to 12:00 h. On all days, RH was higher and wind speed was lower during the night than during the day. In r1, highest daily average DBT and RAD combined with high RH were observed on d4, resulting in the highest index values on that day compared to the other days within r1. In r2, highest daily average DBT, RAD and index, values were observed on d4. Highest RH occurred on d5, and lowest WS was recorded on d1.

### 3.2. Physiological Parameters

The development of respiration rate, milk yield, milk composition, and fecal cortisol content is depicted in Figure 1 for r1 and in Figure 2 for r2. No significant difference was found between respiration rate recorded in the stable or on pasture ( $p = 0.17$ ).

**Table 1.** Mean DBT <sup>1</sup>, RH <sup>2</sup>, RAD <sup>3</sup>, WS <sup>4</sup>, THI <sup>5</sup>, and BGHI <sup>6</sup> per 6 h period (0:00–06:00, 06:00–12:00, 12:00–18:00, and 18:00–24:00 h) and per day (06:00–06:00 h) in r1 on d1 to d4.

Day	Time of Day	DBT [°C]	RH [%]	RAD [W/m <sup>2</sup> ]	WS [m/s]	THI	BGHI
0	06:00–12:00	20	66	180	2.0	67	65
	12:00–18:00	23	45	213	2.4	69	70
	18:00–24:00	18	66	39	1.5	63	60
	00:00–06:00	13	78	0	1.5	56	52
	daily average	19	64	105	1.8	64	62
1	06:00–12:00	19	59	79	2.8	64	62
	12:00–18:00	23	39	128	3.1	68	68
	18:00–24:00	19	52	48	3.3	64	62
	00:00–06:00	14	82	0	1.8	57	52
	daily average	19	58	64	2.8	63	61
2	06:00–12:00	16	73	189	2.1	61	59
	12:00–18:00	22	51	356	2.5	68	71
	18:00–24:00	16	78	73	3.0	61	57
	00:00–06:00	10	97	0	0.6	51	47
	daily average	16	75	155	2.0	60	58
3	06:00–12:00	18	72	63	1.7	63	60
	12:00–18:00	25	53	190	3.3	72	73
	18:00–24:00	19	83	59	3.2	65	61
	00:00–06:00	16	95	0	1.0	61	56
	daily average	20	76	78	2.3	65	62
4	06:00–12:00	22	73	83	1.9	69	66
	12:00–18:00	27	50	224	3.8	75	76
	18:00–24:00	18	86	27	2.8	64	60
	00:00–06:00	16	96	0	0.6	62	57
	daily average	21	76	83	2.3	67	65

<sup>1</sup> dry bulb temperature, <sup>2</sup> relative humidity, <sup>3</sup> radiation, <sup>4</sup> wind speed, <sup>5</sup> Temperature-Humidity-Index, <sup>6</sup> Black Globe Humidity Index.

In r1, respiration rate of the observed animals ( $n = 11$ ) during morning milking increased significantly between d3 and d4 (21 vs. 27 breaths/minute;  $p < 0.05$ ). Respiration rate in the afternoon was statistically similar ( $p = 0.13$ ) but increased numerically on d4. Milk yield was significantly lower on d0 than on d2 (18.3 vs. 19.5 kg;  $p < 0.01$ ) and d3 (18.3 vs. 19.2 kg;  $p < 0.05$ ). Milk yield in the morning was higher on d4 than on d0 (10.2 vs. 8.7 kg;  $p < 0.01$ ) and d1 (10.2 vs. 9.2 kg;  $p < 0.05$ ). At evening milking, it was significantly lower on d4 than on d2 (9.2 vs. 10.2 kg;  $p < 0.01$ ). No significant difference was observed for somatic cell count ( $p = 0.12$ ), but on d4, the count was numerically higher. Milk fat and protein content were similar on all days ( $p = 0.32$  and  $p = 0.06$ , respectively). Fecal cortisol did not differ statistically ( $p = 0.06$ ), but a wider range was observed on d0 and the change in fecal cortisol content from d2 to d4 was significantly greater than from d0 to d2 (1.7 vs. 0.5;  $p < 0.05$ ).

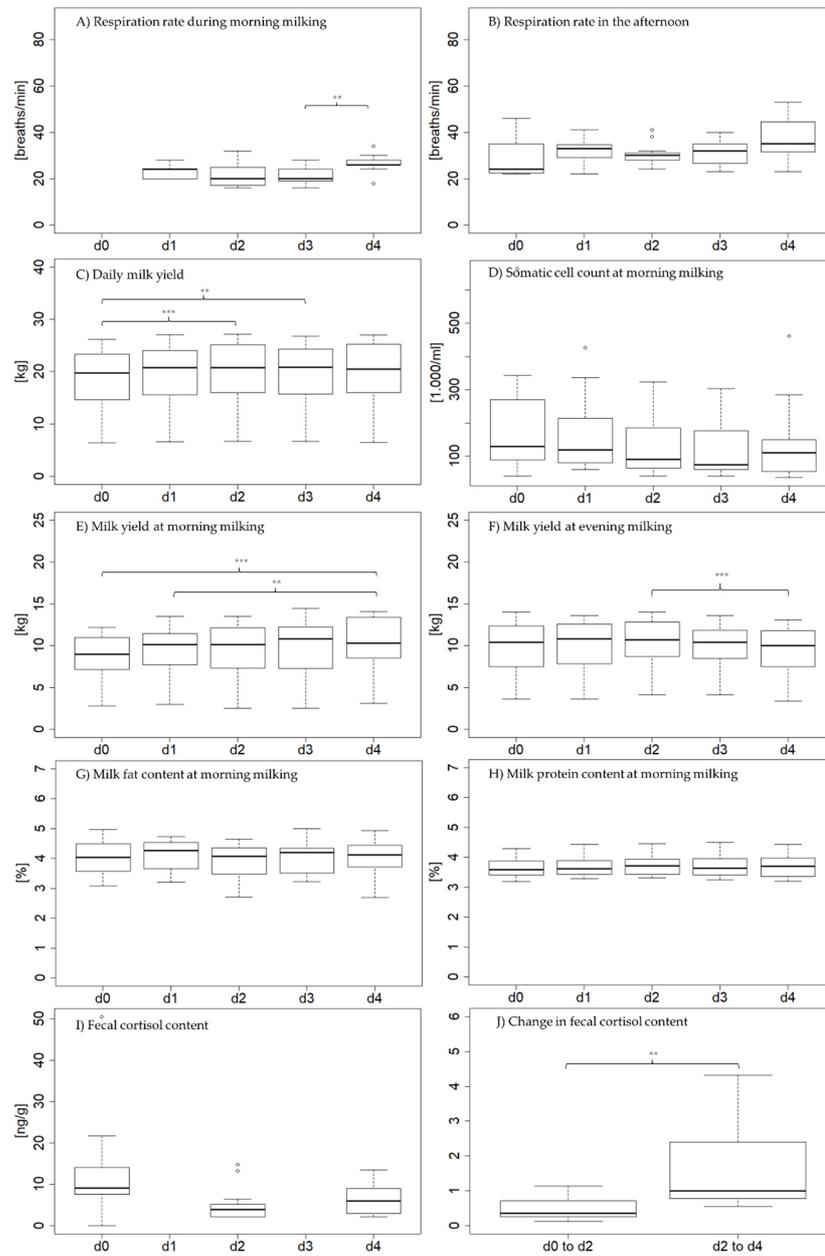
In r2, respiration rate of the observed animals ( $n = 13$ ) during morning milking increased between d2 and d5 (26 vs. 32 breaths/minute;  $p < 0.01$ ). In the afternoon, respiration rate increased significantly from d1 to d4 (28 vs. 62 breaths/minute;  $p < 0.01$ ). Daily milk yield was significantly lower on d3 than on d1 (18.4 vs. 19.6 kg;  $p < 0.05$ ). Morning milk yield decreased significantly from d1 to d5 (10.9 vs. 9.3 kg;  $p < 0.01$ ), increased to d6, but stayed low until d7, whereas evening milk yield was higher on d3 than on d1 (10.4 vs. 9.0 kg;  $p < 0.01$ ) and decreased non-significantly afterwards. Somatic cell count and milk fat content were similar between the different days ( $p = 0.43$  and  $p = 0.37$ , respectively). Milk protein decreased significantly between d4 and d5 (3.90 vs. 3.81%;  $p < 0.01$ ). Fecal cortisol increased from d3 to d5 to d7 with significant differences between

d3 and d5 (8.5 vs. 17.9 ng/g;  $p < 0.05$ ) and d3 and d7 (8.5 vs. 18.4 ng/g;  $p < 0.01$ ). The change in fecal cortisol from d3 to d5 and from d5 to d7 did not differ significantly ( $p = 0.20$ ).

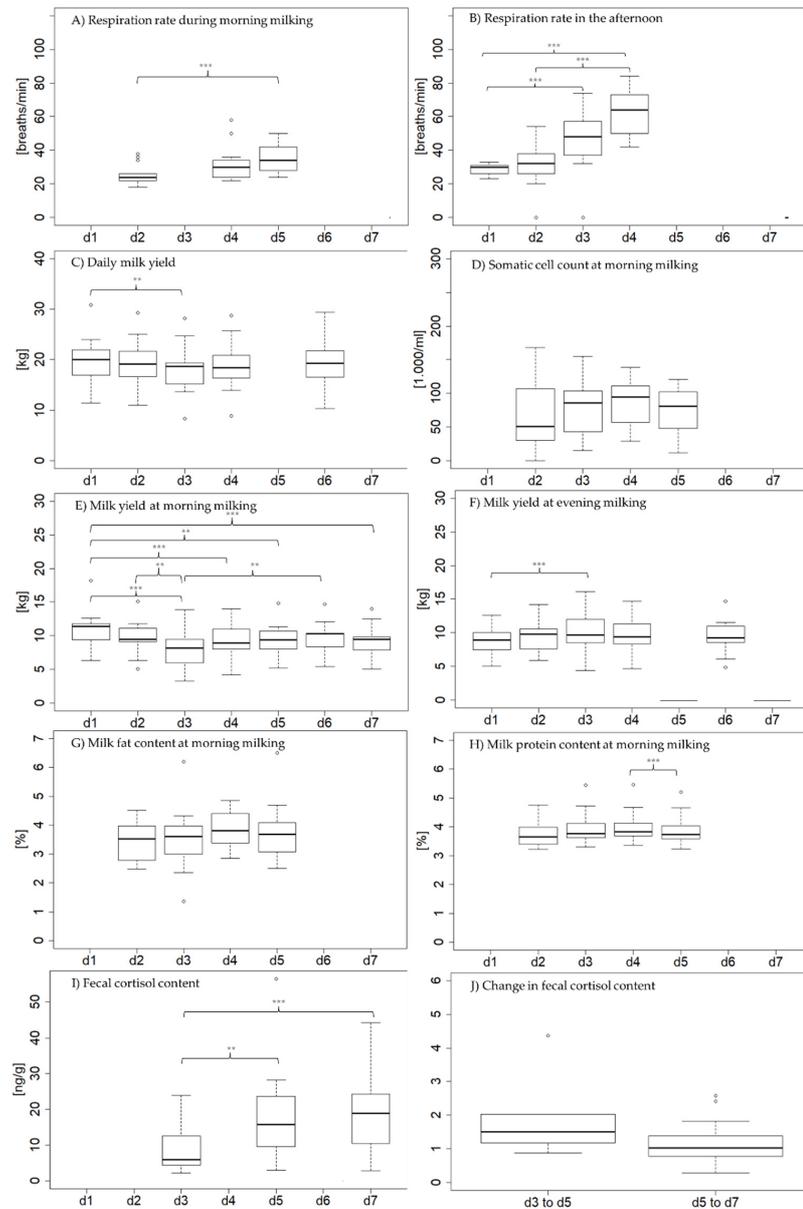
**Table 2.** Mean DBT <sup>1</sup>, RH <sup>2</sup>, RAD <sup>3</sup>, WS <sup>4</sup>, THI <sup>5</sup>, and BGHI <sup>6</sup> per 6 h period (0:00–06:00, 06:00–12:00, 12:00–18:00, and 18:00–24:00 h) and per day (06:00–06:00 h) in r2 on d1 to d7.

Day	Time of Day	DBT [°C]	RH [%]	RAD [W/m <sup>2</sup> ]	WS [m/s]	THI	BGHI
0	18:00–24:00	20	68	82	0.7	66	64
	00:00–06:00	17	83	0	0.3	61	56
	daily average	-7	-7	-7	-7	-7	-7
1	06:00–12:00	17	78	128	0.9	62	60
	12:00–18:00	19	74	315	0.7	64	64
	18:00–24:00	18	74	91	0.5	63	60
	00:00–06:00	15	85	0	0.6	58	54
	daily average	17	78	133	0.7	62	59
2	06:00–12:00	15	79	258	0.7	59	58
	12:00–18:00	22	49	632	0.9	68	75
	18:00–24:00	20	63	101	0.6	65	63
	00:00–06:00	15	78	0	0.9	58	54
	daily average	18	67	248	0.8	63	63
3	06:00–12:00	16	77	216	1.0	60	59
	12:00–18:00	27	42	721	1.1	73	84
	18:00–24:00	25	51	115	0.8	72	72
	00:00–06:00	19	67	0	1.6	65	61
	daily average	22	59	263	1.1	68	69
4	06:00–12:00	19	70	247	1.3	65	65
	12:00–18:00	30	39	738	1.1	77	89
	18:00–24:00	28	45	111	0.8	74	76
	00:00–06:00	20	77	0	0.6	67	62
	daily average	24	58	274	0.9	71	73
5	06:00–12:00	21	72	46	2.3	68	65
	12:00–18:00	19	89	26	2.7	66	61
	18:00–24:00	18	96	9	1.6	65	59
	00:00–06:00	16	99	0	0.7	60	55
	daily average	19	89	46	1.8	65	60
6	06:00–12:00	19	80	126	2.6	64	62
	12:00–18:00	21	59	155	4.9	68	66
	18:00–24:00	16	78	11	1.8	61	57
	00:00–06:00	12	91	0	1.0	54	50
	daily average	17	77	73	2.5	62	59
7	06:00–12:00	16	76	167	0.9	60	58
	12:00–18:00	20	50	487	2.6	66	70
	18:00–24:00	15	81	23	0.9	59	55

<sup>1</sup> dry bulb temperature, <sup>2</sup> relative humidity, <sup>3</sup> radiation, <sup>4</sup> wind speed, <sup>5</sup> Temperature-Humidity-Index, <sup>6</sup> Black Globe Humidity Index, <sup>7</sup> as recording started at noon no average was calculated for that d1.



**Figure 1.** Development of respiration rate (A,B), milk yield (C,E,F), milk composition (G,H), somatic cell count (D), and fecal cortisol level (I,J) in r1 from d0 to d4. “\*\*\*” indicates highly significant differences ( $p < 0.01$ ), and “\*\*” indicates significant differences ( $p < 0.05$ ).



**Figure 2.** Development of respiration rate (A,B), milk yield (C,E,F), milk composition (G,H), somatic cell count (D), and fecal cortisol level (I,J) in r2 from d1 to d7. “\*\*\*” indicates highly significant differences ( $p < 0.01$ ), and “\*\*” indicates significant differences ( $p < 0.05$ ).

### 3.3. Grazing Behavior

In r1, animals ( $n = 5$ ) grazed for a mean of 8.2 ( $\pm 0.6$ ) h per 24 h period. Grazing time decreased significantly between d1 and d2 (8.9 vs. 7.8 h/d;  $p < 0.01$ ; see Table 3). Between d2 and d3, grazing time increased numerically, but it was not statistically significant (7.8 vs. 7.9 h/d;  $p > 0.05$ ). The same differences between the days were evident when considering daytime grazing (4.9 vs. 3.9 vs. 4.1 h/12h;  $p < 0.05$ ), but no difference was found between nighttime grazing between days. In general, significantly more grazing time occurred during the day than during the night ( $p < 0.05$ ), but within each day, the difference could not be confirmed statistically. On d2, the same time was spent grazing during the day and during the night (3.9 h/12 h). Overall  $\kappa_F$  for grazing was 0.66, which indicates a substantial agreement between animals (=synchrony). Synchrony on d1 and d3 was similar (0.63 vs. 0.62) but was higher on d2 (0.73; see Table 4). In general, synchrony was slightly lower during the day than during the night (0.63 vs. 0.69). This was true for d1 (0.59 vs. 0.67) and d2 (0.67 vs. 0.79), but not for d3 (0.63 vs. 0.61).

**Table 3.** Grazing and ruminating behavior per day (d; 06:00–06:00 h) and separately for daytime (06:00–18:00 h) and nighttime (06:00–18:00 h) for d1 to d3 in r1 and for d1 to d4 in r2. For behavior evaluation, previously validated machine learning models [45,46,60] for each behavioral pattern were applied to the sensor data from 5 animals.

	d1		d2		d3		d4	
	$\bar{\sigma}$	SEM	$\bar{\sigma}$	SEM	$\bar{\sigma}$	SEM	$\bar{\sigma}$	SEM
	round 1							
Grazing time/24 h [h]	8.9 <sup>a</sup>	0.37	7.8 <sup>b</sup>	0.39	7.9 <sup>a,b</sup>	0.30	- <sup>1</sup>	
Grazing time/12 h daytime [h]	4.9 <sup>a</sup>	0.22	3.9 <sup>b</sup>	0.25	4.1 <sup>a,b</sup>	0.19	- <sup>1</sup>	
Grazing time/12 h nighttime [h]	4.0	0.16	3.9	0.20	3.8	0.17	- <sup>1</sup>	
Rumination time/24 h [h]	7.1	0.25	6.8	0.33	7.1	0.17	- <sup>1</sup>	
Rumination time/12 h daytime [h]	2.7	0.34	2.6	0.26	3.0	0.13	- <sup>1</sup>	
Rumination time/12 h nighttime [h]	4.4	0.12	4.2	0.14	4.1	0.06	- <sup>1</sup>	
	round 2							
Grazing time/24 h [h]	7.0	0.34	6.8	0.48	7.1	0.38	6.4	0.38
Grazing time/12 h daytime [h]	3.7 <sup>a,b</sup>	0.22	4.6 <sup>a</sup>	0.21	4.3 <sup>a,b</sup>	0.26	2.9 <sup>b</sup>	0.28
Grazing time/12 h nighttime [h]	3.3 <sup>a,b</sup>	0.14	2.2 <sup>a</sup>	0.30	2.8 <sup>a,b</sup>	0.19	3.5 <sup>b</sup>	0.13
Rumination time/24 h [h]	7.0	0.31	7.5	0.19	7.4	0.26	8.2	0.14
Rumination time/12 h daytime [h]	2.9 <sup>a,b</sup>	0.14	2.3 <sup>a</sup>	0.14	2.6 <sup>a,b</sup>	0.16	3.6 <sup>b</sup>	0.22
Rumination time/12 h nighttime [h]	4.1 <sup>b</sup>	0.19	5.2 <sup>a</sup>	0.19	4.8 <sup>a,b</sup>	0.26	4.6 <sup>a,b</sup>	0.19

<sup>a,b</sup> significant ( $p < 0.05$ ) differences within a row; <sup>1</sup> behavior data was not recorded for 24 h on that day in round 1.

In r2, animals grazed for a mean of 6.8 ( $\pm 0.8$ ) h per 24 h period. Grazing time did not differ significantly between the days ( $p = 0.15$ ; see Table 3). However, when considering daytime and nighttime separately, d2 and d4 differed significantly, with more grazing time being shown on d2 during the day (4.6 vs. 2.9 h/12 h;  $p < 0.01$ ) and on d4 during the night (2.2 vs. 3.5 h/12 h;  $p < 0.01$ ). In general, significantly more grazing time occurred during the day ( $p < 0.01$ ), but on d4, nighttime grazing time was higher than grazing time during the day (3.5 vs. 2.9 h/12 h). Overall  $\kappa_F$  for grazing was 0.68, which indicates a substantial agreement between animals (=synchrony). Although on d1 and d4, synchrony was substantial (0.71 and 0.73, respectively), it was only moderate on d2 and d3 (0.59 both; see Table 4). In general, synchrony was lower during the day than during the night (0.64 vs.

0.72). This was evident on d1 (0.60 vs. 0.80), d3 (0.56 vs. 0.62), and d4 (0.50 vs. 0.92) but not on d2 (0.82 vs. 0.41).

**Table 4.** Fleiss' Kappa ( $\kappa_F$ ) values for the evaluation of synchrony of grazing and ruminating behavior in the two rounds from 5 animals for each day (d; 06:00–06:00 h) and during daytime (06:00–18:00 h) and nighttime (06:00–18:00 h) for d1 to d3 in r1 and for d1 to d4 in r2.

	Round 1			Round 2			
	d1	d2	d3	d1	d2	d3	d4
Synchrony of grazing behavior within 24 h	0.63	0.73	0.62	0.71	0.59	0.59	0.73
Synchrony of grazing behavior during the day	0.59	0.67	0.63	0.60	0.82	0.56	0.50
Synchrony of grazing behavior during the night	0.67	0.79	0.61	0.80	0.41	0.62	0.92
Synchrony of ruminating behavior within 24 h	0.30	0.32	0.43	0.45	0.42	0.39	0.27
Synchrony of ruminating behavior during the day	0.04	0.26	0.35	0.28	0.11	0.41	0.34
Synchrony of ruminating behavior during the night	0.38	0.31	0.48	0.52	0.40	0.34	0.18

### 3.4. Ruminating Behavior

In r1, animals ( $n = 5$ ) ruminated for a mean of 7.0 ( $\pm 0.5$ ) h per 24 h period. Rumination time did not differ significantly between the days ( $p > 0.05$ ; see Table 3). In general, significantly more ruminating occurred during the night than during the day ( $p < 0.01$ ), but within each day, the difference could not be confirmed statistically. Differences between the different days were not evident when daytime and nighttime rumination time was assessed separately. Overall  $\kappa_F$  for ruminating behavior was 0.35, which indicates fair agreement (=synchrony) between animals. Synchrony increased from d1 (0.30) to d2 (0.32) and was highest on d3 (0.43; see Table 4). In general, synchrony was higher during the night than during the day (0.23 vs. 0.39) which was evident for all days.

In r2, animals ruminated for a mean of 7.5 ( $\pm 0.3$ ) h per 24 h period. Rumination time per day did not differ significantly between the different days ( $p > 0.05$ ; see Table 3). In general, significantly more ruminating occurred during the night than during the day ( $p < 0.01$ ). Ruminating time during the day differed significantly between d2 and d4 (2.3 vs. 3.6 h/12 h;  $p < 0.01$ ) and ruminating time during the night differed significantly between d1 and d2 (4.1 vs. 5.2 h/12 h;  $p < 0.05$ ). Overall  $\kappa_F$  for ruminating was 0.38, which indicates fair agreement (=synchrony). Between the days, synchrony decreased steadily from 0.45 on d1 to 0.27 on d4 (see Table 4). In general, synchrony of rumination behavior was similar during the day and during the night (0.32 vs. 0.36). However, within each day, synchrony was higher during the night on d1 (0.28 vs. 0.52) and d2 (0.11 vs. 0.40) and higher during the day on d3 (0.41 vs. 0.34) and d4 (0.34 vs. 0.18).

## 4. Discussion

### 4.1. Physiological Responses in Relation to Weather Conditions

In previous studies, different thresholds were defined for the various weather indices depending on the regarded physiological reaction. In r1, the daily THI and BGHI means did not reach the thresholds of 67 and 74 determined by Zimelman et al. [61] and Dalcin et al. [62], respectively, for the elevation of respiration rate. However, respiration rate increased significantly during morning milking and numerically in the afternoon, between d3 and d4 when THI increased from 65 to 67 and BGHI from 62 to 65. Kibler [63] stated that respiration rate elevation is the first reaction towards heat load shown by dairy cows, which is in line with our findings. Previously determined thresholds for changes in milk yield vary widely. Although the THI thresholds of 60 to 62 defined by Brüge-

mann [2], Hammami et al. [1] and Gorniak et al. [64] for changes in milk yield and milk composition in Holstein cows were reached on all days except for d2, no reduction in milk yield with rising intensity of weather conditions or change in milk fat or protein was observed in r1 in our study. The reduced milk yield on d0 might have been caused by the presence of an unknown person during milking. This is supported by the reduction in milk yield being mainly based on a reduction in morning milk yield, whereas evening milk yield was not reduced. Concerning the reduction in milk yield caused by high temperatures, Brügemann [2] found that changes in milk yield and milk composition under heat load occur with a time delay of two days. Therefore, the changes in our study might have occurred after the observed period. On the other hand, Gantner [65] defined a THI threshold of 77 for a reduction in milk yield in Simmental cows. That threshold was not reached in r1 in our study. Although a certain reaction towards heat load was shown by an elevated respiration rate, burden of the weather conditions was not confirmed by a rise in fecal cortisol level in r1. Heat dissipation through breathing air might have prevented the animals from experiencing a burden caused by the observed weather conditions.

In contrast to r1, heat load was confirmed by elevated fecal cortisol content, which could be based on the more extreme and longer excess of heat load thresholds in r2. Although temperatures decreased after d5, heat load seemed to persist, reflected by a persisting high level of fecal cortisol on d7. R1 of data collection was conducted in June, after two months of pasture season, whereas r2 took place in August, when cows had already been outside for four months. On the one hand, physiological reactions towards heat load can be expected to be more pronounced at the beginning summer, when animals are not acclimatized to higher temperatures yet [66]. On the other hand, heat load can accumulate leading to more extreme reactions to high temperatures at the end of summer [21]. The observed group of cows (r1:  $n = 11$ , r2:  $n = 13$ ) differed between rounds, and some cows were unique to one round. Although focal cows had higher DIM in r2 (194 vs. 243), average milk yield did not differ (19.1 vs. 18.9 kg). Milk yield influences the sensitivity of dairy cows to heat load [18]. The similar milk yield results in the same thresholds for respiration rate elevation.

In r2, a significant rise in respiration rate was observed between d2 and d3 when THI changed from 63 to 69 and BGHI from 63 to 69. The change is in line with the THI threshold for respiration rate elevation of 67 defined by Zimelman et al. [61] but occurred at lower BGHI values than expected after the findings of Dalcin et al. [62]. In contrast to r1, milk yield was reduced on d3 and stayed low until d7 in r2. The decrease in milk yield was mainly based on a reduction in morning milk yield and was partly compensated by an elevated evening milk yield. On d3, THI reached a daily mean of 68 and BGHI a mean of 69. Observed THI threshold for change in milk yield is in line with the findings of Zimelman et al. [61], higher than the thresholds determined by Hammami et al. [1] for Holstein cows in the stable, by Brügemann [2] for Holstein cows on pasture and lower than the threshold determined by Gantner [65] for Simmental cows in the stable. If a delay of two days for the heat load induced change in milk yield is considered, as proposed by Brügemann [2], we observed the same threshold of 62, as determined in the mentioned study. Milk composition did not differ between the days in r2. Unlike r1, a longer time period was covered after the days with increased heat load intensity. The lack of change in milk composition might have been prevented by a reduction in milk yield in general.

#### 4.2. Behavioral Changes

In r1, grazing duration was similar on d1 and d2 but decreased on d3 with higher index values. The reduction in grazing time corresponds to the findings of Tucker et al. [27] in Holstein cows. In contrast, Fisher et al. [67] did not observe a reduction in grazing time. In their study, observations were limited to two 24 h periods and were also conducted with Holstein cows. In r2, no significant difference was observed in grazing time between the days, whereas grazing time was numerically lower on d4. In general, significantly more time was spent grazing during the day than during the night in the second round. However,

on d4, more grazing was shown during the night than during the day. Feed utilization is linked to heat production in dairy cows [68]. A shift of grazing behavior towards the cooler night hours might be a counteraction to heat burdening daytime. In r1, more time was spent grazing compared to r2. Although milk yield did not differ significantly between the rounds, it was lower in r2 due to higher DIM. Lower milk yields and thereby energy requirements could have caused the lower grazing time. Additionally, differences in pasture quality and availability might have influenced grazing behavior. Rumination time did not differ significantly between the days in r1 and r2, but more rumination time was shown during the night than during the day which is in line with previously conducted studies [69,70]. Additionally, a difference between day- and nighttime rumination behavior was largest on d4 in r2.

Synchrony of grazing behavior was moderate to high, which is in agreement with the findings of Flury and Gyax [71] for animals on pasture. In general, rumination behavior had a lower synchrony. Between the rounds, synchrony of grazing and rumination behavior only differed slightly (0.66 vs. 0.68 for grazing, 0.35 vs. 0.38 for ruminating in r1 and r2, respectively). No meaningful development of synchrony was observed in r1. Within r2, synchrony of rumination behavior decreased steadily. Synchrony of grazing behavior was decreased on d2 and d3. Only a small subset of the herd ( $n = 5$ ) was included in the behavior assessment under heat load. As most of the animals ( $n = 4$ ) were unique to each round, a comparison between rounds is difficult. The behavioral dynamics of the whole herd might also look different, because the development of heat load highly relates to various factors that are individual for each animal [41].

## 5. Conclusions

The two periods of data collection differed in extremity of heat load conditions. In both rounds, elevated respiration rates as a first physiological reaction towards high temperatures was observed. The burden of weather conditions was confirmed by an elevated fecal cortisol level only in r2, where temperatures were more extreme. Additionally, a reduction in milk yield and changes in milk composition as consequences of heat load only occurred in the second round. Whereas the observed thresholds for THI were in line with previous literature, physiological heat load reactions were evident at lower BGHI values than those reported previously. The behavioral changes observed in a subset of animals included a reduction in grazing duration and a shift of grazing time towards the night.

Although informative value of reported behavior changes is limited by the small sample size, they provide the base for further studies on the behavioral reactions of mid-yielding Simmental cows to heat load on pasture.

**Author Contributions:** Conceptualization, S.T. and E.R.; methodology, L.S., S.T. and E.R.; validation, L.S.; formal analysis, L.S.; resources, S.T.; data curation, L.S.; writing—original draft preparation, L.S.; writing—review and editing, S.T., M.E. and E.R.; visualization, L.S.; supervision, S.T., M.E. and E.R.; project administration, S.T. and E.R.; funding acquisition, S.T. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research was funded by Bavarian Research Foundation, grant number 1301-17.

**Institutional Review Board Statement:** The study was conducted according to the guidelines of EU directive 2010/63/EU and the German Welfare Act and was approved by the Ethics Committee from the Faculty of Veterinary Medicine of Ludwig-Maximilians-University Munich (protocol code 231-08-08-2020).

**Informed Consent Statement:** Not applicable.

**Data Availability Statement:** Data is contained within the article.

**Acknowledgments:** First: we would like to thank the farmer and his family for allowing us to conduct the study on their farm and for their support in animal handling and sampling. We are grateful for the help of Daniela Nicklas and her students who developed the machine learning models. Furthermore, we would like to thank Alexander Süsse from Blaupunkt Telematics GmbH for providing us with the prototype of the monitoring system.

**Conflicts of Interest:** The authors declare no conflict of interest. The funders had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript, or in the decision to publish the results.

## References

- Hammami, H.; Bormann, J.; M'hamdi, N.; Montaldo, H.H.; Gengler, N. Evaluation of heat stress effects on production traits and somatic cell score of Holsteins in a temperate environment. *J. Dairy Sci.* **2013**, *96*, 1844–1855. [[CrossRef](#)] [[PubMed](#)]
- Brügemann, K. Defining and evaluating heat stress thresholds in different dairy cow production systems. *Arch. Tierz.* **2012**, *55*, 13–24. [[CrossRef](#)]
- Carvalho, D.; Cardoso Pereira, S.; Rocha, A. Future surface temperatures over Europe according to CMIP6 climate projections: An analysis with original and bias-corrected data. *Clim. Chang.* **2021**, *167*, 10. [[CrossRef](#)]
- Wankar, A.K.; Rindhe, S.N.; Doijad, N.S. Heat stress in dairy animals and current milk production trends, economics, and future perspectives: The global scenario. *Trop Anim. Health Prod.* **2021**, *53*, 70. [[CrossRef](#)]
- Polsky, L.; von Keyserlingk, M.A.G. Invited review: Effects of heat stress on dairy cattle welfare. *J. Dairy Sci.* **2017**, *100*, 8645–8657. [[CrossRef](#)]
- Gantner, V.; Bobić, T.; Potočnik, K.; Gregić, M.; Kučević, D. Persistence of heat stress effect in dairy cows. *Mljekarstvo/Dairy* **2019**, *69*, 30–41. [[CrossRef](#)]
- Schüller, L.K.; Burfeind, O.; Heuwieser, W. Impact of heat stress on conception rate of dairy cows in the moderate climate considering different temperature-humidity index thresholds, periods relative to breeding, and heat load indices. *Theriogenology* **2014**, *81*, 1050–1057. [[CrossRef](#)]
- Gantner, V.; Kuterovac, K.; Potočnik, K. Effect of Heat Stress on Metabolic Disorders Prevalence Risk and Milk Production in Holstein Cows in Croatia. *Ann. Anim. Sci.* **2016**, *16*, 451–461. [[CrossRef](#)]
- Vitali, A.; Felici, A.; Lees, A.M.; Giacinti, G.; Maresca, C.; Bernabucci, U.; Gaughan, J.B.; Nardone, A.; Lacetera, N. Heat load increases the risk of clinical mastitis in dairy cattle. *J. Dairy Sci.* **2020**, *103*, 8378–8387. [[CrossRef](#)]
- Sanders, A.H.; Shearer, J.K.; de Vries, A. Seasonal incidence of lameness and risk factors associated with thin soles, white line disease, ulcers, and sole punctures in dairy cattle. *J. Dairy Sci.* **2009**, *92*, 3165–3174. [[CrossRef](#)]
- Thom, E.C. The Discomfort Index. *Weatherwise* **1959**, *12*, 57–61. [[CrossRef](#)]
- Buffington, D.E.; Collazo-Arocho, A.; Canton, G.H.; Pitt, D.; Thatcher, W.W.; Collier, R.J. Black Globe-Humidity Index (BGHI) as Comfort Equation for Dairy Cows. *Trans. ASAE* **1981**, *24*, 711–714. [[CrossRef](#)]
- Gebremedhin, K.G.; Lee, C.N.; Hillman, P.E.; Collier, R.J. Physiological Responses of Dairy Cows during Extended Solar Exposure. *Trans. ASABE* **2010**, *53*, 239–247. [[CrossRef](#)]
- Rashid, S.A.; Tomar, A.K.S.; Verma, M.R.; Mehrotra, S.; Bharti, P.K. Effect of skin and coat characteristics on growth and milk production traits in Tharparkar cattle. *Indian J. Anim. Sci.* **2019**, *89*, 1251–1254.
- Ji, B.; Banhazi, T.; Ghahramani, A.; Bowtell, L.; Wang, C.; Li, B. Modelling of heat stress in a robotic dairy farm. Part 2: Identifying the specific thresholds with production factors. *Biosyst. Eng.* **2020**, *199*, 43–57. [[CrossRef](#)]
- Ji, B.; Banhazi, T.; Ghahramani, A.; Bowtell, L.; Wang, C.; Li, B. Modelling of heat stress in a robotic dairy farm. Part 1: Thermal comfort indices as the indicators of production loss. *Biosyst. Eng.* **2020**, *199*, 27–42. [[CrossRef](#)]
- Abeni, F.; Galli, A. Monitoring cow activity and rumination time for an early detection of heat stress in dairy cow. *Int. J. Biometeorol.* **2017**, *61*, 417–425. [[CrossRef](#)]
- Navrátil, S.; Falta, D.; Chládek, G. Effect of Temperature Cumulation on Milk Yield of Czech Fleckvieh-Simmental Cattle. *Acta Univ. Agric. Silv. Mendel. Brun.* **2017**, *65*, 1579–1584. [[CrossRef](#)]
- Heinicke, J.; Hoffmann, G.; Ammon, C.; Amon, B.; Amon, T. Effects of the daily heat load duration exceeding determined heat load thresholds on activity traits of lactating dairy cows. *J. Therm. Biol.* **2018**, *77*, 67–74. [[CrossRef](#)]
- Abdeltalif, A.M.; Alameen, A.O. Influence of Season and Pregnancy on Thermoregulation and Haematological Profile in Crossbred Dairy Cows in Tropical Environment. *Glob. Vet.* **2012**, *9*, 334–340. [[CrossRef](#)]
- Heinicke, J.; Ibscher, S.; Belik, V.; Amon, T. Cow individual activity response to the accumulation of heat load duration. *J. Therm. Biol.* **2019**, *82*, 23–32. [[CrossRef](#)] [[PubMed](#)]
- Van Laer, E.; Tuytens, F.A.M.; Ampe, B.; Sonck, B.; Moons, C.P.H.; Vandaele, L. Effect of summer conditions and shade on the production and metabolism of Holstein dairy cows on pasture in temperate climate. *Animal* **2015**, *9*, 1547–1558. [[CrossRef](#)] [[PubMed](#)]
- Chen, S.; Wang, J.; Peng, D.; Li, G.; Chen, J.; Gu, X. Exposure to heat-stress environment affects the physiology, circulation levels of cytokines, and microbiome in dairy cows. *Sci. Rep.* **2018**, *8*, 14606. [[CrossRef](#)] [[PubMed](#)]

24. McManus, C.M.; Louvandini, H.; Paim, T.P.; Silva, F.C.P.; Bernal, F.E.M. Factors affecting heat tolerance in crossbred cattle in central Brazil. *Ciênc. Anim. Bras.* **2014**, *15*, 152–158. [[CrossRef](#)]
25. Vizzotto, E.F.; Fischer, V.; Thaler Neto, A.; Abreu, A.S.; Stumpf, M.T.; Werncke, D.; Schmidt, F.A.; McManus, C.M. Access to shade changes behavioral and physiological attributes of dairy cows during the hot season in the subtropics. *Animal* **2015**, *9*, 1559–1566. [[CrossRef](#)] [[PubMed](#)]
26. Herbut, P.; Angrecca, S. The effect of heat stress on time spent lying by cows in a housing system. *Ann. Anim. Sci.* **2018**, *18*, 825–833. [[CrossRef](#)]
27. Tucker, C.B.; Rogers, A.R.; Schütz, K.E. Effect of solar radiation on dairy cattle behaviour, use of shade and body temperature in a pasture-based system. *Appl. Anim. Behav. Sci.* **2008**, *109*, 141–154. [[CrossRef](#)]
28. Eslamizad, M.; Lamp, O.; Derno, M.; Kuhla, B. The control of short-term feed intake by metabolic oxidation in late-pregnant and early lactating dairy cows exposed to high ambient temperatures. *Physiol. Behav.* **2015**, *145*, 64–70. [[CrossRef](#)]
29. Fraser, D.; Weary, D.M.; Pajor, E.; Milligan, B.N. A Scientific Conception of Animal Welfare that Reflects Ethical Concerns. *Anim. Welf.* **1997**, *6*, 187–205.
30. Von Keyserlingk, M.A.G.; Rushen, J.; de Passillé, A.M.; Weary, D.M. Invited review: The welfare of dairy cattle—key concepts and the role of science. *J. Dairy Sci.* **2009**, *92*, 4101–4111. [[CrossRef](#)]
31. Berckmans, D. Precision livestock farming technologies for welfare management in intensive livestock systems. *Rev. Sci. Tech. OIE* **2014**, *33*, 189–196. [[CrossRef](#)] [[PubMed](#)]
32. Allen, J.D.; Hall, L.W.; Collier, R.J.; Smith, J.F. Effect of core body temperature, time of day, and climate conditions on behavioral patterns of lactating dairy cows experiencing mild to moderate heat stress. *J. Dairy Sci.* **2015**, *98*, 118–127. [[CrossRef](#)] [[PubMed](#)]
33. Arias, R.A.; Delgado, C.; Keim, J.P.; Gandarillas, M. Use of the Comprehensive Climate Index to estimate heat stress response of grazing dairy cows in a temperate climate region. *J. Dairy Res.* **2021**, *88*, 154–161. [[CrossRef](#)] [[PubMed](#)]
34. Becker, C.A.; Aghalari, A.; Marufuzzaman, M.; Stone, A.E. Predicting dairy cattle heat stress using machine learning techniques. *J. Dairy Sci.* **2021**, *104*, 501–524. [[CrossRef](#)]
35. Karimi, M.T.; Ghorbani, G.R.; Kargar, S.; Drackley, J.K. Late-gestation heat stress abatement on performance and behavior of Holstein dairy cows. *J. Dairy Sci.* **2015**, *98*, 6865–6875. [[CrossRef](#)]
36. Boonsanit, D.; Chanpongsang, S.; Chaiyabutr, N. Effects of supplemental recombinant bovine somatotropin and mist-fan cooling on the renal tubular handling of sodium in different stages of lactation in crossbred Holstein cattle. *Res. Vet. Sci.* **2012**, *93*, 417–426. [[CrossRef](#)]
37. Ortiz, X.A.; Smith, J.F.; Rojano, F.; Choi, C.Y.; Bruer, J.; Steele, T.; Schuring, N.; Allen, J.; Collier, R.J. Evaluation of conductive cooling of lactating dairy cows under controlled environmental conditions. *J. Dairy Sci.* **2015**, *98*, 1759–1771. [[CrossRef](#)]
38. Schütz, K.E.; Rogers, A.R.; Poulouin, Y.A.; Cox, N.R.; Tucker, C.B. The amount of shade influences the behavior and physiology of dairy cattle. *J. Dairy Sci.* **2010**, *93*, 125–133. [[CrossRef](#)]
39. Calamari, L.; Petrera, F.; Stefanini, L.; Abeni, F. Effects of different feeding time and frequency on metabolic conditions and milk production in heat-stressed dairy cows. *Int. J. Biometeorol.* **2013**, *57*, 785–796. [[CrossRef](#)]
40. Steinwider, A.; Gasteiner, J. 8 Tipps Gegen Hitzestress bei Milchkühen. Available online: <https://landwirt-media.com/8-tipps-gegen-hitzestress-bei-milchkuehen/> (accessed on 16 September 2021).
41. Galán, E.; Llonch, P.; Villagrà, A.; Levit, H.; Pinto, S.; Del Prado, A. A systematic review of non-productivity-related animal-based indicators of heat stress resilience in dairy cattle. *PLoS ONE* **2018**, *13*, e0206520. [[CrossRef](#)]
42. National Research Council (U.S.). *A Guide to Environmental Research on Animals*; National Academy of Sciences: Washington, DC, USA, 1971; ISBN 0309018692 9780309018692.
43. Hajizadeh, R.; Farhang Dehghan, S.; Golbabaie, F.; Jafari, S.M.; Karajizadeh, M. Offering a model for estimating black globe temperature according to meteorological measurements. *Met. Apps* **2017**, *24*, 303–307. [[CrossRef](#)]
44. Lawrence, M.G. The Relationship between Relative Humidity and the Dewpoint Temperature in Moist Air: A Simple Conversion and Applications. *Bull. Am. Meteorol. Soc.* **2005**, *86*, 225–234. [[CrossRef](#)]
45. Schmeling, L.; Elmamooz, G.; Nicklas, D.; Rauch, E.; Thurner, S. Evaluation of a sensor-based system for monitoring rumination in dairy cows with access to pasture. In Proceedings of the EurAgEng 2021 Conference, New Challaneges for Agricultural Engineering towards a Digital World, Online, 5–8 July 2021; University of Évora: Évora, Portugal, 2021; pp. 154–155.
46. Schmeling, L.; Thurner, S.; Nicklas, D.; Erhard, M.; Rauch, E. Automated detection of grazing behaviour with a collar-based monitoring system. In *Sensing-New Insights into Grassland and Science and Practice, Proceedings of the 21st Symposium of the European Grassland Federation, 21st Symposium of the European Grassland Federation, Online, 17–19 May 2021*; Astor, T., Dzene, I., Eds.; EGF: Witzenhausen, Germany, 2021; pp. 193–195. ISBN 978-3-00-068789-1.
47. German Federal Ministry of Food and Agriculture. Verordnung zur Fortentwicklung des Rohmilchgüterrechts: RohmilchGütV. Available online: [https://www.bgbl.de/xaver/bgbl/text.xav?SID=&tf=xaver.component.Text\\_0&toctf=&qmf=&hlf=xaver.component.Hitlist\\_0&bk=bgbl&start=%2F%2F%5B%40node\\_id%3D%27817545%27%5D&skin=pdf&tlevel=-2&nohist=1](https://www.bgbl.de/xaver/bgbl/text.xav?SID=&tf=xaver.component.Text_0&toctf=&qmf=&hlf=xaver.component.Hitlist_0&bk=bgbl&start=%2F%2F%5B%40node_id%3D%27817545%27%5D&skin=pdf&tlevel=-2&nohist=1) (accessed on 8 September 2021).
48. Abeni, F.; Calamari, L.; Stefanini, L. Metabolic conditions of lactating Friesian cows during the hot season in the Po valley. 1. Blood indicators of heat stress. *Int. J. Biometeorol.* **2007**, *52*, 87–96. [[CrossRef](#)]

49. Pesenhofer, G.; Palme, R.; Pesenhofer, R.M.; Kofler, J. Comparison of two methods of fixation during functional claw trimming-walk-in crush versus tilt table-in dairy cows using faecal cortisol metabolite concentrations and daily milk yield as parameters. *Wien. Tierärztliche Wochenschrift* **2006**, *93*, 288–294.
50. Palme, R.; Robia, C.; Messmann, S.; Hofer, J.; Möstl, E. Measurement of faecal cortisol metabolites in ruminants: A non-invasive parameter of adrenocortical function. *Wien. Tierärztliche Wochenschrift* **1999**, *86*, 237–241.
51. Morrow, C.J.; Kolver, E.S.; Verkerk, G.A.; Matthews, L.R. Fecal glucocorticoid metabolites as a measure of adrenal activity in dairy cattle. *Gen. Comp. Endocrinol.* **2002**, *126*, 229–241. [[CrossRef](#)] [[PubMed](#)]
52. Geischeder, S. Auswirkungen von Hitzestress auf Milchkühe der Rasse Fleckvieh unter Bayerischen Klimabedingungen und Einfluss Einer Unterstützungs Lüftung Durch Ventilatoren. Ph.D. Thesis, Ludwig-Maximilians-Universität München, München, Germany, 2017.
53. Palme, R.; Möstl, E. Measurement of cortisol metabolites in faeces of sheep as a parameter of cortisol concentration in blood. In Proceedings of the 1st International Symposium on Physiology and Ethology of Wild and Zoo Animals, 1st International Symposium on Physiology and Ethology of Wild and Zoo Animals, Berlin, Germany, 18–21 September 1996; Deutsche Gesellschaft Für Säugetierkunde EV Berlin, European Association of Zoos and Aquaria, Ed.; Gustav Fischer Verlag: Berlin, Germany, 1997; pp. 192–197.
54. Elischer, M.F.; Arceo, M.E.; Karcher, E.L.; Siegford, J.M. Validating the accuracy of activity and rumination monitor data from dairy cows housed in a pasture-based automatic milking system. *J. Dairy Sci.* **2013**, *96*, 6412–6422. [[CrossRef](#)]
55. Giraudoux, P. *Pgirmess: Spatial Analysis and Data Mining for Field Ecologists: R Package Version 1.7.0*. 2021. Available online: <https://CRAN.R-project.org/package=pgirmess> (accessed on 8 September 2021).
56. Signorell, A.; Aho, K.; Alfons, A.; Anderegg, N.; Aragon, T.; Arachchige, C.; Arppe, A.; Baddeley, A.; Barton, K.; Bolker, B.; et al. DescTools: Tools for Descriptive Statistics: R Package Version 0.99.42. 2021. Available online: <https://cran.r-project.org/package=DescTools> (accessed on 8 September 2021).
57. Crump, A.; Jenkins, K.; Bethell, E.J.; Ferris, C.P.; Arnott, G. Pasture Access Affects Behavioral Indicators of Wellbeing in Dairy Cows. *Animals* **2019**, *9*, 902. [[CrossRef](#)]
58. Fleiss, J.L. Measuring nominal scale agreement among many raters. *Psychol. Bull.* **1971**, *76*, 378–382. [[CrossRef](#)]
59. Landis, J.R.; Koch, G.G. The Measurement of Observer Agreement for Categorical Data. *Biometrics* **1977**, *33*, 159. [[CrossRef](#)]
60. Schmeling, L.; Elmamooz, G.; Hoang, P.T.; Kozar, A.; Nicklas, D.; Sünkel, M.; Thurner, S.; Rauch, E. Training and Validating a Machine Learning Model for the Sensor-based Monitoring of Lying Behavior in Dairy Cows on Pasture and in the Barn. *Animals* **2021**, *11*, 2660. [[CrossRef](#)] [[PubMed](#)]
61. Zimelman, R.B.; Rhoads, R.; Rhoads, M.L.; Duff, G.C.; Baumgard, L.H.; Collier, R.J. A Re-Evaluation of the Impact of Temperature Humidity Index (THI) and Black Globe Humidity Index (BGHI) on Milk Production in High Producing Dairy Cows. In Proceedings of the Southwest Nutrition and Management Conference, Southwest Nutrition and Management Conference, American Registry of Professional Animal Scientists, Tempe, AZ, USA, 26–27 February 2009; Southwest Nutrition Conference: Phoenix, AZ, USA, 2009; pp. 158–168.
62. Dalcin, V.C.; Fischer, V.; Daltro, D.D.S.; Alfonso, E.P.M.; Stumpf, M.T.; Kolling, G.J.; da Silva, M.V.G.B.; McManus, C. Physiological parameters for thermal stress in dairy cattle. *R. Bras. Zootec.* **2016**, *45*, 458–465. [[CrossRef](#)]
63. Kibler, H.H. *Environmental Physiology and Shelter Engineering: LXVII. Thermal Effects of Various Temperature-Humidity Combinations on Holstein Cattle as Measured by Eight Physiological Responses*; Research Bulletin No. 862: Columbia, MO, USA, 1964; Available online: <https://mospace.umsystem.edu/xmlui/handle/10355/58200> (accessed on 8 September 2021).
64. Gorniak, T.; Meyer, U.; Südekum, K.-H.; Dänicke, S. Impact of mild heat stress on dry matter intake, milk yield and milk composition in mid-lactation Holstein dairy cows in a temperate climate. *Arch. Anim. Nutr.* **2014**, *68*, 358–369. [[CrossRef](#)]
65. Gantner, V. The differences in heat stress resistance due to dairy cattle breed. *Mljekarstvo/Dairy* **2017**, *62*, 112–122. [[CrossRef](#)]
66. Collier, R.J.; Baumgard, L.H.; Zimelman, R.B.; Xiao, Y. Heat stress: Physiology of acclimation and adaptation. *Anim. Front.* **2019**, *9*, 12–19. [[CrossRef](#)] [[PubMed](#)]
67. Fisher, A.D.; Roberts, N.; Bluett, S.J.; Verkerk, G.A.; Matthews, L.R. Effects of shade provision on the behaviour, body temperature and milk production of grazing dairy cows during a New Zealand summer. *N. Z. J. Agric. Res.* **2008**, *51*, 99–105. [[CrossRef](#)]
68. Suzuki, T.; Kamiya, Y.; Tanaka, M.; Hattori, I.; Sakaigaichi, T.; Terauchi, T.; Nonaka, I.; Terada, F. Effect of fiber content of roughage on energy cost of eating and rumination in Holstein cows. *Anim. Feed. Sci. Technol.* **2014**, *196*, 42–49. [[CrossRef](#)]
69. Terman, E.; Pastell, M.; Hänninen, L.; Agenäs, S.; Nielsen, P.P. First-night effect on sleep time in dairy cows. *PLoS ONE* **2018**, *13*, e0195593. [[CrossRef](#)]
70. Gregorini, P.; DelaRue, B.; McLeod, K.; Clark, C.; Glassey, C.B.; Jago, J. Rumination behavior of grazing dairy cows in response to restricted time at pasture. *Livest. Sci.* **2012**, *146*, 95–98. [[CrossRef](#)]
71. Flury, R.; Gyax, L. Daily patterns of synchrony in lying and feeding of cows: Quasi-natural state and (anti-) synchrony factors. *Behav. Processes* **2016**, *133*, 56–61. [[CrossRef](#)]

## VII. ERWEITERTE ERGEBNISSE

### 1. Performance der maschinellen Lernmodelle

Für die Evaluation der Modelle stand eine unterschiedliche Menge an Ground Truth Daten zur Verfügung, die sich auf Daten aus dem Stall und auf der Weide verteilte. Tabelle 29 gibt einen Überblick über die genutzte Datenmenge für jedes Modell

**Tabelle 29: Übersicht über die für die Evaluation der Modelle genutzte Datenmenge**

Modell	Für die Evaluation genutzte Datenmenge [h]		
	Gesamt	Weide	Stall
Liegen	476,2	238,7	237,5
Grasen	102,4	102,4	-
Wiederkauen	184,8	120,1	64,7

In Tabelle 30 sind die Performancewerte (Sensitivität, Spezifität und Genauigkeit) der Modelle für die Verhaltensweisen Liegen, Grasens und Wiederkauens aufgeführt. Die Modelle erkannten die Verhaltensweise auf der Weide generell mit einer höheren Genauigkeit als im Stall.

**Tabelle 30: Sensitivität, Spezifität, Genauigkeit der Modelle in der Erkennung der verschiedenen Verhaltensweisen (Liegen, Grasens, Wiederkauens)**

Modell	Lokalisierung	Sensitivität [%]	Spezifität [%]	Genauigkeit [%]	Validierung
Liegen	Gesamt	96	80	87	SCHMELING et al. 2021a
	Weide	94	92	93	
	Stall	97	65	81	
Grasen	Weide	92	93	92	SCHMELING et al. 2021c
Wiederkauen	Gesamt	93	99	97	SCHMELING et al. 2021b
	Weide	92	100	98	
	Stall	95	98	97	

Das Liegen-Modell verwechselte Liegen am häufigsten mit Stehen. Die am häufigsten mit Grasens verwechselte Verhaltensweise war Gehen mit und ohne

Kauen. Das Wiederkauen-Modell verwechselte Wiederkauen am häufigsten mit Liegen ohne Wiederkauen. Das Liegen-Modell erkannte einzelne Liegeperioden mit einer Genauigkeit von 93 % auf der Weide und 96 % im Stall. Nicht-Liegeperioden wurden mit einer Genauigkeit von 89 % auf der Weide und 76 % im Stall erkannt. Auch das Wiederkauen-Modell konnte einzelne Wiederkauperioden erkennen und erzielte dabei eine Genauigkeit von 97 %.

## **2. Verhalten der Tiere an Tagen der Datenerhebung für die Modellentwicklung**

Die mittlere Dauer der Verhaltensweisen auf den verschiedenen Betrieben in den einzelnen Durchgängen ist in Tabelle 31 aufgeführt. Auf Betrieb 2 wurde nur Durchgang 2 ausgewertet. Da bei Durchgang 1 auf Betrieb 3 lediglich drei Monitoringsysteme über 24 h Daten erfassten, wurde dieser Durchgang beim Vergleich der Verhaltensdauern nicht berücksichtigt. Das Liegeverhalten unterschied sich zwischen den beiden Durchgängen auf Betrieb 1 und Betrieb 2 nicht. Auf Betrieb 3 lag die Liegezeit signifikant höher ( $p = 0,02$ ). Nachts verbrachten die Tiere bei allen Durchgängen mehr Zeit mit Liegen als tagsüber, bei Durchgang 2 auf Betrieb 1 war der Unterschied signifikant ( $p = 0,02$ ). Die Wiederkaudauer unterschied sich zwischen den Durchgängen nicht signifikant. Im Vergleich zwischen Tag und Nacht kauten die Tiere nachts mehr wieder. Signifikant war der Unterschied zwischen Tag und Nacht bei Durchgang 2 auf Betrieb 1 ( $p = 0,02$ ) und auf Betrieb 2 ( $p < 0,01$ ). Die tägliche Grasedauer lag in Durchgang 2 auf Betrieb 1 signifikant niedriger als auf Betrieb 2 ( $p = 0,01$ ). Zwischen Durchgang 1 und 2 auf Betrieb 1 und zwischen Durchgang 1 auf Betrieb 1 und Betrieb 2 lag kein signifikanter Unterschied. Auf Betrieb 1 verbrachten die Tiere tagsüber mehr Zeit mit Grasen als nachts. Signifikant war der Unterschied nur bei Durchgang 2 ( $p = 0,02$ ). Auf Betrieb 2 grasten die Tiere nachts signifikant mehr ( $p < 0,01$ ).

**Tabelle 31: Mittlere Liege-, Wiederkau- und Grasedauer ( $\pm$  Standardabweichung) auf den verschiedenen Betrieben über 24 h, tagsüber**

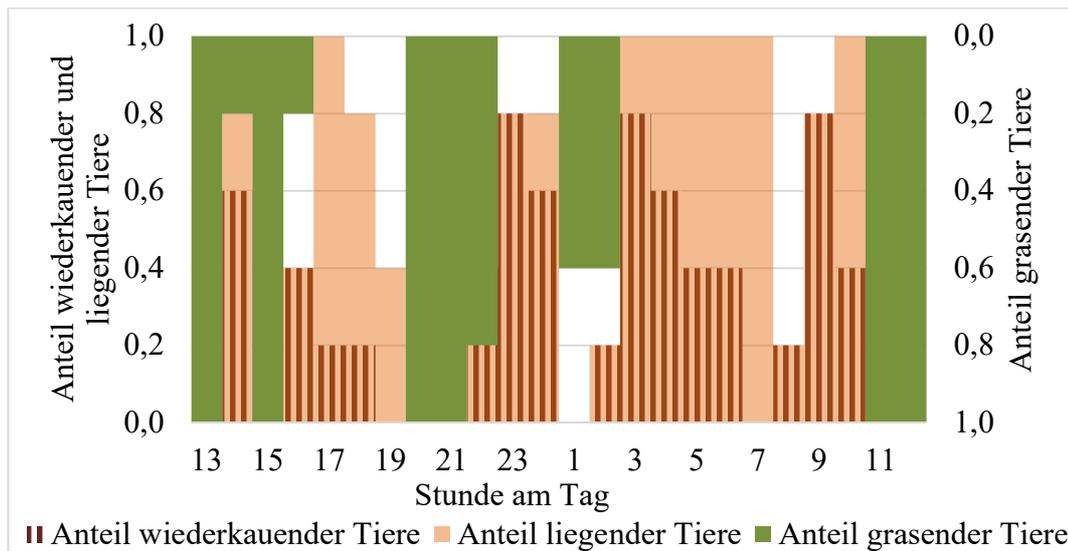
**(06:00 bis 18:00 Uhr) und nachts (18:00 bis 06:00 Uhr)**

Betrieb	1		2	3
Durchgang	1	2	2 <sup>1</sup>	2 <sup>2</sup>
Tierzahl	5	7	9	8
Liegen [h/24h]	11,9 <sup>a</sup> (±0,8)	11,7 <sup>a</sup> (± 0,8)	11,8 <sup>a</sup> (±1,2)	14,7 <sup>b</sup> (±3,0)
Liegen tagsüber [h/12h]	5,4 (±0,6)	4,1 (±0,8)	5,8 (±0,9)	7,1 (±1,7)
Liegen nachts [h/12h]	6,5 (±0,8)	7,6 (± 0,5)	6,0 (±0,4)	7,6 (±1,5)
Wiederkauen [h/24h]	7,4 (±0,9)	7,2 (±1,4)	7,3 (±0,7)	7,8 (±1,6)
Wiederkauen tagsüber [h/12h]	3,2 (±0,2)	2,8 (±1,0)	3,3 (±0,5)	3,7 (±0,7)
Wiederkauen nachts [h/12h]	4,2 (±0,9)	4,4 (± 0,6)	4,0 (±0,4)	4,1 (±1,0)
Grasen [h/24h]	7,4 <sup>ab</sup> (±0,7)	6,9 <sup>a</sup> (±0,9)	8,1 <sup>b</sup> (±0,9)	- <sup>3</sup>
Grasen tagsüber [h/12h]	3,9 (±0,5)	4,4 (±0,5)	3,3 (±0,5)	- <sup>3</sup>
Grasen nachts [h/12h]	3,5 (±0,3)	2,5 (± 0,6)	4,8 (±0,6)	- <sup>3</sup>

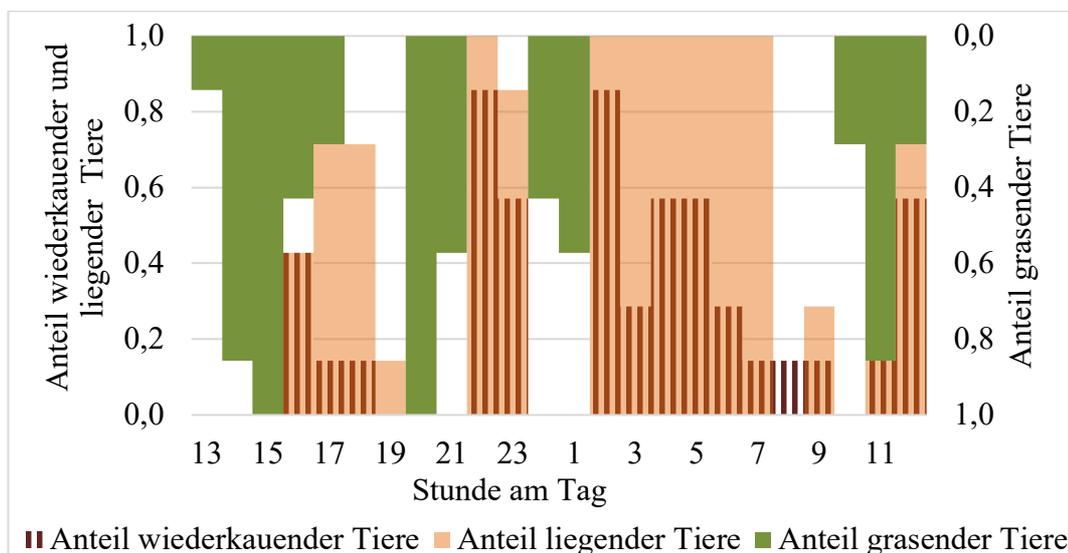
<sup>1</sup>Durchgang 1 wurde auf diesem Betrieb nicht ausgewertet, <sup>2</sup>in Durchgang 1 waren auf diesem Betrieb lediglich Daten von drei Tieren verfügbar, weshalb dieser nicht in den Vergleich einbezogen wurde, <sup>3</sup>die Beobachtungen fanden auf diesem Betrieb im Stall statt, das Graseverhalten wurde hier nicht erfasst; <sup>a,b</sup>unterschiedliche Buchstaben repräsentieren signifikante Unterschiede (p<0,05) zwischen den Spalten

Der Tagesverlauf der verschiedenen Verhaltensweisen für die einzelnen Betriebe und Durchgänge ist in Abbildung 8 bis Abbildung 11 dargestellt. Das Graseverhalten wurde auf Betrieb 1 in Durchgang 1 in vier Peaks gezeigt, wobei die zwei größeren um die Mittagszeit und abends gezeigt wurden. In Durchgang 2 gab es ebenfalls vier Peaks, wobei der größte am Nachmittag auftrat. Auf Betrieb 2 wurde das Graseverhalten in vier kleineren und einem großen Peak gezeigt. Letzterer trat am Abend auf. Das Liegeverhalten teilte sich in Durchgang 1 auf Betrieb 1 auf drei kleinere und einen großen, zweigeteilten Peak auf, der von

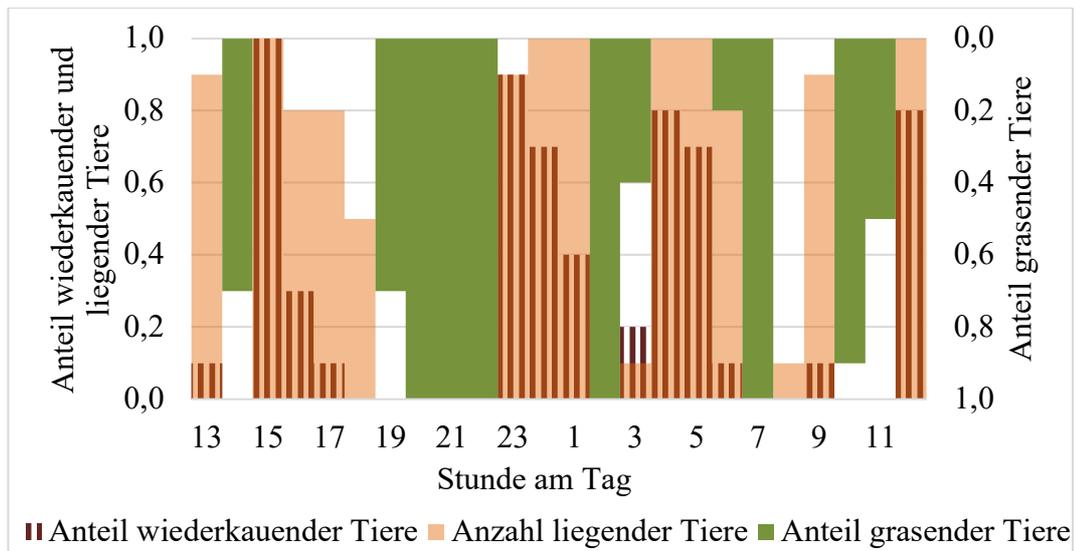
Mitternacht bis morgens andauerte. Die gleiche Verteilung zeigte das Liegeverhalten auch bei Durchgang 2. Auf Betrieb 2 verteilen sich vier ähnlich große Peaks gleichmäßig über die 24 h. Auf Betrieb 3 sind die Peaks des Liegeverhaltens weniger klar getrennt. Die meisten Tiere lagen Nachmittags, spät abends, sowie von Mitternacht bis zum Morgen. Die Peaks des Wiederkauverhaltens entsprechen denen des Liegeverhaltens.



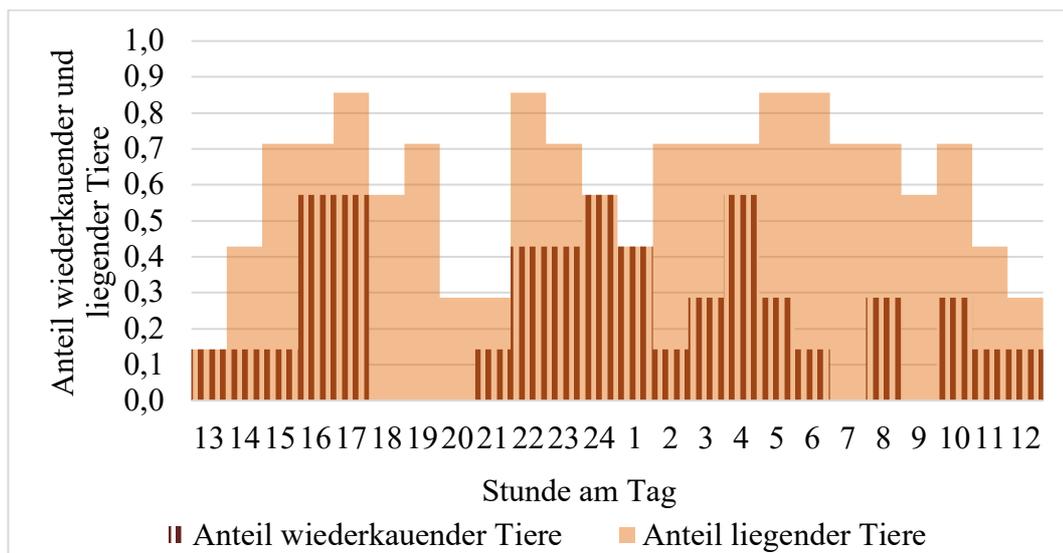
**Abbildung 8: Verlauf des Wiederkau-, Liege- und Graseverhaltens der Tiere bei Durchgang 1 auf Betrieb 1 innerhalb von 24 h**



**Abbildung 9: Verlauf des Wiederkau-, Liege- und Graseverhaltens der Tiere bei Durchgang 2 auf Betrieb 1 innerhalb von 24 h**



**Abbildung 10: Verlauf des Wiederkau-, Liege- und Graseverhaltens der Tiere auf Betrieb 2 innerhalb von 24 h**



**Abbildung 11: Verlauf des Wiederkau- und Liegeverhaltens der Tiere bei auf Betrieb 3 innerhalb von 24 h**

Die Synchronitäts( $\kappa_F$ )-Werte der Tiere in den einzelnen Durchgängen für die verschiedenen Verhaltensweisen sind in Tabelle 32 aufgeführt. Insgesamt wurden Grasen und Liegen mit einer höheren Synchronität gezeigt als Wiederkauen. Auf Betrieb 1 in Durchgang 2 und auf Betrieb 2 wies das Graseverhalten die höchste Synchronität auf, während auf Betrieb 1 in Durchgang 2 Liegeverhalten mit der höchsten Synchronität gezeigt wurde. Auf Betrieb 2 war die Synchronität generell höher als auf Betrieb 1. Auf Betrieb 3 war sie mit einem  $\kappa_F < 0,1$  für Liegen und Wiederkauen am niedrigsten.

**Tabelle 32: Synchronitäts( $\kappa_F$ )-Werte für das Liege-, Wiederkau- und Graseverhalten für die verschiedenen Durchgänge**

Betrieb	1		2	3
Durchgang	1	2	2 <sup>1</sup>	2 <sup>2</sup>
Liegen	0,63	0,72	0,78	0,04
Wiederkauen	0,23	0,31	0,57	0,08
Grasen	0,78	0,53	0,76	- <sup>3</sup>

<sup>1</sup>Durchgang 1 wurde auf diesem Betrieb nicht ausgewertet, <sup>2</sup>in Durchgang 1 waren auf diesem Betrieb lediglich Daten von drei Tieren verfügbar, weshalb dieser nicht in den Vergleich einbezogen wurde, <sup>3</sup>die Beobachtungen fanden auf diesem Betrieb im Stall statt, das Graseverhalten wurde hier nicht erfasst

### 3. Ergebnisse der Einflussfaktoren und Zusammenhang mit dem Tierverhalten

Tabelle 33 gibt eine Übersicht über die im Mittel erfassten tierbezogenen Daten aller in die Untersuchung eingeschlossener Tiere pro Betrieb und Durchgang. Während die Beobachtungen auf Betrieb 3 zu Beginn der Laktation stattfanden, waren die Tiere auf Betrieb 1 und 2 im späten Abschnitt der Laktation. Entsprechend war hier auch die Milchleistung niedriger. Da die Witterungsdaten nur tagsüber, also in dem Zeitraum, in dem die Verhaltensbeobachtungen stattfanden, erfasst wurden, wurden diese nicht weiter evaluiert.

**Tabelle 33: Parität, Tage in Milch, Body Condition Score (BCS), Milchleistung, Milchfett- und Milchproteingehalt der in die Durchgänge auf den verschiedenen Betrieben eingeschlossenen Milchkühe (Mittelwert  $\pm$  Standardabweichung)**

Betrieb	1		2		3	
Durchgang	1	2	1	2	1	2
Tierzahl	7	8	12	11	9	11
Parität	3,4 $\pm$ 0,5	3,5 $\pm$ 1,2	4,0 $\pm$ 0,9	4,0 $\pm$ 0,9	3,8 $\pm$ 1,8	3,8 $\pm$ 1,4
Tage in Milch	233 $\pm$ 30	285 $\pm$ 40	242 $\pm$ 15	273 $\pm$ 16	66 $\pm$ 22	103 $\pm$ 40
BCS	3,1 $\pm$ 0,4	3,1 $\pm$ 0,4	3,2 $\pm$ 0,7	3,0 $\pm$ 0,6	3,6 $\pm$ 0,4	3,8 $\pm$ 0,4

Milchleistung [kg]	23,2 ± 2,4	- <sup>1</sup>	20,7 ± 2,4	19,1 ± 2,7	38,3 ± 3,4	34,7 ± 4,8
Milchfettgehalt [%]	3,5 ± 0,3	- <sup>1</sup>	3,8 ± 0,1	4,1 ± 0,4	3,9 ± 0,4	4,1 ± 0,5
Milchprotein-gehalt [%]	3,6 ± 0,2	- <sup>1</sup>	3,7 ± 0,1	4,9 ± 0,2	3,6 ± 0,2	3,6 ± 0,3

<sup>1</sup>aufgrund technischer Schwierigkeiten wurde bei diesem Durchgang die Milchleistung nicht erfasst und keine Milchproben zur Analyse entnommen

Bei einem Teil der Tiere wurde das Verhalten ausgewertet. Parität, Tage in Milch, BCS, Milchleistung, sowie Milchfett- und Milchproteingehalt dieser Tiere sind in Tabelle 34 aufgeführt. Zwischen der Parität und der Grasedauer bestand ein starker positiver Zusammenhang ( $\varphi = 0,51$ ;  $p = 0,01$ ). Mit der Liege- und der Wiederkaudauer korrelierte die Parität nicht signifikant. Die Tage in Milch korrelierten stark negativ mit der Liegedauer ( $\varphi = -0,66$ ;  $p < 0,01$ ) und moderat mit der Wiederkaudauer ( $\varphi = -0,43$ ;  $p = 0,02$ ). Zwischen der Milchleistung und der Liegedauer gab es einen starken positiven Zusammenhang ( $\varphi = 0,58$ ;  $p < 0,05$ ). Mit der Wiederkaudauer korrelierte die Milchleistung moderat ( $\varphi = 0,44$ ;  $p = 0,04$ ). Zwischen Milchleistung und Grasedauer bestand kein Zusammenhang. Der BCS korrelierte mit keiner der Verhaltensdauern.

**Tabelle 34: Parität, Tage in Milch, Body Condition Score (BCS), Milchleistung, Milchfett- und Milchproteingehalt der in die Durchgänge auf den verschiedenen Betrieben eingeschlossenen Milchkühe (Mittelwert ± Standardabweichung)**

Betrieb	1		2	3
Durchgang	1	2	2 <sup>1</sup>	2 <sup>2</sup>
Tierzahl	7	7	10	7
Parität	3,4 ± 0,5	3,6 ± 1,3	3,9 ± 0,9	4,3 ± 1,0
Tage in Milch	227 ± 28	283 ± 43	273 ± 15	97 ± 48
BCS	3,2 ± 0,5	3,2 ± 0,4	3,0 ± 0,5	4 ± 0,5
Milchleistung [kg]	24,0 ± 1,4	- <sup>3</sup>	19,2 ± 2,7	35,5 ± 5,3
Milchfettgehalt [%]	3,5 ± 0,2	- <sup>3</sup>	4,1 ± 0,4	3,9 ± 0,3
Milchprotein-gehalt [%]	3,6 ± 0,2	- <sup>3</sup>	4,0 ± 0,2	3,5 ± 0,3

<sup>1</sup>Durchgang 1 wurde auf diesem Betrieb nicht ausgewertet, <sup>2</sup>in Durchgang 1 waren auf diesem Betrieb lediglich Daten von drei Tieren verfügbar, weshalb dieser nicht in den Vergleich einbezogen wurde, <sup>3</sup>die Beobachtungen fanden auf diesem Betrieb im Stall statt, das Graseverhalten wurde hier nicht erfasst

## VIII. ERWEITERTE DISKUSSION

### 1. Performance der maschinellen Lernmodelle

Das Liegen-Modell erzielte auf der Weide ähnliche bzw. höhere Performannewerte wie ein von MOLFINO et al. (2017) auf der Weide evaluiertes Halsband- und Accelerometer-basiertes Monitoringsystem. Im Gegensatz zu der von uns gewählten Definition, fassten MOLFINO et al. (2017) jedoch Liegen und Stehen zusammen. Im Stall war die Performance des Liegen-Modells niedriger. Im Vergleich mit dem von BENAÏSSA et al. (2019) im Stall evaluierten Halsband-basierten System erkannte das Liegen-Modell das Liegeverhalten weniger gut. Die schlechtere Performance im Stall ist bei unserem Modell auf die häufige Verwechslung mit Stehen zurückzuführen (SCHMELING et al. 2021a). Auch das von MARTISKAINEN et al. (2009) evaluierte System verwechselte Liegen am häufigsten mit Stehen und erzielte eine ähnliche Performance wie unser Modell. Eine mögliche Erklärung für die Verwechslung ist die ruhige Kopf- und Halshaltung im Liegen und im Stehen, was zu ähnlichen Mustern in den Sensordaten führt (MARTISKAINEN et al. 2009). Die Wahl eines orientierungs-unabhängigen Featuresets hat zwar den Vorteil, dass kleine Lageveränderungen des Systems am Hals der Tiere keinen Einfluss haben (KAMMINGA et al. 2018), könnte aber dazu führen, dass die unterschiedliche Kopfhöhe, im Liegen und Stehen nicht erkannt wird. Eine Verbesserung der Erkennung im Stall könnte über die Ergänzung eines Modells zur Vorhersage von Aufsteh- und Ablegevorgängen erreicht werden (VÁZQUEZ DIOSDADO et al. 2015). Einzelne Liegeperioden wurden vom Modell mit einer hohen Genauigkeit (96 % auf der Weide, 93 % im Stall) erkannt, die mit der von KOK et al. (2015) für den Stall und der von MCGOWAN et al. (2007) für die Weide, jeweils für Gliedmaßen-basierte Systeme, ermittelten Genauigkeiten in der Erkennung einzelner Liegeperioden übereinstimmte.

Das Grasen-Modell erkannte das Graseverhalten mit einer hohen Genauigkeit, die etwas über der von NIELSEN (2013) für ein Halfter-basiertes und von ANDRIAMANDROSO et al. (2017) für ein Halsband-basiertes System lag. MOLFINO et al. (2017) ermittelten für ein Halsband-basiertes System eine höhere Genauigkeit, die Evaluation erfolgte hier aber auf Minutenbasis. Zudem beinhaltete hier die

Definition für das Graseverhalten das Vorwärtsgehen mit Kauen, was bei uns am häufigsten mit Grasem verwechselt wurde.

Auch die Performance des Wiederkauen-Modells war vergleichbar mit der Genauigkeit zuvor evaluierter Systeme. Im Stall ermittelten HAMILTON et al. (2019) eine höhere Sensitivität, aber niedrigere Spezifität für die Erkennung des Wiederkauverhaltens mit einem Pansenbolus. Auf der Weide erkannte ein von SMITH et al. (2016) evaluiertes Halsband-basiertes System Wiederkauen mit einer geringeren Sensitivität. ANDRIAMANDROSO et al. (2017) ermittelten eine ähnliche Spezifität und Genauigkeit, aber eine deutlich niedrigere Sensitivität für ein Halsband-basiertes System auf der Weide.

Insgesamt war die Sensitivität, Spezifität und Genauigkeit der maschinellen Lernmodelle für die Erkennung des Liege-, Wiederkau- und Graseverhaltens vergleichbar mit der in der Vergangenheit evaluierter Systeme (STYGAR et al. 2021). Der größte Unterschied der von uns entwickelten Modelle bestand darin, dass die Evaluation auf Daten sowohl von der Weide als auch aus dem Stall basierte und die Erkennung der verschiedenen Verhaltensweisen in beiden Lokalisationen zuverlässig war. ELISCHER et al. (2013) evaluierten beispielsweise ein Halsband-basiertes System für die Erkennung von Gehen, Stehen, Liegen und Wiederkauen auf einem gemischten Datensatz aus Stall und Weide und ermittelten nur für das Liegen eine akzeptable Genauigkeit. Zu einem ähnlichen Ergebnis kamen AMBRIZ-VILCHIS et al. (2015), die ein Halsband-basiertes System sowohl im Stall als auch auf der Weide auf die Erkennung des Wiederkauverhaltens hin validierten. Während die Übereinstimmung für die ermittelte Wiederkauzeit zwischen System und Ground Truth im Stall hoch war, erkannte das System das Wiederkauverhalten auf der Weide nicht zuverlässig. Für einen Wechsel oder eine Kombination der Haltungsbedingungen sind die meisten verfügbaren Systeme nicht geeignet bzw. bedarf es einer Anpassung der ihrer Modelle (STYGAR et al. 2021). Die von uns entwickelten Modelle erwiesen sich hingegen auf der Weide und im Stall als genau.

Eine zuverlässige Klassifizierung der Verhaltensweisen ist die Grundlage für die Erfassung von Verhaltensdauern und Änderungen dieser. Dies wiederum repräsentiert die Basis für den Einsatz von Monitoringsystemen zur automatisierten Erkennung der Brunst, der Abkalbung, von Erkrankungen bzw. Belastungssituationen.

## 2. Verhalten der Tiere an Tagen der Datenerhebung für die Modellentwicklung

Bei der Betrachtung der Verhaltensdauern ergab sich ein signifikanter Unterschied zwischen der Liegedauer auf Betrieb 1 und 2, wo die Tiere sich überwiegend auf der Weide aufhielten und der Liegedauer auf Betrieb 3, auf dem die Tiere zur Beobachtungszeit ausschließlich im Stall gehalten wurden. Eine längere Liegedauer im Stall im Vergleich zur Weide wurde auch in anderen Untersuchungen beobachtet (LEGRAND et al. 2009; DOHME-MEIER et al. 2014; BLACK und KRAWCZEL 2016). OLMOS et al. (2009) ermittelten hingegen eine längere Liegezeit auf der Weide als im Stall. Den Tieren standen in dieser Studie innen allerdings keine Liegeboxen zur Verfügung. Die auf der Weide erfasste Liegezeit von 11,7 bis 11,8 h liegt etwas über der von BEGGS et al. (2018) und SEPÚLVEDA-VARAS et al. (2018) berichteten mittleren Liegezeit von 9,5 bis 10,3 h. In der Untersuchung von BEGGS et al. (2018) nahm die Melkzeit einen deutlich größeren Anteil des Tages ein, was eine kürzere Liegedauer verursacht haben könnte. SEPÚLVEDA-VARAS et al. (2018) führten ihre Untersuchung an Holsteinkühen in der Mitte der Laktation durch. Die höhere Milchleistung dieser Rasse in der Phase der Laktation könnten Gründe für die kürzere Liegedauer sein (THORUP et al. 2015). Die Liegezeit im Stall lag mit 14,7 h im Mittel deutlich über der in anderen Studien ermittelten Liegezeit im Stall von 10,5 bis 11 h (ITO et al. 2010; TOLKAMP et al. 2010). Hierbei ist zu bedenken, dass das Liegen-Modell im Stall eine niedrigere Genauigkeit aufwies als auf der Weide (SCHMELING et al. 2021a). Die häufige Verwechslung von Stehen und Liegen kann hier zu der hohen Liegedauer beigetragen haben. Sowohl im Stall als auch auf der Weide verbrachten die Tiere nachts mehr Zeit mit Liegen. Diese Beobachtung ist im Einklang mit vorherigen Untersuchungen des Liegeverhaltens im Stall (WINCKLER et al. 2015) und auf der Weide (HERBUT und ANGRECKA 2018).

Das Wiederkauverhalten unterschied sich zwischen Weide und Stall nicht. Im Gegensatz dazu beobachteten DOHME-MEIER et al. (2014) auf der Weide eine niedrigere Wiederkaudauer als im Stall. Nachts wurde mehr Wiederkauen gezeigt als tagsüber. Auch TERNMAN et al. (2018) beobachteten nachts mehr Wiederkauen. Die erfasste Wiederkaudauer von 7,2 bis 7,8 h ist im Einklang mit der in anderen Untersuchungen beobachteten Wiederkaudauer (PRENDIVILLE et al. 2010; TERNMAN et al. 2018; WEIGELE et al. 2018).

Die tägliche Grasedauer lag auf Betrieb 2 signifikant höher als in Durchgang 2 auf Betrieb 1. Die Tiere waren auf Betrieb 1 bei diesem Durchgang geringgradig später in der Laktation als auf Betrieb 2. Ein Vergleich der Milchleistung ist hier leider nicht möglich, dennoch könnte eine höhere Milchleistung einen höheren Futterbedarf (FREGONESI und LEAVER 2001) und damit eine höhere Grasezeit bedingen. Die mittlere Grasezeit von 6,9 bis 8,1 h lag etwas unter der in anderen Untersuchungen beobachteten täglichen Grasedauer von 8,3 bis 11,0 h (PÉREZ-RAMÍREZ et al. 2009; PRENDIVILLE et al. 2010; SHEAHAN et al. 2013). Diese Untersuchungen wurden an Holsteinkühen durchgeführt, die aufgrund ihrer höheren Milchleistung eine höhere Futteraufnahme aufweisen. Auf Betrieb 2 grasten die Tiere nachts mehr, während auf Betrieb 1 mehr Grasezeit tagsüber gezeigt wurde. PÉREZ-RAMÍREZ et al. (2009) und TUCKER et al. (2007a) beobachteten ebenfalls mehr Grasens tagsüber als nachts. Auf Betrieb 2 war im Vergleich zu Betrieb 1 der Unterschied zwischen der Liegezeit am Tag und in der Nacht geringer. Mehr Liegezeit fand hier auch tagsüber statt, was zu einer Reduktion bzw. Umverteilung des Graseverhaltens geführt haben kann.

Die Synchronität des Liege- und Wiederkauverhaltens lag auf der Weide deutlich über der im Stall. FLURY und GYGAX (2016) beobachteten ebenfalls eine erhöhte Synchronität des Liegeverhaltens bei Milchkühen, die auf der Weide gehalten werden im Vergleich zu Tieren im Stall. Auch die hohe beobachtete Synchronität des Graseverhaltens auf der Weide ist im Einklang mit den Beobachtungen von FLURY und GYGAX (2016).

Entgegen der aus vorherigen Studien erwarteten Zunahme der Liegedauer mit Fortschreiten der Laktation THORUP et al. (2015) und KING et al. (2017a), zeigten die Tage in Milch eine negative Korrelation mit der Liegedauer. Hierbei ist zu beachten, dass sich die Tiere auf Betrieb 3 am Beginn der Laktation befanden, während die Beobachtungen auf Betrieb 1 und 2 gegen Ende der Laktation stattfanden. Auf Betrieb 3 wurde, vermutlich bedingt durch die niedrigere Performance des Liegen-Modells und die häufige Verwechslung mit Stehen, eine deutlich höhere Liegezeit erfasst, was die Ursache für die negative Korrelation sein könnte. Auch die Wiederkaudauer korrelierte negativ mit den Tagen in Milch, was hingegen im Einklang mit den Beobachtungen von KING et al. (2017a) und MÜSCHNER-SIEMENS et al. (2020) ist.

Insgesamt konnten mit dem Einsatz des Monitoringsystems und der Anwendung der Modelle auf die damit erfassten Daten einige Informationen zum Liege-, Wiederkau- und Graseverhalten von Fleckviehkühen gewonnen werden. Die ermittelte Liegedauer im Stall ist aufgrund der niedrigen Genauigkeit des Modells, die eine häufige Verwechslung mit der Verhaltensweise Stehen bedingt, nur eingeschränkt interpretierbar (SCHMELING et al. 2021a). Die beobachteten Unterschiede zwischen Stall und Weide stimmen mit den Ergebnissen vorheriger Studien überein. Zum Einfluss der verschiedenen tierbezogenen Parameter konnte ein erster Eindruck gewonnen werden, für fundiertere Aussagen sind aber mehr Daten nötig.

### **3. Einsatz des Monitoringsystems für die Untersuchung einer beginnenden Hitzebelastung bei Fleckviehkühen**

Bisher durchgeführte Untersuchungen zur Hitzebelastungen bei Milchkühen wurden vor allem mit Kühen der Rasse Holstein durchgeführt. Bei Untersuchungen des Tierverhaltens, wurden Verhaltensweisen auf der Weide nur selten betrachtet (GALÁN et al. 2018). Im Gegensatz dazu lag der Fokus unserer Untersuchung auf der Rasse Fleckvieh. Zudem wurden die Untersuchungen auf der Weide durchgeführt.

Die Modelle für die Verhaltensweisen Grasens und Wiederkauens wiesen eine hohe Performance sowohl im Stall als auch auf der Weide auf (SCHMELING et al. 2021c; SCHMELING et al. 2021b), sodass die in den beiden Untersuchungsdurchgängen zur beginnenden Hitzebelastung erfassten Dauern dieser beiden Verhaltensweisen verlässlich sind. Im Einklang mit den Ergebnissen von TUCKER et al. (2008) beobachteten wir eine Reduktion der Grasezeit unter Hitzebelastung. FISHER et al. (2010) hingegen stellten keine Veränderung der Grasezeit bei hohen Temperaturen fest. Im Gegensatz zu ARIAS et al. (2021), die eine Reduktion der Wiederkaudauer unter Hitzebelastung feststellten, veränderten die Tiere in unserer Untersuchung die Wiederkaudauer nicht.

Das Modell, das für die automatisierte Erfassung des Liegeverhaltens entwickelt wurde, erkannte das Liegen im Weide zwar mit einer hohen Genauigkeit, wies im Stall aber eine niedrigere Performance auf (SCHMELING et al. 2021a). Insbesondere der negative Zusammenhang zwischen Stehzeit und Genauigkeit stellt ein Problem

dar. Milchkühe erhöhen unter Hitzebelastung ihre Stehzeit (HEINICKE et al. 2018; NORDLUND et al. 2019), was das vorliegende Modell aufgrund der häufigen Verwechslung von Stehen und Liegen möglicherweise nicht erfassen kann. Dennoch erfasste das Monitoringsystem im ersten Durchgang eine Reduktion der Liegezeit unter Hitzebelastung. Eine Abnahme der Liegedauer beobachteten auch HEINICKE et al. (2018) und NORDLUND et al. (2019).

Die begrenzte Batterielaufzeit des Prototyps verhindert einen längerfristigen Einsatz des Systems. Die Entwicklung einer Hitzebelastung hängt von zahlreichen tierindividuellen Faktoren ab (SCHÜTZ et al. 2009; GANTNER et al. 2019; Ji et al. 2020b; MÜSCHNER-SIEMENS et al. 2020). Der Schwellenwert, ab dem ein Tier durch hohe Temperaturen belastet ist, variiert, sodass die Tiere bei steigenden Temperaturen zeitversetzt die dadurch ausgelösten Reaktionen zeigen (GAUGHAN et al. 2008; Ji et al. 2020b). Eine Untersuchung über einen längeren Zeitraum würde dabei demnach mehr Informationen über den tierindividuellen Beginn einer Hitzebelastung liefern. Zudem war die Zahl der funktionstüchtigen Geräte begrenzt ( $n = 5$ ), was zu einer geringen Menge an verfügbaren Verhaltensdaten führte. Dennoch lieferte die Untersuchung erste Hinweise zu hitzebedingten Verhaltensänderungen von Fleckviehkühen auf der Weide.

## IX. FAZIT

Mit dem gewonnen Datensatz konnten zuverlässige maschinelle Lernmodelle für die automatisierte Erfassung des Wiederkau-, Grase- und Liegeverhaltens entwickelt werden. Die Modelle für die Verhaltensweisen Wiederkauen und Grasens erkannten das jeweilige Verhalten sowohl im Stall als auch auf der Weide mit hoher Genauigkeit. Auf der Weide performte das Liegen-Modell gut, während im Stall die häufige Verwechslung mit Stehen die Performance minderte. Eine Verbesserung der Genauigkeit könnte hier über die Ergänzung um ein Modell für das Ablegen und Aufstehen oder eine genauere Betrachtung der Unterschiede in den Sensordaten zwischen Liegen und Stehen erreicht werden. Die Dauer der verschiedenen Verhaltensweisen konnte mit den Modellen erfasst und Unterschiede aufgrund tierbezogener Einflussfaktoren ausgemacht werden. Die Entwicklung von Lernmodellen zur automatisierten Erkennung der verschiedenen Verhaltensweisen und die zuverlässige Erfassung der Verhaltensdauern stellt die Grundlage für die automatisierte Erkennung der Brunst, der Abkalbung, von Gesundheitsstörungen bzw. Belastungssituationen dar.

Die Zuverlässigkeit der Modelle ermöglichte den Einsatz des Monitoringsystems für die automatisierte Erfassung von Verhaltensänderungen bei einer beginnenden Hitzebelastung. Die Untersuchungen lieferten erste Hinweise auf die Verhaltensänderungen, die bei zunehmenden Temperaturen bei Fleckviehkühen auf der Weide auftreten. Für den Einsatz des Monitoringsystems zur automatisierten Erkennung einer Hitzebelastung anhand von Verhaltensparametern muss die Batterielaufzeit der Systeme verlängert werden. Zudem müssen Schwellenwerte ermittelt und in ein Modell integriert werden, das eine Hitzebelastung unter Berücksichtigung tierindividueller Einflussfaktoren auf das Verhalten vorhersagt. In den durchgeführten Untersuchungen konnten dafür grundlegende Informationen gewonnen werden. Eine automatisierte Erkennung einer Hitzebelastung auf Tierebene ermöglicht das frühzeitige Ergreifen von Gegenmaßnahmen, die die Folgen der Belastung verhindern bzw. abmildern können.

## X. ZUSAMMENFASSUNG

Auf dem Markt sind zahlreiche Monitoringsysteme für den Einsatz bei Milchkühen verfügbar, die automatisiert Verhaltensänderungen bzw. den Veränderungen zugrunde liegende Ursachen, wie die Brunst, die Abkalbung oder beginnende Gesundheitsstörungen und Belastungssituationen, erkennen. Die Systeme sind überwiegend entweder im Stall oder auf der Weide einsetzbar, erkennen das Tierverhalten bei einem Wechsel oder einer Kombination der Haltungssysteme jedoch nicht zuverlässig. Ziel der vorliegenden Untersuchung war daher die Entwicklung maschineller Lernmodelle für die automatisierte und zuverlässige Erkennung verschiedener Verhaltensweisen bei Milchkühen auf der Weide und im Stall. Die Modelle sollten im Anschluss eingesetzt werden, um eine beginnende Hitzebelastung bei Fleckviehkühen auf der Weide zu untersuchen. Bisherige Studien zur Hitzebelastung wurden überwiegend an Holsteinkühen durchgeführt und konzentrierten sich auf den Stall. Aus dem Klimawandel, und der damit verbundenen Zunahme von Tagen mit für Milchkühe belastenden Witterungsbedingungen, ergibt sich die hohe Relevanz dieses Themengebietes.

Zur Datenerfassung für die Entwicklung der maschinellen Lernmodelle wurden auf drei Betrieben in je zwei Durchgängen fünf bis zwölf Fleckviehkühe mit dem Prototyp eines Monitoringsystems (Blaupunkt Telematics GmbH, Hildesheim, Deutschland) ausgestattet. Die Tiere wurden dabei im Beobachtungszeitraum entweder ausschließlich auf der Weide (Betrieb 1), sowohl auf der Weide als auch im Stall (Betrieb 2) oder ausschließlich im Stall (Betrieb 3) gehalten. Das am Halsband fixierte System enthielt einen Beschleunigungssensor, ein Magnetometer und ein Gyroskop, die mit einer Frequenz von 10 Hz die Kopf- und Halsbewegungen der Tiere erfassten. Parallel wurden die Tiere mit Kameras (GoPro HERO5; GoPro Inc., San Mateo, USA) beobachtet. Die Videodaten wurden im Anschluss an die Beobachtungen gelabelt, das heißt das Verhalten der Tiere wurde zu jedem Zeitpunkt anhand eines Ethrogramms klassifiziert. Ein Teil der Datensätze, bestehend aus Sensor- und gelabelten Videodaten, diente dem Projektpartner an der Universität Bamberg als Grundlage für die Entwicklung binärer maschineller Lernmodelle für die Unterscheidung von Liegen/Nicht-Liegen, Grasen/Nicht-Grasen und Wiederkauen/Nicht-Wiederkauen. Anhand der

verbleibenden Datensätze wurden die Modelle im Anschluss validiert. Parallel wurden bei den Durchgängen die Parität, der Body Condition Score (BCS), die Milchleistung, der Milchfett- und Milchproteingehalt erfasst, um tierbezogene Einflussfaktoren auf das Verhalten zu ermitteln.

In zwei Durchgängen à fünf bzw. acht Tagen wurde auf Betrieb 3 der Einfluss von Witterungsbedingungen mit zunehmend belastender Intensität auf verschiedene physiologische Parameter, sowie das Verhalten von Fleckviehkühen auf der Weide untersucht. Die Atemfrequenz, die Milchleistung, der Milchfett- und Milchproteingehalt, der somatische Zellgehalt der Milch, sowie der Kotkortisolgehalt wurden erfasst. Das Grase-, Wiederkau- und Liegeverhalten wurde über die Anwendung der maschinellen Lernmodelle, auf die in den beiden Durchgängen mit dem Prototyp des Monitoringsystems aufgezeichneten Sensordaten, erfasst. Die Dauer der verschiedenen Verhaltensweisen sowie ihre Synchronität wurden ermittelt.

Das Liegen-Modell erkannte das Liegeverhalten auf der Weide mit einer Genauigkeit von 93 %, während das Liegeverhalten im Stall mit einer geringeren Genauigkeit von 81 % erkannt wurde. Am häufigsten verwechselte das Modell Stehen mit Liegen. Eine lange Stehdauer kann im Stall eine Erklärung für die verminderte Erkennungsgenauigkeit sein. Einzelne Liegeperioden identifizierte das Modell mit einer Genauigkeit von 93 % auf der Weide und 96 % im Stall. Das Grasen-Modell erzielte eine Genauigkeit von 92 % und verwechselte Grasen am häufigsten mit Gehen mit/ohne Kauen. Mit einer Genauigkeit von 98 % auf der Weide und 97 % im Stall erkannte das Wiederkauen-Modell das Wiederkauverhalten der Tiere. Einzelne Wiederkauperioden wurden mit einer Genauigkeit von 97 % identifiziert. Insgesamt erkannten die Modelle die Verhaltensweisen mit einer hohen Genauigkeit. Das Liegen-Modell könnte im Stall über die Ergänzung um ein Modell für die Identifizierung von Aufsteh- und Ablegevorgängen verbessert werden.

Der Vergleich der Verhaltensdauern zwischen den Betrieben bzw. den verschiedenen Haltungssystemen ergab eine höhere Liegedauer im Stall (Betrieb 3) als auf der Weide (Betrieb 1) bzw. bei der Kombination aus Stall und Weide (Betrieb 2). Nachts lagen die Tiere mehr als tagsüber. Die Wiederkaudauer unterschied sich zwischen den Betrieben nicht. Wiedergekaut wurde ebenfalls

vermehrt nachts. Die Grasedauer war auf Betrieb 2 höher als auf Betrieb 1. Während auf Betrieb 1 tagsüber mehr gegrast wurde als nachts, war es auf Betrieb 2 umgekehrt. Die Synchronität des Wiederkauverhaltens lag auf allen Betrieben unter der des Liege- und Graseverhaltens. Auf Betrieb 2 war die Synchronität am höchsten, gefolgt von Betrieb 1. Eine deutlich niedrigere Synchronität aller Verhaltensweisen wurde auf Betrieb 3 beobachtet. Zwischen der Parität und der Grasedauer wurde ein signifikanter positiver Zusammenhang beobachtet. Die Tage in Milch korrelierten negativ mit der Wiederkaudauer, sowie der Liegezeit. Letzteres war bedingt durch die deutlich höhere erfasste Liegedauer im Stall (Betrieb 3). Die Milchleistung korrelierte signifikant positiv mit der Liege- und Wiederkaudauer.

Während im ersten Durchgang zur Untersuchung der beginnenden Hitzebelastung keine Belastungssituation in Form eines Anstiegs der Kortikosteroidmetaboliten nachgewiesen wurde, stieg der Kortikosteroidmetabolitengehalt in Durchgang 2 an. In beiden Durchgängen reagierten die Tiere auf die zunehmenden Temperaturen mit einer Erhöhung der Atemfrequenz. In Durchgang 1 stieg zudem der somatische Zellgehalt der Milch an. Die Milchleistung sank in Durchgang 2. Die Milchinhaltsstoffe veränderten sich in beiden Durchgängen nicht. Das Verhalten konnte aufgrund technischer Schwierigkeiten nur bei fünf Tieren je Durchgang ausgewertet werden. Während in Durchgang 1 die Grase- und Liegedauer mit steigenden Temperaturen sank, veränderte sie sich in Durchgang 2 nicht. Sowohl der Anteil des Liege-, als auch der des Wiederkauverhaltens, der nachts gezeigt wurde, vergrößerte sich in diesem Durchgang mit zunehmend belastender Intensität der Witterungsbedingungen. Zudem sank die Synchronität des Wiederkauverhaltens.

Insgesamt konnten mit den erfassten Daten verlässliche Modelle für die automatisierte Erkennung des Liege-, Grase- und Wiederkauverhaltens bei Milchkühen im Stall und auf der Weide entwickelt werden. Lediglich das Liegen-Modell sollte für den Einsatz im Stall im Hinblick auf die häufige Verwechslung mit der Verhaltensweise Stehen optimiert werden. Die Untersuchung der physiologischen Reaktionen von Fleckviehkühen auf der Weide auf zunehmende Temperaturen und die damit verbundenen Verhaltensänderungen liefern Informationen, die für die automatisierte Erkennung einer Hitzebelastung mit einem Monitoringsystem genutzt werden können.

## XI. SUMMARY

Numerous monitoring systems for dairy cows which detect changes in behavior and conditions causing behavioral changes, like estrous, calving or emerging health disorders and burdening situations, are available on the market. Most of the systems were developed either for the barn or for pasture and fail to detect the behavior reliably when housing conditions change or if the animals are kept in a combination of barn and pasture. Therefore, the goal of the present study was to develop machine learning models for the automated and reliable detection of different behavioral patterns in dairy cows kept on pasture as well as in the barn. Following, the models were applied to investigate beginning heat load in Simmental cows on pasture. Previous studies on heat load in dairy cows focused on Holstein cows and were mainly conducted in the barn. Due to climate change and the accompanying increase in days with burdening climatic conditions for dairy cows, heat load is a highly relevant research topic.

Data collection for the development of the machine learning models was conducted on three different farms in two rounds and on five to twelve Simmental cows each. The animals were equipped with the prototype of the monitoring system (Blaupunkt Telematics GmbH, Hildesheim, Deutschland). Within the observation period, the animals were either kept on pasture exclusively (farm 1), both on pasture and in the barn (farm 2) or in the barn exclusively (farm 3). The monitoring system, which was attached to the collar, consisted of an accelerometer, a magnetometer and a gyroscope, all collecting data at a frequency of 10 Hz. In parallel, the animals were observed with cameras (GoPro HERO5; GoPro Inc., San Mateo, USA). Following the observations, the video data were labelled, i.e., the behavior of the animals was classified in each second based on an ethogram. A share of the data sets that consisted of sensor and labelled video data, served our project partner at University of Bamberg as a basis for the development of binary machine learning models for distinguishing between Lying/Non-Lying, Grazing/Non-Grazing and Ruminating/Non-Ruminating. Afterwards, the models were validated based on the remaining data sets. Also, data on parity, body condition score (BCS), milk yield, the milk fat and protein content were collected to evaluate animal-based factors influencing the behavior.

In two rounds with five and eight days each, respectively, on farm 3 the influence of climatic conditions with increasing burdening intensity on different physical parameters, as well as the behavior of Simmental cows on pasture was assessed. Respiration rate, milk yield, milk fat and protein content, somatic cell count, as well as fecal cortisol metabolites were measured. The grazing, rumination and lying behavior was recorded by applying the machine learning models on sensor data collected with the prototype of the monitoring system. Duration and synchrony of the different behavioral patterns was determined.

The lying model predicted lying behavior on pasture with an accuracy of 93 %, while in the barn accuracy was lower with 93 %. The behavior confused the most with lying was standing. A higher standing time in the barn is a possible explanation for the lower prediction accuracy. Individual lying bouts were identified by the model with an accuracy of 93 % and 96 % on pasture and in the stable, respectively. The grazing model achieved an accuracy of 92 % and grazing was confused the most with walking with/without chewing. With an accuracy of 98 % on pasture and 97 % in the barn, the model predicted rumination behavior. Individual rumination bouts were identified with an accuracy of 97 %. To summarize, the models predicted the respective behavioral pattern reliably. The lying model could be improved by complementing a model for the identification of lying down and standing up events.

A higher lying time was observed in the barn (farm 3) than on pasture (farm 1) or when a combination of barn and pasture was used (farm 2). Lying time was higher during the night than during the day. Rumination time did not differ between the farms. During the night, rumination time was higher than during the day. Grazing time was higher on farm 2 than on farm 1. While on farm 1, animals grazed more during the day, grazing time was higher during the night on farm 2. In general, synchrony of rumination behavior was lower than synchrony of lying and grazing behavior. On farm 2, synchrony was highest, followed by farm 1. Significantly lower synchrony was observed on farm 3. A significant positive correlation was identified between parity and grazing duration. Days in milk correlated significantly negative with rumination and lying time. The higher lying time with increasing days in milk was probably caused by the higher lying time detected in the barn (farm 3). A significant positive correlation was determined between milk yield and lying and rumination duration.

While in round 1 of the study on beginning heat load the burden of the climatic conditions was not confirmed by elevated fecal cortisol metabolites, the cortisol content increased in round 2. In both rounds, the animals showed a rise in respiration rate with increasing temperatures. In round 1, also somatic cell score increased. Milk yield dropped in round 2. No change in milk fat or protein content was observed in either round. The behavior of only five animals per round could be assessed due to technical problems. While in round 1 the grazing and lying time decreased with increasing temperatures, no change was observed in round 2. The share of lying and rumination behavior that was shown during the night, increased with rising burden intensity of climatic conditions. Additionally, the synchrony of rumination behavior decreased.

To summarize, reliable models for the automated prediction of lying, grazing and rumination behavior in dairy cows in the barn and on pasture were developed. Only the lying model should be improved for the application in the stable, especially regarding the frequent confusion with standing. The investigation of physical and behavioral reactions of Simmental cows provides information that can be used for the automated detection of heat load with a monitoring system.

## XII. LITERATURVERZEICHNIS

- Abdeltalif, A.M.; Alameen, A.O. (2012): Influence of Season and Pregnancy on Thermoregulation and Haematological Profile in Crossbred Dairy Cows in Tropical Environment. *Global Veterinaria* 9(3), S. 334–340, DOI: 10.5829/idosi.gv.2012.9.3.65130
- Abeni, F.; Calamari, L.; Stefanini, L. (2007): Metabolic conditions of lactating Friesian cows during the hot season in the Po valley. 1. Blood indicators of heat stress. *International Journal of Biometeorology* 52(2), S. 87–96, DOI: 10.1007/s00484-007-0098-3
- Abeni, F.; Galli, A. (2017): Monitoring cow activity and rumination time for an early detection of heat stress in dairy cow. *International Journal of Biometeorology* 61(3), S. 417–425, DOI: 10.1007/s00484-016-1222-z
- Abrahamse, P.A.; Vlaeminck, B.; Tamminga, S.; Dijkstra, J. (2008): The effect of silage and concentrate type on intake behavior, rumen function, and milk production in dairy cows in early and late lactation. *Journal of Dairy Science* 91(12), S. 4778–4792, DOI: 10.3168/jds.2008-1350
- Aguiar, L.H. de; Hyde, K.A.; Pedroza, G.H.; Denicol, A.C. (2020): Heat stress impairs in vitro development of preantral follicles of cattle. *Animal Reproduction Science* 213, 106277, DOI: 10.1016/j.anireprosci.2020.106277
- Aikman, P.C.; Reynolds, C.K.; Beever, D.E. (2008): Diet digestibility, rate of passage, and eating and rumination behavior of Jersey and Holstein cows. *Journal of Dairy Science* 91(3), S. 1103–1114, DOI: 10.3168/jds.2007-0724
- Akbar, J.; Yusuf, M.; Toleng, A.L.; Masturi; Sahiruddin (2020): Estrus expression of dairy cows after calving with and without using cooling system. In: IOP Conference Series: Earth and Environmental Science. The 3rd International Conference of Animal Science and Technology, 03.-04.11.2020, Makassar, Indonesia, 12147, DOI: 10.1088/1755-1315/788/1/012147
- Ali, J.; Khan, R.; Ahmad, N.; Maqsood, I. (2012): Random Forest and Decision Trees. *International Journal of Computer Science Issues* 9(5), S. 272–278
- Allain, C. (2016): Technical, economic and sociological impacts of an automated estrus detection system for dairy cows. In: Proceedings of the Conference on Precision Dairy Farming. Conference on Precision Dairy Farming, 21.-23.06.2016, Leeuwarden, The Netherlands: Wageningen Academic Publishers, S. 451–456
- Allen, J.D.; Hall, L.W.; Collier, R.J.; Smith, J.F. (2015): Effect of core body temperature, time of day, and climate conditions on behavioral patterns of lactating dairy cows experiencing mild to moderate heat stress. *Journal of Dairy Science* 98(1), S. 118–127, DOI: 10.3168/jds.2013-7704
- Almeida, P.E.; Weber, P.S.D.; Burton, J.L.; Zanella, A.J. (2008): Depressed DHEA and increased sickness response behaviors in lame dairy cows with inflammatory foot lesions. *Domestic Animal Endocrinology* 34(1), S. 89–99, DOI: 10.1016/j.domaniend.2006.11.006
- Alonso, M.E.; González-Montaña, J.R.; Lomillos, J.M. (2020): Consumers' Concerns and Perceptions of Farm Animal Welfare. *Animals* 10(3), 385, DOI: 10.3390/ani10030385
- Al-Qaisi, M.; Timms, L.L. (2017): Use of an Ear Tag Based Behavioral and Temperature Monitor (Cow Manager™) During a Heat Stress Induction Trial Using Electric Heat Blankets (EHB). (Preliminary Results). *Animal Industry Report*, 663. ASL R3166, Ames, USA. Iowa State University (Hg.),

- DOI: 10.31274/ans\_air-180814-359
- Alsaad, M.; Huber, S.; Beer, G.; Kohler, P.; Schüpbach-Regula, G.; Steiner, A. (2017): Locomotion characteristics of dairy cows walking on pasture and the effect of artificial flooring systems on locomotion comfort. *Journal of Dairy Science* 100(10), S. 8330–8337, DOI: 10.3168/jds.2017-12760
- Alsaad, M.; Niederhauser, J.J.; Beer, G.; Zehner, N.; Schüpbach-Regula, G.; Steiner, A. (2015): Development and validation of a novel pedometer algorithm to quantify extended characteristics of the locomotor behavior of dairy cows. *Journal of Dairy Science* 98(9), S. 6236–6242, DOI: 10.3168/jds.2015-9657
- Ambriz-Vilchis, V.; Jessop, N.S.; Fawcett, R.H.; Shaw, D.J.; Macrae, A.I. (2015): Comparison of rumination activity measured using rumination collars against direct visual observations and analysis of video recordings of dairy cows in commercial farm environments. *Journal of Dairy Science* 98(3), S. 1750–1758, DOI: 10.3168/jds.2014-8565
- Ammer, S.; Lambertz, C.; Gaulty, M. (2016): Is reticular temperature a useful indicator of heat stress in dairy cattle? *Journal of Dairy Science* 99(12), S. 10067–10076, DOI: 10.3168/jds.2016-11282
- Anderson, S.D.; Bradford, B.J.; Harner, J.P.; Tucker, C.B.; Choi, C.Y.; Allen, J.D.; Hall, L.W.; Rungruang, S.; Collier, R.J.; Smith, J.F. (2013): Effects of adjustable and stationary fans with misters on core body temperature and lying behavior of lactating dairy cows in a semiarid climate. *Journal of Dairy Science* 96(7), S. 4738–4750, DOI: 10.3168/jds.2012-6401
- Andersson, M.; Schaar, J.; Wiktorsson, H. (1984): Effects of drinking water flow rates and social rank on performance and drinking behaviour of tied-up dairy cows. *Livestock Production Science* 11(6), S. 599–610, DOI: 10.1016/0301-6226(84)90074-5
- Andriamandroso, A.L.H.; Lebeau, F.; Beckers, Y.; Froidmont, E.; Dufrasne, I.; Heinesch, B.; Dumortier, P.; Blanchy, G.; Blaise, Y.; Bindelle, J. (2017): Development of an open-source algorithm based on inertial measurement units (IMU) of a smartphone to detect cattle grass intake and ruminating behaviors. *Computers and Electronics in Agriculture* 139(2), S. 126–137, DOI: 10.1016/j.compag.2017.05.020
- Angrecka, S.; Herbut, P. (2016): Conditions for cold stress development in dairy cattle kept in free stall barn during severe frosts. *Czech Journal of Animal Science* 60(2), S. 81–87, DOI: 10.17221/7978-CJAS
- Angrecka, S.; Herbut, P.; Nawalany, G.; Sokołowski, P. (2017): The Impact of localization and barn type on insolation of sidewall stalls during summer. *Journal of Ecological Engineering* 18(4), S. 60–66, DOI: 10.12911/22998993/74398
- Antanaitis, R.; Žilaitis, V.; Juozaitiene, V.; Stoškus, R. (2016): Usefulness of Acidity and Temperature of the Rumen and Abomasum in Diagnosing SARA in Dairy Cows after Calving. *Polish Journal of Veterinary Sciences* 19(3), S. 553–558, DOI: 10.1515/pjvs-2016-0069
- Arias, R.A.; Delgado, C.; Keim, J.P.; Gandarillas, M. (2021): Use of the Comprehensive Climate Index to estimate heat stress response of grazing dairy cows in a temperate climate region. *Journal of Dairy Research* 88(2), S. 154–161, DOI: 10.1017/S0022029921000406
- Armstrong, D.V. (1994): Heat Stress Interaction with Shade and Cooling. *Journal of Dairy Science* 77(7), S. 2044–2050, DOI: 10.3168/jds.S0022-0302(94)77149-6
- Atkins, I.K.; Cook, N.B.; Mondaca, M.R.; Choi, C.Y. (2018): Continuous

- Respiration Rate Measurement of Heat-Stressed Dairy Cows and Relation to Environment, Body Temperature, and Lying Time. *Transactions of the ASABE* 61(5), S. 1475–1485, DOI: 10.13031/trans.12451
- Atkins, N.E.; Cianchi, C.; Rutter, S.M.; Williams, S.J.; Gauld, C.; Charlton, G.L.; Sinclair, L.A. (2020): Performance, milk fatty acid composition and behaviour of high-yielding Holstein dairy cows given a limited grazing period. *Grass and Forage Science* 75(2), S. 181–191, DOI: 10.1111/gfs.12471
- Azizi, O.; Kaufmann, O.; Hasselmann, L. (2009): Relationship between feeding behaviour and feed intake of dairy cows depending on their parity and milk yield. *Livestock Science* 122(2-3), S. 156–161, DOI: 10.1016/j.livsci.2008.08.009
- Bach, A.; Valls, N.; Solans, A.; Torrent, T. (2008): Associations between nondietary factors and dairy herd performance. *Journal of Dairy Science* 91(8), S. 3259–3267, DOI: 10.3168/jds.2008-1030
- Bae, D.H.; Welch, J.G.; Gilman, B.E. (1983): Mastication and Rumination in Relation to Body Size of Cattle. *Journal of Dairy Science* 66(10), S. 2137–2141, DOI: 10.3168/jds.S0022-0302(83)82060-8
- Balch, C.C. (1971): Proposal to use time spent chewing as an index of the extent to which diets for ruminants possess the physical property of fibrousness characteristic of roughages. *British Journal of Nutrition* 26(3), S. 383–392, DOI: 10.1079/bjn19710045
- Balch, C.C.; Kelly, A.; Heim, G. (1951): Factors affecting the utilization of food by dairy cows. 4. The action of the reticulo-omasal orifice. *British Journal of Nutrition* 5(2), S. 207–216, DOI: 10.1079/bjn19510026
- Banos, G.; Brotherstone, S.; Coffey, M.P. (2004): Evaluation of Body Condition Score Measured Throughout Lactation as an Indicator of Fertility in Dairy Cattle. *Journal of Dairy Science* 87(8), S. 2669–2676, DOI: 10.3168/jds.S0022-0302(04)73393-7
- Bar, D.; Kaim, M.; Flamenbaum, I.; Hanochi, B.; Toaff-Rosenstein, R.L. (2019): Technical note. Accelerometer-based recording of heavy breathing in lactating and dry cows as an automated measure of heat load. *Journal of Dairy Science* 102(4), S. 3480–3486, DOI: 10.3168/jds.2018-15186
- Bareille, N.; Beaudreau, F.; Billon, S.; Robert, A.; Faverdin, P. (2003): Effects of health disorders on feed intake and milk production in dairy cows. *Livestock Production Science* 83(1), S. 53–62, DOI: 10.1016/S0301-6226(03)00040-X
- Barker, Z.E.; Vázquez Diosdado, J.A.; Codling, E.A.; Bell, N.J.; Hodges, H.R.; Croft, D.P.; Amory, J.R. (2018): Use of novel sensors combining local positioning and acceleration to measure feeding behavior differences associated with lameness in dairy cattle. *Journal of Dairy Science* 101(7), S. 6310–6321, DOI: 10.3168/jds.2016-12172
- Bastian, K.R.; Gebremedhin, K.G.; Scott, N.R. (2003). A finite difference model to determine conduction heat loss to a water filled mattress for dairy cows. *Transactions of the ASAE* 46(3), S. 773–780, DOI: 10.13031/2013.13592
- Bauer, D.F. (1972): Constructing Confidence Sets Using Rank Statistics. *Journal of the American Statistical Association* 67(339), S. 687–690, DOI: 10.1080/01621459.1972.10481279
- Becker, C.A.; Aghalari, A.; Marufuzzaman, M.; Stone, A.E. (2021): Predicting dairy cattle heat stress using machine learning techniques. *Journal of Dairy Science* 104(1), S. 501–524, DOI: 10.3168/jds.2020-18653
- Beer, G.; Alsaad, M.; Starke, A.; Schuepbach-Regula, G.; Müller, H.; Kohler, P.; Steiner, A. (2016): Use of Extended Characteristics of Locomotion and Feeding Behavior for Automated Identification of Lamé Dairy Cows. *PloS*

- ONE 11(5), e0155796, DOI: 10.1371/journal.pone.0155796
- Beggs, D.S.; Jongman, E.C.; Hemsworth, P.E.; Fisher, A.D. (2018): Implications of prolonged milking time on time budgets and lying behavior of cows in large pasture-based dairy herds. *Journal of Dairy Science* 101(11), S. 10391–10397, DOI: 10.3168/jds.2018-15049
- Beggs, D.S.; Jongman, E.C.; Hemsworth, P.H.; Fisher, A.D. (2019): The effects of herd size on the welfare of dairy cows in a pasture-based system using animal- and resource-based indicators. *Journal of Dairy Science* 102(4), S. 3406–3420, DOI: 10.3168/jds.2018-14850
- Bellagi, R.; Martin, B.; Chassaing, C.; Najjar, T.; Pomiès, D. (2017): Evaluation of heat stress on Tarentaise and Holstein cow performance in the Mediterranean climate. *International Journal of Biometeorology* 61(8), S. 1371–1379, DOI: 10.1007/s00484-017-1314-4
- Benaissa, S.; Tuytens, F.A.M.; Plets, D.; Pessemier, T. de; Trogh, J.; Tanghe, E.; Martens, L.; Vandaele, L.; Van Nuffel, A.; Joseph, W.; Sonck, B. (2017): Behaviours recognition using neck-mounted accelerometers in dairy barns. In: *Proceedings of the 8th European Conference on Precision Livestock Farming. 8th European Conference on Precision Livestock Farming, 12.-13.09.2017, Nantes, France*, S. 69–76
- Benaissa, S.; Tuytens, F.A.M.; Plets, D.; Pessemier, T. de; Trogh, J.; Tanghe, E.; Martens, L.; Vandaele, L.; Van Nuffel, A.; Joseph, W.; Sonck, B. (2019): On the use of on-cow accelerometers for the classification of behaviours in dairy barns. *Research in Veterinary Science* 125, S. 425–433, DOI: 10.1016/j.rvsc.2017.10.005
- Berckmans, D. (2014): Precision livestock farming technologies for welfare management in intensive livestock systems. *Revue Scientifique et Technique de l'OIE* 33(1), S. 189–196, DOI: 10.20506/rst.33.1.2273
- Berglund, B.; Philipsson, J.; Danell, Ö. (1987): External signs of preparation for calving and course of parturition in Swedish dairy cattle breeds. *Animal Reproduction Science* 15(1), S. 61–79, DOI: 10.1016/0378-4320(87)90006-6
- Berman, A. (2005): Estimates of heat stress relief needs for Holstein dairy cows. *Journal of Animal Science* 83(6), S. 1377–1384, DOI: 10.2527/2005.8361377x
- Berry, I.L.; Shanklin, M.D.; Johnson, H.D. (1964): Dairy Shelter Design Based on Milk Production Decline as Affected by Temperature and Humidity. *Transactions of the ASAE* 7(3), S. 329–331, DOI: 10.13031/2013.40772
- Bewley, J.M.; Boyce, R.E.; Hockin, J.; Munksgaard, L.; Eicher, S.D.; Einstein, M.E.; Schutz, M.M. (2010): Influence of milk yield, stage of lactation, and body condition on dairy cattle lying behaviour measured using an automated activity monitoring sensor. *Journal of Dairy Research* 77(1), S. 1–6, DOI: 10.1017/S0022029909990227
- Bewley, J.M.; Grott, M.W.; Einstein, M.E.; Schutz, M.M. (2008): Impact of intake water temperatures on reticular temperatures of lactating dairy cows. *Journal of Dairy Science* 91(10), S. 3880–3887, DOI: 10.3168/jds.2008-1159
- Bewley, J.M.; Schutz, M.M. (2008): An Interdisciplinary Review of Body Condition Scoring for Dairy Cattle. *The Professional Animal Scientist* 24(6), S. 507–529, DOI: 10.15232/S1080-7446(15)30901-3
- Bianca, W. (1976): The significance of meteorology in animal production. *International Journal of Biometeorology* 20(2), S. 139–156, DOI: 10.1007/BF01553047
- Bikker, J.P.; Laar, H. van; Rump, P.; Doorenbos, J.; Meurs, K. van; Griffioen, G.M.; Dijkstra, J. (2014): Technical note. Evaluation of an ear-attached

- movement sensor to record cow feeding behavior and activity. *Journal of Dairy Science* 97(5), S. 2974–2979, DOI: 10.3168/jds.2013-7560
- Black, R.A.; Krawczel, P.D. (2016): A Case Study of Behaviour and Performance of Confined or Pastured Cows During the Dry Period. *Animals* 6(7), 41, DOI: 10.3390/ani6070041
- Bonissone, P.; Cadenas, J.M.; Carmen Garrido, M.; Andrés Díaz-Valladares, R. (2010): A fuzzy random forest. *International Journal of Approximate Reasoning* 51(7), S. 729–747, DOI: 10.1016/j.ijar.2010.02.003
- Boonsanit, D.; Chanpongsang, S.; Chaiyabutr, N. (2012): Effects of supplemental recombinant bovine somatotropin and mist-fan cooling on the renal tubular handling of sodium in different stages of lactation in crossbred Holstein cattle. *Research in Veterinary Science* 93(1), S. 417–426, DOI: 10.1016/j.rvsc.2011.07.021
- Borchers, M.R.; Chang, Y.M.; Proudfoot, K.L.; Wadsworth, B.A.; Stone, A.E.; Bewley, J.M. (2017): Machine-learning-based calving prediction from activity, lying, and ruminating behaviors in dairy cattle. *Journal of Dairy Science* 100(7), S. 5664–5674, DOI: 10.3168/jds.2016-11526
- Borchers, M.R.; Chang, Y.M.; Tsai, I.C.; Wadsworth, B.A.; Bewley, J.M. (2016): A validation of technologies monitoring dairy cow feeding, ruminating, and lying behaviors. *Journal of Dairy Science* 99(9), S. 7458–7466, DOI: 10.3168/jds.2015-10843
- Brassel, J.; Rohrssen, F.; Failing, K.; Wehrend, A. (2018): Automated oestrus detection using multimetric behaviour recognition in seasonal-calving dairy cattle on pasture. *New Zealand Veterinary Journal* 66(5), S. 243–247, DOI: 10.1080/00480169.2018.1479316
- Brassel, J.; Rohrssen, F.; Failing, K.; Wehrend, A. (2019): Automated detection of health disorders in lactating dairy cattle on pasture. A preliminary study. *Polish Journal of Veterinary Sciences* 22(4), S. 761–767, DOI: 10.24425/pjvs.2019.131406
- Breiman, L. (2001): Random Forest. *Machine Learning* 45(1), S. 5–32, DOI: 10.1023/A:1010933404324
- Brody, S.; Ragsdale, A.C.; Thompson, H.J.; Worstell, D.M. (1954): *Environmental Physiology and Shelter Engineering*. XXV. The Effect of Wind on Milk Production, Feed and Water Consumption and Body Weight in Dairy Cattle. With Special Reference to Domestic Animals. Research Bulletin 545. University of Missouri College of Agriculture Agricultural Experiment Station (Hg.)
- Brown, D.D.; Kays, R.; Wikelski, M.; Wilson, R.; Klimley, A.P. (2013): Review. Observing the unwatchable through acceleration logging of animal behavior. *Animal Biotelemetry* 1, 20, DOI: 10.1186/2050-3385-1-20
- Brügemann, K. (2012): Defining and evaluating heat stress thresholds in different dairy cow production systems. *Archiv Tierzucht* 55(1), S. 13–24, DOI: 10.5194/aab-55-13-2012
- Brun, J.P.; Prache, S.; Béchet, G. (1984): A portable device for eating behaviour studies. In: *Proceedings of the 5th European Grazing Workshop*. 5th European Grazing Workshop, Midlothian, UK
- Bruun, J.; Ersbøll, A.; Alban, L. (2002): Risk factors for metritis in Danish dairy cows. *Preventive Veterinary Medicine* 54(2), S. 179–190, DOI: 10.1016/S0167-5877(02)00026-0
- Bucklin, R.A.; Bray, D.R.; Martin, J.G.; Carlos, L.; Carvalho, V. (2009): Environmental Temperatures in Florida Dairy Housing. *Applied Engineering in Agriculture* 25(5), S. 727–735, DOI: 10.13031/2013.28851

- Buffington, D.E.; Collazo-Arocho, A.; Canton, G.H.; Pitt, D.; Thatcher, W.W.; Collier, R.J. (1981): Black Globe-Humidity Index (BGHI) as Comfort Equation for Dairy Cows. *Transactions of the ASAE* 24(3), S. 711–714, DOI: 10.13031/2013.34325
- Bundesministerium für Ernährung und Landwirtschaft (2021): Verordnung zur Fortentwicklung des Rohmilchgüterrechts. RohmilchGütV vom 11.01.2021. Bundesgesetzblatt I
- Burfeind, O.; Keyserlingk, M.A.G. von; Weary, D.M.; Veira, D.M.; Heuwieser, W. (2010): Short communication. Repeatability of measures of rectal temperature in dairy cows. *Journal of Dairy Science* 93(2), S. 624–627, DOI: 10.3168/jds.2009-2689
- Burfeind, O.; Suthar, V.S.; Heuwieser, W. (2012): Effect of heat stress on body temperature in healthy early postpartum dairy cows. *Theriogenology* 78(9), S. 2031–2038, DOI: 10.1016/j.theriogenology.2012.07.024
- Burkov, A. (2019): *Machine Learning kompakt: Alles, was Sie wissen müssen.* mitp Professional, MITP-Verlags GmbH & Co. KG, Frechen, 1. Aufl. ISBN 978-3-95845-996-0
- Burnett, T.A.; Madureira, A.M.L.; Silper, B.F.; Nadalin, A.; Tahmasbi, A.; Veira, D.M.; Cerri, R.L.A. (2014): Short communication. Factors affecting hair cortisol concentrations in lactating dairy cows. *Journal of Dairy Science* 97(12), S. 7685–7690, DOI: 10.3168/jds.2014-8444
- Bustamante, H.A.; Rodríguez, A.R.; Herzberg, D.E.; Werner, M.P. (2015): Stress and pain response after oligofructose induced-lameness in dairy heifers. *Journal of Veterinary Science* 16(4), S. 405–411, DOI: 10.4142/jvs.2015.16.4.405
- Calamari, L.; Abeni, F.; Calegari, F.; Stefanini, L. (2007): Metabolic conditions of lactating Friesian cows during the hot season in the Po valley. 2. Blood minerals and acid-base chemistry. *International Journal of Biometeorology* 52(2), S. 97–107, DOI: 10.1007/s00484-007-0097-4
- Calamari, L.; Petrer, F.; Stefanini, L.; Abeni, F. (2013): Effects of different feeding time and frequency on metabolic conditions and milk production in heat-stressed dairy cows. *International Journal of Biometeorology* 57(5), S. 785–796, DOI: 10.1007/s00484-012-0607-x
- Caplen, G.; Held, S.D.E. (2021 [Im Druck]): Changes in social and feeding behaviors, activity, and salivary serum amyloid A in cows with subclinical mastitis. *Journal of Dairy Science*, DOI: 10.3168/jds.2020-20047
- Cardot, V.; Le Roux, Y.; Jurjanz, S. (2008): Drinking behavior of lactating dairy cows and prediction of their water intake. *Journal of Dairy Science* 91(6), S. 2257–2264, DOI: 10.3168/jds.2007-0204
- Carvalho, D.; Cardoso Pereira, S.; Rocha, A. (2021): Future surface temperatures over Europe according to CMIP6 climate projections. An analysis with original and bias-corrected data. *Climatic Change* 167, 10, DOI: 10.1007/s10584-021-03159-0
- Carvalho, G.A. de; Salman, A.K.D.; Cruz, P.G. da; Souza, E.C. de; Silva, F.R.F. da; Schmitt, E. (2020): Technical note. An acoustic method for assessing the respiration rate of free-grazing dairy cattle. *Livestock Science* 241(5), 104270, DOI: 10.1016/j.livsci.2020.104270
- Cassida, K.A.; Stokes, M.R. (1986): Eating and Resting Salivation in Early Lactation Dairy Cows. *Journal of Dairy Science* 69(5), S. 1282–1292, DOI: 10.3168/jds.S0022-0302(86)80534-3
- Chakravarty, P.; Maalberg, M.; Cozzi, G.; Ozgul, A.; Aminian, K. (2019): Behavioural compass. Animal behaviour recognition using magnetometers.

- Movement Ecology 7, 28, DOI: 10.1186/s40462-019-0172-6
- Chanvallon, A.; Coyral-Castel, S.; Gatien, J.; Lamy, J.-M.; Ribaud, D.; Allain, C.; Clément, P.; Salvetti, P. (2014): Comparison of three devices for the automated detection of estrus in dairy cows. *Theriogenology* 82(5), S. 734–741, DOI: 10.1016/j.theriogenology.2014.06.010
- Chapinal, N.; Passillé, A. de; Weary, D.M.; Keyserlingk, M.A.G. von; Rushen, J. (2009): Using gait score, walking speed, and lying behavior to detect hoof lesions in dairy cows. *Journal of Dairy Science* 92(9), S. 4365–4374, DOI: 10.3168/jds.2009-2115
- Chapinal, N.; Veira, D.M.; Weary, D.M.; Keyserlingk, M.A.G. von (2007): Technical note. Validation of a system for monitoring individual feeding and drinking behavior and intake in group-housed cattle. *Journal of Dairy Science* 90(12), S. 5732–5736, DOI: 10.3168/jds.2007-0331
- Charlton, G.L.; Bouffard, V.; Gibbons, J.; Vasseur, E.; Haley, D.B.; Pellerin, D.; Rushen, J.; Passillé, A.M. de (2016): Can automated measures of lying time help assess lameness and leg lesions on tie-stall dairy farms? *Applied Animal Behaviour Science* 175, S. 14–22, DOI: 10.1016/j.applanim.2015.02.011
- Chelotti, J.O.; Vanrell, S.R.; Galli, J.R.; Giovanini, L.L.; Rufiner, H.L. (2018): A pattern recognition approach for detecting and classifying jaw movements in grazing cattle. *Computers and Electronics in Agriculture* 145, S. 83–91, DOI: 10.1016/j.compag.2017.12.013
- Chelotti, J.O.; Vanrell, S.R.; Martinez Rau, L.S.; Galli, J.R.; Planisich, A.M.; Utsumi, S.A.; Milone, D.H.; Giovanini, L.L.; Rufiner, H.L. (2020): An online method for estimating grazing and rumination bouts using acoustic signals in grazing cattle. *Computers and Electronics in Agriculture* 173(2), 105443, DOI: 10.1016/j.compag.2020.105443
- Chen, J.M.; Schütz, K.E.; Tucker, C.B. (2016): Sprinkler flow rate affects dairy cattle preferences, heat load, and insect deterrence behavior. *Applied Animal Behaviour Science* 182, S. 1–8, DOI: 10.1016/j.applanim.2016.05.023
- Chen, S.; Wang, J.; Peng, D.; Li, G.; Chen, J.; Gu, X. (2018): Exposure to heat-stress environment affects the physiology, circulation levels of cytokines, and microbiome in dairy cows. *Scientific Reports* 8(1), 14606, DOI: 10.1038/s41598-018-32886-1
- Chung, H.; Li, J.; Kim, Y.; Van Os, J.M.; Brounts, S.H.; Choi, C.Y. (2020): Using implantable biosensors and wearable scanners to monitor dairy cattle's core body temperature in real-time. *Computers and Electronics in Agriculture* 174(3), 105453, DOI: 10.1016/j.compag.2020.105453
- Cincović, M.R.; Belić, B.; Toholj, B.; Potkonjak, A.; Stevančević, M.; Lako, B.; Radović, I. (2011): Metabolic acclimation to heat stress in farm housed Holstein cows with different body condition scores. *African Journal of Biotechnology* 10(50), S. 10293–10303, DOI: 10.5897/AJB11.847
- Clark, C.E.F.; Lyons, N.A.; Millapan, L.; Talukder, S.; Cronin, G.M.; Kerrisk, K.L.; Garcia, S.C. (2015): Rumination and activity levels as predictors of calving for dairy cows. *Animal* 9(4), S. 691–695, DOI: 10.1017/S1751731114003127
- Cohen, J. (1988): *Statistical Power Analysis for the Behavioral Sciences*, Routledge, London, UK, 2. Aufl. ISBN 978-0-12-179060-8
- Connors, M.G.; Michelot, T.; Heywood, E.I.; Orben, R.A.; Phillips, R.A.; Vyssotski, A.L.; Shaffer, S.A.; Thorne, L.H. (2021): Hidden Markov models identify major movement modes in accelerometer and magnetometer data from four albatross species. *Movement Ecology* 9, 7, DOI: 10.1186/s40462-021-00243-z

- Cook, N.B.; Bennett, T.B.; Nordlund, K.V. (2004): Effect of Free Stall Surface on Daily Activity Patterns in Dairy Cows with Relevance to Lameness Prevalence. *Journal of Dairy Science* 87(9), S. 2912–2922, DOI: 10.3168/jds.S0022-0302(04)73422-0
- Cook, N.B.; Mentink, R.L.; Bennett, T.B.; Burgi, K. (2007): The effect of heat stress and lameness on time budgets of lactating dairy cows. *Journal of Dairy Science* 90(4), S. 1674–1682, DOI: 10.3168/jds.2006-634
- Cooper, R. (2014): Ketosis in dairy cattle. *Livestock* 19(2), S. 74–82, DOI: 10.12968/live.2014.19.2.74
- Crump, A.; Jenkins, K.; Bethell, E.J.; Ferris, C.P.; Arnott, G. (2019): Pasture Access Affects Behavioral Indicators of Wellbeing in Dairy Cows. *Animals* 9(11), 902, DOI: 10.3390/ani9110902
- Dado, R.G.; Allen, M.S. (1993): Continuous Computer Acquisition of Feed and Water Intakes, Chewing, Reticular Motility, and Ruminant pH of Cattle. *Journal of Dairy Science* 76(6), S. 1589–1600, DOI: 10.3168/jds.S0022-0302(93)77492-5
- Dado, R.G.; Allen, M.S. (1994): Variation in and Relationships Among Feeding, Chewing, and Drinking Variables for Lactating Dairy Cows. *Journal of Dairy Science* 77(1), S. 132–144, DOI: 10.3168/jds.S0022-0302(94)76936-8
- Dalcin, V.C.; Fischer, V.; Santos Daltro, D. dos; Alfonzo, E.P.M.; Stumpf, M.T.; Kolling, G.J.; Silva, M.V.G.B. da; McManus, C. (2016): Physiological parameters for thermal stress in dairy cattle. *Revista Brasileira de Zootecnia* 45(8), S. 458–465, DOI: 10.1590/S1806-92902016000800006
- Daros, R.R.; Bran, J.A.; Hötzel, M.J.; Keyserlingk, M.A.G. von (2019): Readily Available Water Access is Associated with Greater Milk Production in Grazing Dairy Herds. *Animals* 9(2), 48, DOI: 10.3390/ani9020048
- Das, R.; Sailo, L.; Verma, N.; Bharti, P.; Saikia, J.; Imtiwati; Kumar, R. (2016): Impact of heat stress on health and performance of dairy animals. A review. *Veterinary World* 9(3), S. 260–268, DOI: 10.14202/vetworld.2016.260-268
- Davis, S.R.; Collier, R.J.; McNamara, J.P.; Head, H.H.; Sussman, W. (1988): Effects of thyroxine and growth hormone treatment of dairy cows on milk yield, cardiac output and mammary blood flow. *Journal of Animal Science* 66(1), S. 70–79, DOI: 10.2527/jas1988.66170x.
- Davison, C.; Michie, C.; Hamilton, A.; Tachtatzis, C.; Andonovic, I.; Gilroy, M. (2020): Detecting Heat Stress in Dairy Cattle Using Neck-Mounted Activity Collars. *Agriculture* 10(6), 210, DOI: 10.3390/agriculture10060210
- Dechow, C. (2015): U.S. breed composition has been slowly shifting. <https://hoards.com/article-16267-us-breed-composition-has-been-slowly-shifting.html>, Zugriff am 10.9.2021
- Deming, J.A.; Bergeron, R.; Leslie, K.E.; DeVries, T.J. (2013): Associations of cow-level factors, frequency of feed delivery, and standing and lying behaviour of dairy cows milked in an automatic system. *Canadian Journal of Animal Science* 93(4), S. 427–433, DOI: 10.4141/cjas2013-055
- DeVries, T.J.; Keyserlingk, M.A.G. von (2005): Time of Feed Delivery Affects the Feeding and Lying Patterns of Dairy Cows. *Journal of Dairy Science* 88(2), S. 625–631, DOI: 10.3168/jds.S0022-0302(05)72726-0
- DeVries, T.J.; Keyserlingk, M.A.G. von; Weary, D.M.; Beauchemin, K.A. (2003): Measuring the Feeding Behavior of Lactating Dairy Cows in Early to Peak Lactation. *Journal of Dairy Science* 86(10), S. 3354–3361, DOI: 10.3168/jds.S0022-0302(03)73938-1
- Diepold, D.A. (2019): Effekte der Fleckvieh-Rückkreuzung auf Fruchtbarkeit und Gesundheit. Inaugural-Dissertation, Ludwig-Maximilians-Universität

- München, München, Deutschland
- Dirksen, N.; Gygax, L.; Traulsen, I.; Wechsler, B.; Burla, J.-B. (2020): Body size in relation to cubicle dimensions affects lying behavior and joint lesions in dairy cows. *Journal of Dairy Science* 103(10), S. 9407–9417, DOI: 10.3168/jds.2019-16464
- Dobson, H.; Williams, J.; Routly, J.E.; Jones, D.N.; Cameron, J.; Holman-Coates, A.; Smith, R.F. (2018): Short communication. Chronology of different sexual behaviors and motion activity during estrus in dairy cows. *Journal of Dairy Science* 101(9), S. 8291–8295, DOI: 10.3168/jds.2017-14341
- Doehring, C.; Sundrum, A. (2019): The informative value of an overview on antibiotic consumption, treatment efficacy and cost of clinical mastitis at farm level. *Preventive Veterinary Medicine* 165, S. 63–70, DOI: 10.1016/j.prevetmed.2019.02.004
- Dohme-Meier, F.; Kaufmann, L.D.; Görs, S.; Junghans, P.; Metges, C.C.; Dorland, H.A. van; Bruckmaier, R.M.; Mürger, A. (2014): Comparison of energy expenditure, eating pattern and physical activity of grazing and zero-grazing dairy cows at different time points during lactation. *Livestock Science* 162, S. 86–96, DOI: 10.1016/j.livsci.2014.01.006
- Dolecheck, K.A.; Heersche, G.; Bewley, J.M. (2016): Retention payoff-based cost per day open regression equations. Application in a user-friendly decision support tool for investment analysis of automated estrus detection technologies. *Journal of Dairy Science* 99(12), S. 10182–10193, DOI: 10.3168/jds.2015-10364
- Dong, R.L.; Chibisa, G.E.; Beauchemin, K.A. (2018): Estimating optimal observational sampling frequency of behaviors for cattle fed high- and low-forage diets. *Journal of Animal Science* 96(3), S. 783–796, DOI: 10.1093/jas/skx073
- Drackley, J.K.; Cicela, T.M.; LaCount, D.W. (2003): Responses of Primiparous and Multiparous Holstein Cows to Additional Energy from Fat or Concentrate During Summer. *Journal of Dairy Science* 86(4), S. 1306–1314, DOI: 10.3168/jds.S0022-0302(03)73714-X
- Dreiseitl, S.; Ohno-Machado, L. (2002): Logistic regression and artificial neural network classification models: a methodology review. *Journal of Biomedical Informatics* 35(5-6), S. 352–359, DOI: 10.1016/S1532-0464(03)00034-0
- Dutta, R.; Smith, D.; Rawnsley, R.; Bishop-Hurley, G.; Hills, J.; Timms, G.; Henry, D. (2015): Dynamic cattle behavioural classification using supervised ensemble classifiers. *Computers and Electronics in Agriculture* 111(1), S. 18–28, DOI: 10.1016/j.compag.2014.12.002
- Dwyer, K.; Holte, R. (2007): Decision Tree Instability and Active Learning. In: *Machine Learning: ECML 2007. ECML 2007. Lecture Notes in Computer Science*, Springer-Verlag GmbH, S. 128–139, DOI: 10.1007/978-3-540-74958-5\_15
- Eastwood, C.; Klerkx, L.; Ayre, M.; Dela Rue, B. (2019): Managing Socio-Ethical Challenges in the Development of Smart Farming. From a Fragmented to a Comprehensive Approach for Responsible Research and Innovation. *Journal of Agricultural and Environmental Ethics* 32, S. 741–768, DOI: 10.1007/s10806-017-9704-5
- Edmonson, A.J.; Lean, I.J.; Weaver, L.D.; Farver, T.; Webster, G. (1988): A Body Condition Scoring Chart for Holstein Dairy Cows. *Journal of Dairy Science* 72, S. 68–78, DOI: 10.3168/jds.S0022-0302(89)79081-0
- Elischer, M.F.; Arceo, M.E.; Karcher, E.L.; Siegford, J.M. (2013): Validating the accuracy of activity and rumination monitor data from dairy cows housed in a

- pasture-based automatic milking system. *Journal of Dairy Science* 96(10), S. 6412–6422, DOI: 10.3168/jds.2013-6790
- El-Nouty, F.D.; Elbanna, I.M.; Davis, T.P.; Johnson, H.D. (1980): Aldosterone and ADH response to heat and dehydration in cattle. *Journal of Applied Physiology: Respiratory, Environmental and Exercise Physiology* 48(2), S. 249–255, DOI: 10.1152/jappl.1980.48.2.249
- Eslamizad, M.; Lamp, O.; Derno, M.; Kuhla, B. (2015): The control of short-term feed intake by metabolic oxidation in late-pregnant and early lactating dairy cows exposed to high ambient temperatures. *Physiology & Behavior* 145, S. 64–70, DOI: 10.1016/j.physbeh.2015.03.044
- Falk, A.C.; Weary, D.M.; Winckler, C.; Keyserlingk, M.A.G. von (2012): Preference for pasture versus freestall housing by dairy cattle when stall availability indoors is reduced. *Journal of Dairy Science* 95(11), S. 6409–6415, DOI: 10.3168/jds.2011-5208
- Ferrell, C.L.; Garrett, W.N.; Hinman, N.; Grichting, G. (1976): Energy utilization by pregnant and non-pregnant heifers. *Journal of Animal Science* 42(4), S. 937–950, DOI: 10.2527/jas1976.424937x
- Fisher, A.D.; Roberts, N.; Bluett, S.J.; Verkerk, G.A.; Matthews, L.R. (2010): Effects of shade provision on the behaviour, body temperature and milk production of grazing dairy cows during a New Zealand summer. *New Zealand Journal of Agricultural Research* 51(2), S. 99–105, DOI: 10.1080/00288230809510439
- Fleiss, J.L. (1971): Measuring nominal scale agreement among many raters. *Psychological Bulletin* 76(5), S. 378–382, DOI: 10.1037/h0031619
- Flury, R.; Gygax, L. (2016): Daily patterns of synchrony in lying and feeding of cows. Quasi-natural state and (anti-) synchrony factors. *Behavioural Processes* 133, S. 56–61, DOI: 10.1016/j.beproc.2016.11.004
- Fogsgaard, K.K.; Bennedsgaard, T.W.; Herskin, M.S. (2015): Behavioral changes in freestall-housed dairy cows with naturally occurring clinical mastitis. *Journal of Dairy Science* 98(3), S. 1730–1738, DOI: 10.3168/jds.2014-8347
- Fogsgaard, K.K.; Røntved, C.M.; Sørensen, P.; Herskin, M.S. (2012): Sickness behavior in dairy cows during *Escherichia coli* mastitis. *Journal of Dairy Science* 95(2), S. 630–638, DOI: 10.3168/jds.2011-4350
- Foris, B.; Thompson, A.J.; Keyserlingk, M.A.G. von; Melzer, N.; Weary, D.M. (2019): Automatic detection of feeding- and drinking-related agonistic behavior and dominance in dairy cows. *Journal of Dairy Science* 102(10), S. 9176–9186, DOI: 10.3168/jds.2019-16697
- Fournel, S.; Ouellet, V.; Charbonneau, É. (2017): Practices for Alleviating Heat Stress of Dairy Cows in Humid Continental Climates: A Literature Review. *Animals* 7(5), DOI: 10.3390/ani7050037
- Fregonesi, J.A.; Leaver, J. (2001): Behaviour, performance and health indicators of welfare for dairy cows housed in strawyard or cubicle systems. *Livestock Production Science* 68(2-3), S. 205–216, DOI: 10.1016/S0301-6226(00)00234-7
- Fregonesi, J.A.; Tucker, C.B.; Weary, D.M. (2007): Overstocking reduces lying time in dairy cows. *Journal of Dairy Science* 90(7), S. 3349–3354, DOI: 10.3168/jds.2006-794
- Friggens, N.C.; Nielsen, B.L.; Kyriazakis, I.; Tolcamp, B.J.; Emmans, G.C. (1998): Effects of Feed Composition and Stage of Lactation on the Short-term Feeding Behavior of Dairy Cows. *Journal of Dairy Science* 81(12), S. 3268–3277, DOI: 10.3168/jds.S0022-0302(98)75891-6
- Fukasawa, M.; Komatsu, T.; Higashiyama, Y. (2019): Sleep and lying behavior of

- milking Holstein cows at commercial tie-stall dairy farms. *Animal Science Journal* 90(9), S. 1313–1319, DOI: 10.1111/asj.13265
- Galán, E.; Llonch, P.; Villagrà, A.; Levit, H.; Pinto, S.; Del Prado, A. (2018): A systematic review of non-productivity-related animal-based indicators of heat stress resilience in dairy cattle. *PloS ONE* 13(11), e0206520, DOI: 10.1371/journal.pone.0206520
- Galindo, F.; Broom, D.M. (2000): The relationships between social behaviour of dairy cows and the occurrence of lameness in three herds. *Research in Veterinary Science* 69(1), S. 75–79, DOI: 10.1053/rvsc.2000.0391
- Gallacher, B.J. (2012): Principles of a Micro-Rate Integrating Ring Gyroscope. *IEEE Transactions on Aerospace and Electronic Systems* 48(1), S. 658–672, DOI: 10.1109/TAES.2012.6129662
- Galli, J.R.; Cangiano, C.A.; Pece, M.A.; Larripa, M.J.; Milone, D.H.; Utsumi, S.A.; Laca, E.A. (2018): Monitoring and assessment of ingestive chewing sounds for prediction of herbage intake rate in grazing cattle. *Animal* 12(5), S. 973–982, DOI: 10.1017/S1751731117002415
- Gantner, V. (2017): The differences in heat stress resistance due to dairy cattle breed. *Mljekarstvo / Dairy* 62(2), S. 112–122, DOI: 10.15567/mljekarstvo.2017.0203
- Gantner, V.; Bobić, T.; Potočnik, K.; Gregić, M.; Kučević, D. (2019): Persistence of heat stress effect in dairy cows. *Mljekarstvo / Dairy* 69(1), S. 30–41, DOI: 10.15567/mljekarstvo.2019.0103
- Gantner, V.; Kuterovac, K.; Potočnik, K. (2016): Effect of Heat Stress on Metabolic Disorders Prevalence Risk and Milk Production in Holstein Cows in Croatia. *Annals of Animal Science* 16(2), S. 451–461, DOI: 10.1515/aoas-2015-0097
- García, R.; Aguilar, J.; Toro, M.; Pinto, A.; Rodríguez, P. (2020): A systematic literature review on the use of machine learning in precision livestock farming. *Computers and Electronics in Agriculture* 179(2), 105826, DOI: 10.1016/j.compag.2020.105826
- Garner, J.B.; Douglas, M.; Williams, S.R.O.; Wales, W.J.; Marett, L.C.; DiGiacomo, K.; Leury, B.J.; Hayes, B.J. (2017): Responses of dairy cows to short-term heat stress in controlled-climate chambers. *Animal Production Science* 57(7), 1233, DOI: 10.1071/AN16472
- Gáspárdy, A.; Efrat, G.; Bajcsy, A.C.; Fekete, S.G. (2014): Electronic monitoring of rumination activity as an indicator of health status and production traits in high-yielding dairy cows. *Acta Veterinaria Hungarica* 62(4), S. 452–462, DOI: 10.1556/AVet.2014.026
- Gaughan, J.B.; Mader, T.L.; Holt, S.M.; Lisle, A. (2008): A new heat load index for feedlot cattle. *Journal of Animal Science* 86(1), S. 226–234, DOI: 10.2527/jas.2007-0305
- Gebremedhin, K.G. (1987): Effect of animal orientation with respect to wind direction on convective heat loss. *Agricultural and Forest Meteorology* 40(2), S. 199–206, DOI: 10.1016/0168-1923(87)90007-4
- Gebremedhin, K.G.; Lee, C.N.; Hillman, P.E.; Collier, R.J. (2010): Physiological Responses of Dairy Cows during Extended Solar Exposure. *Transactions of the ASABE* 53(1), S. 239–247, DOI: 10.13031/2013.29499
- Geischer, S. (2017): Auswirkungen von Hitzestress auf Milchkühe der Rasse Fleckvieh unter bayerischen Klimabedingungen und Einfluss einer Unterstützungslüftung durch Ventilatoren. Dissertation, Ludwig-Maximilians-Universität München, München, Deutschland
- Ghassemi Nejad, J.; Kim, B.-W.; Lee, B.-H.; Sung, K.-I. (2017): Coat and hair

- color. Hair cortisol and serotonin levels in lactating Holstein cows under heat stress conditions. *Animal Science Journal* 88(1), S. 190–194, DOI: 10.1111/asj.12662
- Giaretta, E.; Marliani, G.; Postiglione, G.; Magazzù, G.; Pantò, F.; Mari, G.; Formigoni, A.; Accorsi, P.A.; Mordenti, A. (2021): Calving time identified by the automatic detection of tail movements and rumination time, and observation of cow behavioural changes. *Animal* 15(1), 100071, DOI: 10.1016/j.animal.2020.100071
- González, L.A.; Bishop-Hurley, G.J.; Handcock, R.N.; Crossman, C. (2015): Behavioral classification of data from collars containing sensors in grazing cattle. *Computers and Electronics in Agriculture* 110, S. 91–102, DOI: 10.1016/j.compag.2014.10.018
- González Pereyra, A.V.; Maldonado May, V.; Guillermo Catracchia, C. (2010): Influence of Water Temperature and Heat Stress on Drinking Water Intake in Dairy Cows. *Chilean Journal of Agricultural Research* 70(2), S. 328–336, DOI: 10.4067/S0718-58392010000200017
- Gorniak, T.; Meyer, U.; Südekum, K.-H.; Dänicke, S. (2014): Impact of mild heat stress on dry matter intake, milk yield and milk composition in mid-lactation Holstein dairy cows in a temperate climate. *Archives of Animal Nutrition* 68(5), S. 358–369, DOI: 10.1080/1745039X.2014.950451
- Green, L.E.; Hedges, V.J.; Schukken, Y.H.; Blowey, R.W.; Packington, A.J. (2002): The Impact of Clinical Lameness on the Milk Yield of Dairy Cows. *Journal of Dairy Science* 85(9), S. 2250–2256, DOI: 10.3168/jds.S0022-0302(02)74304-X
- Gregorini, P.; Clark, C.E.F.; Jago, J.G.; Glassey, C.B.; McLeod, K.L.M.; Romera, A.J. (2009): Restricting time at pasture: Effects on dairy cow herbage intake, foraging behavior, hunger-related hormones, and metabolite concentration during the first grazing session. *Journal of Dairy Science* 92(9), S. 4572–4580, DOI: 10.3168/jds.2009-2322
- Gregorini, P.; Dela Rue, B.; Pourau, M.; Glassey, C.; Jago, J. (2013): A note on rumination behavior of dairy cows under intensive grazing systems. *Livestock Science* 158(1-3), S. 151–156, DOI: 10.1016/j.livsci.2013.10.012
- Gregorini, P.; DelaRue, B.; McLeod, K.; Clark, C.; Glassey, C.B.; Jago, J. (2012): Rumination behavior of grazing dairy cows in response to restricted time at pasture. *Livestock Science* 146(1), S. 95–98, DOI: 10.1016/j.livsci.2012.02.020
- Grinter, L.N. (2019): Validation of an automated behavior monitoring collar, and evaluation of heat stress on lactating dairy cow behavior with access to a free choice soaker. Masterarbeit, University of Kentucky, Lexington, USA
- Grinter, L.N.; Campler, M.R.; Costa, J.H.C. (2019): Technical note. Validation of a behavior-monitoring collar's precision and accuracy to measure rumination, feeding, and resting time of lactating dairy cows. *Journal of Dairy Science* 102(4), S. 3487–3494, DOI: 10.3168/jds.2018-15563
- Gygax, L.; Neuffer, I.; Kaufmann, C.; Hauser, R.; Wechsler, B. (2006): Milk Cortisol Concentration in Automatic Milking Systems Compared with Auto-Tandem Milking Parlors. *Journal of Dairy Science* 89(9), S. 3447–3454, DOI: 10.3168/jds.S0022-0302(06)72382-7
- Haladjian, J.; Haug, J.; Nüske, S.; Bruegge, B. (2018): A Wearable Sensor System for Lameness Detection in Dairy Cattle. *Multimodal Technologies and Interaction* 2(2), 27, DOI: 10.3390/mti2020027
- Haley, D.; Passillé, A. de; Rushen, J. (2001): Assessing cow comfort. Effects of two floor types and two tie stall designs on the behaviour of lactating dairy

- cows. *Applied Animal Behaviour Science* 71(2), S. 105–117, DOI: 10.1016/S0168-1591(00)00175-1
- Hamada, T. (1971): Estimation of Lower Critical Temperatures for Dry and Lactating Dairy Cows. *Journal of Dairy Science* 54(11), S. 1704–1705, DOI: 10.3168/jds.S0022-0302(71)86093-9
- Hamilton, A.W.; Davison, C.; Tachtatzis, C.; Andonovic, I.; Michie, C.; Ferguson, H.J.; Somerville, L.; Jonsson, N.N. (2019): Identification of the Rumination in Cattle Using Support Vector Machines with Motion-Sensitive Bolus Sensors. *Sensors* 19(5), 1165, DOI: 10.3390/s19051165
- Hammami, H.; Bormann, J.; M'hamdi, N.; Montaldo, H.H.; Gengler, N. (2013): Evaluation of heat stress effects on production traits and somatic cell score of Holsteins in a temperate environment. *Journal of Dairy Science* 96(3), S. 1844–1855, DOI: 10.3168/jds.2012-5947
- Han, Y.K.; Kim, I.H. (2005): Risk factors for retained placenta and the effect of retained placenta on the occurrence of postpartum diseases and subsequent reproductive performance in dairy cows. *Journal of Veterinary Science* 6(1), S. 53–59, DOI: 10.4142/jvs.2005.6.1.53
- Hansen, B.D.; Lascelles, B.D.X.; Keene, B.W.; Adams, A.K.; Thomson, A.E. (2007): Evaluation of an accelerometer for at-home monitoring of spontaneous activity in dogs. *American Journal of Veterinary Research* 68(5), S. 468–475, DOI: 10.2460/ajvr.68.5.468
- Hanušovský, O.; Bíro, D.; Šimko, M.; Gálik, B.; Juráček, M.; Rolinec, M.; Herkeľ, R. (2017): Drinking regime evaluation with continuous ruminal monitoring boluses. *Acta fytotechnica et zootechnica* 20(1), S. 1–5, DOI: 10.15414/afz.2017.20.01.01-05
- Hasegawa, N.; Nishiwaki, A.; Sugawara, K.; Ito, I. (1997): The effects of social exchange between two groups of lactating primiparous heifers on milk production, dominance order, behavior and adrenocortical response. *Applied Animal Behaviour Science* 51(1-2), S. 15–27, DOI: 10.1016/S0168-1591(96)01082-9
- Heinicke, J.; Hoffmann, G.; Ammon, C.; Amon, B.; Amon, T. (2018): Effects of the daily heat load duration exceeding determined heat load thresholds on activity traits of lactating dairy cows. *Journal of Thermal Biology* 77, S. 67–74, DOI: 10.1016/j.jtherbio.2018.08.012
- Heinicke, J.; Ibscher, S.; Belik, V.; Amon, T. (2019): Cow individual activity response to the accumulation of heat load duration. *Journal of Thermal Biology* 82, S. 23–32, DOI: 10.1016/j.jtherbio.2019.03.011
- Henriksen, J.C.; Munksgaard, L. (2019): Validation of AfiTagII, a device for automatic measuring of lying behaviour in Holstein and Jersey cows on two different bedding materials. *Animal* 13(3), S. 617–621, DOI: 10.1017/S1751731118001623
- Herbut, P.; Angrecka, S. (2018): The effect of heat stress on time spent lying by cows in a housing system. *Annals of Animal Science* 18(3), S. 825–833, DOI: 10.2478/aoas-2018-0018
- Hernandez, C.E.; Thierfelder, T.; Svennersten-Sjaunja, K.; Berg, C.; Orihuela, A.; Lidfors, L. (2014): Time lag between peak concentrations of plasma and salivary cortisol following a stressful procedure in dairy cattle. *Acta Veterinaria Scandinavica* 56, 61, DOI: 10.1186/s13028-014-0061-3
- Hernandez-Mendo, O.; Keyserlingk, M.A.G. von; Veira, D.M.; Weary, D.M. (2007): Effects of Pasture on Lameness in Dairy Cows. *Journal of Dairy Science* 90(3), S. 1209–1214, DOI: 10.3168/jds.S0022-0302(07)71608-9
- Herskin, M.S.; Munksgaard, L.; Ladewig, J. (2004): Effects of acute stressors on

- nociception, adrenocortical responses and behavior of dairy cows. *Physiology & Behavior* 83(3), S. 411–420, DOI: 10.1016/j.physbeh.2004.08.027
- Hilbk-Kortenbruck, K. (2020): Die Reproduktion im Blick behalten. Wie fruchtbar sind meine Kühe, was kann ich verbessern und wo möchte ich hin? Ein Überblick über wichtige Kennzahlen und Tipps zum Reproduktionsmanagement. <https://www.elite-magazin.de/news/nachrichten/die-reproduktion-im-blick-behalten-10819.html>, Zugriff am 13.9.2021
- Hildebrandt, J.-P.; Bleckmann, H.; Homberg, U. (2021): *Penzlin - Lehrbuch der Tierphysiologie*, Springer-Verlag GmbH, Berlin [u.a.], Deutschland. ISBN 978-3-642-55368-4
- Hillman, P.E.; Lee, C.N.; Willard, S.T. (2005): Thermoregulatory responses associated with lying and standing in heat-stressed dairy cows. *Transactions of the ASAE* 48(2), S. 795–801, DOI: 10.13031/2013.18322
- Hoffmann, G.; Herbut, P.; Pinto, S.; Heinicke, J.; Kuhla, B.; Amon, T. (2019): Animal-related, non-invasive indicators for determining heat stress in dairy cows. *Biosystems Engineering* 199, S. 83–96, DOI: 10.1016/j.biosystemseng.2019.10.017
- Holman, A.; Thompson, J.; Routly, J.E.; Cameron, J.; Jones, D.N.; Grove-Whie, D.; Smith, R.F.; Dobson, H. (2011): Comparison of oestrus detection methods in dairy cattle. *Veterinary Record* 169(2), 47, DOI: 10.1136/vr.d2344.
- Honig, H.; Miron, J.; Lehrer, H.; Jackoby, S.; Zachut, M.; Zinou, A.; Portnick, Y.; Moallem, U. (2012): Performance and welfare of high-yielding dairy cows subjected to 5 or 8 cooling sessions daily under hot and humid climate. *Journal of Dairy Science* 95(7), S. 3736–3742, DOI: 10.3168/jds.2011-5054
- Hopster, H.; Werf, J.T. van der; Erkens, J.H.; Blokhuis, H.J. (1999): Effects of repeated jugular puncture on plasma cortisol concentrations in loose-housed dairy cows. *Journal of Animal Science* 77(3), S. 708–714, DOI: 10.2527/1999.773708x
- Horst, R.L.; Goff, J.P.; Reinhardt, T.A. (2005): Adapting to the transition between gestation and lactation. Differences between rat, human and dairy cow. *Journal of Mammary Gland Biology and Neoplasia* 10(2), S. 141–156, DOI: 10.1007/s10911-005-5397-x
- Horváth, A.; Lénárt, L.; Csepregy, A.; Madar, M.; Pálffy, M.; Szenci, O. (2021): A field study using different technologies to detect calving at a large-scale hungarian dairy farm. *Reproduction in Domestic Animals* 56(4), S. 673–679, DOI: 10.1111/rda.13904
- Hostiou, N.; Fagon, J.; Chauvat, S.; Turlot, A.; Kling-Eveillard, F. (2017): Impact of precision livestock farming on work and human-animal interactions on dairy farms. A review. *Biotechnology, Agronomy, Society and Environment* 21(4), S. 268–275, DOI: 10.25518/1780-4507.13706
- Hurnik, J.F.; King, G.J.; Robertson, H.A. (1975): Estrous and related behaviour in postpartum Holstein cows. *Applied Animal Ethology* 2(1), S. 55–68, DOI: 10.1016/0304-3762(75)90065-6
- Huzzey, J.M.; Keyserlingk, M.A.G. von; Weary, D.M. (2005): Changes in Feeding, Drinking, and Standing Behavior of Dairy Cows During the Transition Period. *Journal of Dairy Science* 88(7), S. 2454–2461, DOI: 10.3168/jds.S0022-0302(05)72923-4
- Igono, M.O.; Bjotvedt, G.; Sanford-Crane, H.T. (1992): Environmental profile and critical temperature effects on milk production of Holstein cows in desert climate. *International Journal of Biometeorology* 36(2), S. 77–87, DOI: 10.1007/BF01208917

- Islam, M.A.; Lomax, S.; Doughty, A.K.; Islam, M.R.; Clark, C.E.F. (2020): Automated Monitoring of Panting for Feedlot Cattle. Sensor System Accuracy and Individual Variability. *Animals* 10(9), DOI: 10.3390/ani10091518
- Ito, K.; Chapinal, N.; Weary, D.M.; Keyserlingk, M.A.G. von (2014): Associations between herd-level factors and lying behavior of freestall-housed dairy cows. *Journal of Dairy Science* 97(4), S. 2081–2089, DOI: 10.3168/jds.2013-6861
- Ito, K.; Keyserlingk, M.A.G. von; LeBlanc, S.J.; Weary, D.M. (2010): Lying behavior as an indicator of lameness in dairy cows. *Journal of Dairy Science* 93(8), S. 3553–3560, DOI: 10.3168/jds.2009-2951
- Ito, K.; Weary, D.M.; Keyserlingk, M.A.G. von (2009): Lying behavior: Assessing within- and between-herd variation in free-stall-housed dairy cows. *Journal of Dairy Science* 92(9), S. 4412–4420, DOI: 10.3168/jds.2009-2235
- Jago, J.; Eastwood, C.; Kerrisk, K.; Yule, I. (2013): Precision dairy farming in Australasia. Adoption, risks and opportunities. *Animal Production Science* 53(9), 907, DOI: 10.1071/AN12330
- Jago, J.G.; Roche, J.R.; Kolver, E.S.; Woolford, M.W. (2005): The drinking behaviour of dairy cows in late lactation. In: *Proceedings of the New Zealand Society of Animal Production*, S. 209–214
- Jaurena, G.; Moorby, J.M.; Fisher, W.J.; Cantet, R. (2005): Association of body weight, loin longissimus dorsi and backfat with body condition score in dry and lactating Holstein dairy cows. *Animal Science* 80(2), S. 219–223, DOI: 10.1079/ASC41750219
- Jawor, P.E.; Huzzey, J.M.; LeBlanc, S.J.; Keyserlingk, M.A.G. von (2012): Associations of subclinical hypocalcemia at calving with milk yield, and feeding, drinking, and standing behaviors around parturition in Holstein cows. *Journal of Dairy Science* 95(3), S. 1240–1248, DOI: 10.3168/jds.2011-4586
- Jemila, J.S.; Priyadharsini, S.S. (2018): A Sensor-Based Forage Monitoring of Grazing Cattle in Dairy Farming. *International Journal on Smart Sensing and Intelligent Systems* 11(1), S. 1–9, DOI: 10.21307/ijssis-2018-014
- Jensen, M.B. (2011): The early behaviour of cow and calf in an individual calving pen. *Applied Animal Behaviour Science* 134(3-4), S. 92–99, DOI: 10.1016/j.applanim.2011.06.017
- Jensen, M.B. (2012): Behaviour around the time of calving in dairy cows. *Applied Animal Behaviour Science* 139(3-4), S. 195–202, DOI: 10.1016/j.applanim.2012.04.002
- Ji, B.; Banhazi, T.; Ghahramani, A.; Bowtell, L.; Wang, C.; Li, B. (2020a): Modelling of heat stress in a robotic dairy farm. Part 1. Thermal comfort indices as the indicators of production loss. *Biosystems Engineering* 199(1), S. 27–42, DOI: 10.1016/j.biosystemseng.2019.11.004
- Ji, B.; Banhazi, T.; Ghahramani, A.; Bowtell, L.; Wang, C.; Li, B. (2020b): Modelling of heat stress in a robotic dairy farm. Part 2. Identifying the specific thresholds with production factors. *Biosystems Engineering* 199(1), S. 43–57, DOI: 10.1016/j.biosystemseng.2019.11.005
- Jorquera-Chavez, M.; Fuentes, S.; Dunshea, F.R.; Warner, R.D.; Poblete, T.; Jongman, E.C. (2019): Modelling and Validation of Computer Vision Techniques to Assess Heart Rate, Eye Temperature, Ear-Base Temperature and Respiration Rate in Cattle. *Animals* 9(12), 1089, DOI: 10.3390/ani9121089
- Kamminga, J.W.; Le, D.V.; Meijers, J.P.; Bisby, H.; Meratnia, N.; Havinga, P.J. (2018): Robust Sensor-Orientation-Independent Feature Selection for Animal Activity Recognition on Collar Tags. *Proceedings of the ACM on Interactive,*

- Mobile, Wearable and Ubiquitous Technologies 2(1), S. 1–27,  
DOI: 10.1145/3191747
- Kamphuis, C.; Frank, E.; Burke, J.K.; Verkerk, G.A.; Jago, J.G. (2013): Applying additive logistic regression to data derived from sensors monitoring behavioral and physiological characteristics of dairy cows to detect lameness. *Journal of Dairy Science* 96(11), S. 7043–7053, DOI: 10.3168/jds.2013-6993
- Kaneene, J.B.; Hurd, S.H. (1990): The National Animal Health Monitoring System in Michigan. III. Cost Estimates of Selected Dairy Cattle Diseases. *Preventive Veterinary Medicine* 8(2-3), S. 127–140, DOI: 10.1016/0167-5877(90)90006-4
- Karimi, M.T.; Ghorbani, G.R.; Kargar, S.; Drackley, J.K. (2015): Late-gestation heat stress abatement on performance and behavior of Holstein dairy cows. *Journal of Dairy Science* 98(10), S. 6865–6875, DOI: 10.3168/jds.2014-9281
- Kaufman, E.I.; Asselstine, V.H.; LeBlanc, S.J.; Duffield, T.F.; DeVries, T.J. (2018): Association of rumination time and health status with milk yield and composition in early-lactation dairy cows. *Journal of Dairy Science* 101(1), S. 462–471, DOI: 10.3168/jds.2017-12909
- Keckeis, K.; Lepschy, M.; Schöpfer, H.; Moser, L.; Troxler, J.; Palme, R. (2012): Hair cortisol. A parameter of chronic stress? Insights from a radiometabolism study in guinea pigs. *Journal of Comparative Physiology* 182(7), S. 985–996, DOI: 10.1007/s00360-012-0674-7
- Kendall, P.E.; Nielsen, P.P.; Webster, J.R.; Verkerk, G.A.; Littlejohn, R.P.; Matthews, L.R. (2006): The effects of providing shade to lactating dairy cows in a temperate climate. *Livestock Science* 103(1-2), S. 148–157, DOI: 10.1016/j.livsci.2006.02.004
- Kendall, P.E.; Webster, J.R. (2009): Season and physiological status affects the circadian body temperature rhythm of dairy cows. *Livestock Science* 125(2-3), S. 155–160, DOI: 10.1016/j.livsci.2009.04.004
- Kerbrat, S.; Disenhaus, C. (2004): A proposition for an updated behavioural characterisation of the oestrus period in dairy cows. *Applied Animal Behaviour Science* 87(3-4), S. 223–238, DOI: 10.1016/j.applanim.2003.12.001
- Ketelaar-de Lauwere, C.; Ipema, A.; van Ouwkerk, E.; Hendriks, M.; Metz, J.; Noordhuizen, J.; Schouten, W. (1999): Voluntary automatic milking in combination with grazing of dairy cows. *Applied Animal Behaviour Science* 64(2), S. 91–109, DOI: 10.1016/S0168-1591(99)00027-1
- Keyserlingk, M.A.G. von; Rushen, J.; Passillé, A. de; Weary, D.M. (2009): Invited review. The welfare of dairy cattle - key concepts and the role of science. *Journal of Dairy Science* 92(9), S. 4101–4111, DOI: 10.3168/jds.2009-2326
- Kim, K.H.; Kim, D.-H.; Oh, Y.-K.; Lee, S.-S.; Lee, H.-J.; Kim, D.-W.; Seol, Y.-J.; Kimura, N. (2010): Productivity and energy partition of late lactation dairy cows during heat exposure. *Animal Science Journal* 81(1), S. 58–62, DOI: 10.1111/j.1740-0929.2009.00711.x
- King, M.T.M.; Dancy, K.M.; LeBlanc, S.J.; Pajor, E.A.; DeVries, T.J. (2017a): Deviations in behavior and productivity data before diagnosis of health disorders in cows milked with an automated system. *Journal of Dairy Science* 100(10), S. 8358–8371, DOI: 10.3168/jds.2017-12723
- King, M.T.M.; LeBlanc, S.J.; Pajor, E.A.; DeVries, T.J. (2017b): Cow-level associations of lameness, behavior, and milk yield of cows milked in automated systems. *Journal of Dairy Science* 100(6), S. 4818–4828, DOI: 10.3168/jds.2016-12281

- Kleine, B.; Rossmannith, W.G. (2021): *Hormone und Hormonsystem. Lehrbuch der Endokrinologie*, Springer-Verlag GmbH, Berlin [u.a.], Deutschland, 4. Aufl. ISBN 978-3-642-37092-2
- Kling-Eveillard, F.; Allain, C.; Boivin, X.; Courboulay, V.; Créach, P.; Philibert, A.; Ramonet, Y.; Hostiou, N. (2020): Farmers' representations of the effects of precision livestock farming on human-animal relationships. *Livestock Science* 238, 104057, DOI: 10.1016/j.livsci.2020.104057
- Kok, A.; Knegsel, A.T.M. van; Middelaar, C.E. van; Hogeveen, H.; Kemp, B.; Boer, I.J.M. de (2015): Technical note. Validation of sensor-recorded lying bouts in lactating dairy cows using a 2-sensor approach. *Journal of Dairy Science* 98(11), S. 7911–7916, DOI: 10.3168/jds.2015-9554
- Kovács, L.; Kézér, F.L.; Ruff, F.; Szenci, O.; Bakony, M.; Jurkovich, V. (2019): Effect of artificial shade on saliva cortisol concentrations of heat-stressed dairy calves. *Domestic Animal Endocrinology* 66, S. 43–47, DOI: 10.1016/j.domaniend.2018.09.001
- Kovács, L.; Kézér, F.L.; Szenci, O. (2016): Effect of calving process on the outcomes of delivery and postpartum health of dairy cows with unassisted and assisted calvings. *Journal of Dairy Science* 99(9), S. 7568–7573, DOI: 10.3168/jds.2016-11325
- Krieger, S.; Sattlecker, G.; Kicking, F.; Auer, W.; Drillich, M.; Iwersen, M. (2018): Prediction of calving in dairy cows using a tail-mounted tri-axial accelerometer. A pilot study. *Biosystems Engineering* 173, S. 79–84, DOI: 10.1016/j.biosystemseng.2017.11.010
- Krohn, C.C.; Munksgaard, L. (1993): Behaviour of dairy cows kept in extensive (loose housing/pasture) or intensive (tie stall) environments II. Lying and lying-down behaviour. *Applied Animal Behaviour Science* 37(1), S. 1–16, DOI: 10.1016/0168-1591(93)90066-X
- Krohn, C.C.; Munksgaard, L.; Jonassen, B. (1992): Behaviour of dairy cows kept in extensive (loose housing/pasture) or intensive (tie stall) environments I. Experimental procedure, facilities, time budgets — diurnal and seasonal conditions. *Applied Animal Behaviour Science* 34(1-2), S. 37–47, DOI: 10.1016/S0168-1591(05)80055-3
- Kull, J.A.; Proudfoot, K.L.; Pighetti, G.M.; Bewley, J.M.; O'Hara, B.F.; Donohue, K.D.; Krawczel, P.D. (2019): Effects of acute lying and sleep deprivation on the behavior of lactating dairy cows. *PloS ONE* 14(8), e0212823, DOI: 10.1371/journal.pone.0212823
- Landis, J.R.; Koch, G.G. (1977): The Measurement of Observer Agreement for Categorical Data. *Biometrics* 33(1), 159, DOI: 10.2307/2529310
- LeBlanc, S. (2010): Monitoring metabolic health of dairy cattle in the transition period. *Journal of Reproduction and Development* 56(S), 29-35, DOI: 10.1262/jrd.1056s29
- LeBlanc, S.J.; Leslie, K.E.; Duffield, T.F. (2005): Metabolic Predictors of Displaced Abomasum in Dairy Cattle. *Journal of Dairy Science* 88(1), S. 159–170, DOI: 10.3168/jds.S0022-0302(05)72674-6
- Ledgerwood, D.N.; Winckler, C.; Tucker, C.B. (2010): Evaluation of data loggers, sampling intervals, and editing techniques for measuring the lying behavior of dairy cattle. *Journal of Dairy Science* 93(11), S. 5129–5139, DOI: 10.3168/jds.2009-2945
- Lee, C.N.; Hillman, P.E. (2007): Thermal Responses of Holstein Dairy Cows on Pastures with High Solar Loads and High Winds. In: *Sixth International Dairy Housing Conference Proceeding*. Sixth International Dairy Housing Conference, 16.-18.06.2007, Minneapolis, USA, ASABE,

- DOI: 10.13031/2013.22791
- Lees, J.C.; Lees, A.M.; Gaughan, J.B. (2018): Developing a heat load index for lactating dairy cows. *Animal Production Science* 58(8), 1387, DOI: 10.1071/AN17776
- Legrand, A.L.; Keyserlingk, M.A.G. von; Weary, D.M. (2009): Preference and usage of pasture versus free-stall housing by lactating dairy cattle. *Journal of Dairy Science* 92(8), S. 3651–3658, DOI: 10.3168/jds.2008-1733
- Lehner, P.N. (1992): Sampling methods in behavior research. *Poultry Science* 71(4), S. 643–649, DOI: 10.3382/ps.0710643
- Leonard, F.C.; O'Connell, J.M.; O'Farrell, K.J. (1996): Effect of overcrowding on claw health in first-calved friesian heifers. *British Veterinary Journal* 152(4), S. 459–472, DOI: 10.1016/S0007-1935(96)80040-6
- Liboreiro, D.N.; Machado, K.S.; Silva, P.R.B.; Maturana, M.M.; Nishimura, T.K.; Brandão, A.P.; Endres, M.I.; Chebel, R.C. (2015): Characterization of peripartum rumination and activity of cows diagnosed with metabolic and uterine diseases. *Journal of Dairy Science* 98(10), S. 6812–6827, DOI: 10.3168/jds.2014-8947
- LKV Bayern e. V. (2020): Leistungsprüfung und Beratung in der Milchviehhaltung in Bayern 2020. Landeskuratorium der Erzeugerringe für tierische Veredelung in Bayern e. V. (Hg.)
- Lopez, H.; Satter, L.D.; Wiltbank, M.C. (2004): Relationship between level of milk production and estrous behavior of lactating dairy cows. *Animal Reproduction Science* 81(3-4), S. 209–223, DOI: 10.1016/j.anireprosci.2003.10.009
- Løvendahl, P.; Chagunda, M.G.G. (2010): On the use of physical activity monitoring for estrus detection in dairy cows. *Journal of Dairy Science* 93(1), S. 249–259, DOI: 10.3168/jds.2008-1721
- Lukas, J.M.; Reneau, J.K.; Wallace, R.; Hawkins, D.; Munoz-Zanzi, C. (2009): A novel method of analyzing daily milk production and electrical conductivity to predict disease onset. *Journal of Dairy Science* 92(12), S. 5964–5976, DOI: 10.3168/jds.2009-2066
- Mader, T.L.; Davis, M.S.; Brown-Brandl, T. (2006): Environmental Factors Influencing Heat Stress in Feedlot Cattle. *Journal of Animal Science* 84(9), S. 712–719, DOI: 10.2527/2006.843712x
- Mader, T.L.; Johnson, L.J.; Gaughan, J.B. (2010): A comprehensive index for assessing environmental stress in animals. *Journal of Animal Science* 88(6), S. 2153–2165, DOI: 10.2527/jas.2009-2586
- Mallonée, P.G.; Beede, D.K.; Collier, R.J.; Wilcox, C.J. (1985): Production and Physiological Responses of Dairy Cows to Varying Dietary Potassium During Heat Stress. *Journal of Dairy Science* 68(6), S. 1479–1487, DOI: 10.3168/jds.S0022-0302(85)80986-3
- Maroto Molina, F.; Pérez Marín, C.C.; Molina Moreno, L.; Agüera Buendía, E.I.; Pérez Marín, D.C. (2020): Welfare Quality® for dairy cows. Towards a sensor-based assessment. *Journal of Dairy Research* 87(S1), S. 28–33, DOI: 10.1017/S002202992000045X
- Martiskainen, P.; Järvinen, M.; Skön, J.-P.; Tiirikainen, J.; Kolehmainen, M.; Mononen, J. (2009): Cow behaviour pattern recognition using a three-dimensional accelerometer and support vector machines. *Applied Animal Behaviour Science* 119(1-2), S. 32–38, DOI: 10.1016/j.applanim.2009.03.005
- Mattachini, G.; Riva, E.; Bisaglia, C.; Pompe, J.C.A.M.; Provolo, G. (2013): Methodology for quantifying the behavioral activity of dairy cows in freestall barns. *Journal of Animal Science* 91(10), S. 4899–4907,

- DOI: 10.2527/jas.2012-5554
- Mattachini, G.; Riva, E.; Perazzolo, F.; Naldi, E.; Provolo, G. (2016): Monitoring feeding behaviour of dairy cows using accelerometers. *Journal of Agricultural Engineering* 47(1), 54, DOI: 10.4081/jae.2016.498
- Mazer, K.A.; Knickerbocker, P.L.; Kutina, K.L.; Huzzey, J.M. (2020): Changes in behavior and fecal cortisol metabolites when dairy cattle are regrouped in pairs versus individually after calving. *Journal of Dairy Science* 103(5), S. 4681–4690, DOI: 10.3168/jds.2019-17593
- McDonald, P.V.; Keyserlingk, M.A.G. von; Weary, D.M. (2020): Hot weather increases competition between dairy cows at the drinker. *Journal of Dairy Science* 103(4), S. 3447–3458, DOI: 10.3168/jds.2019-17456
- McGowan, J.E.; Burke, C.R.; Jago, J.G. (2007): Validation of a technology for objectively measuring behaviour in dairy cows and its application for oestrous detection. In: *Proceedings of the New Zealand Society of Animal Production*, S. 136–142
- McManus, C.M.; Louvandini, H.; Paim, T.P.; Silva, F.C.P.; Bernal, F.E.M. (2014): Factors affecting heat tolerance in crossbred cattle in central Brazil. *Ciência Animal Brasileira* 15(2), S. 152–158, DOI: 10.1590/1809-6891v15i28726
- Melin, M.; Pettersson, G.; Svennersten-Sjaunja, K.; Wiktorsson, H. (2007): The effects of restricted feed access and social rank on feeding behavior, ruminating and intake for cows managed in automated milking systems. *Applied Animal Behaviour Science* 107(1-2), S. 13–21, DOI: 10.1016/j.applanim.2006.09.026
- Menconi, M.E.; Grohmann, D. (2014): Model integrated of life-cycle costing and dynamic thermal simulation (MILD) to evaluate roof insulation materials for existing livestock buildings. *Energy and Buildings* 81, S. 48–58, DOI: 10.1016/j.enbuild.2014.06.005
- Metcalf, J.A.; Roberts, S.J.; Sutton, J.D. (1992): Variations in blood flow to and from the bovine mammary gland measured using transit time ultrasound and dye dilution. *Research in Veterinary Science* 53(1), S. 59–63, DOI: 10.1016/0034-5288(92)90085-G
- Metzner, M.; Heuwieser, W.; Klee, W. (1993): Die Beurteilung der Körperkondition (Body condition scoring) im Herdenmanagement. *Der praktische Tierarzt* 74(11), S. 992–998
- Meyer, U.; Everinghoff, M.; Gädeken, D.; Flachowsky, G. (2004): Investigations on the water intake of lactating dairy cows. *Livestock Production Science* 90(2-3), S. 117–121, DOI: 10.1016/j.livprodsci.2004.03.005
- Miedema, H.M.; Cockram, M.S.; Dwyer, C.M.; Macrae, A.I. (2011a): Behavioural predictors of the start of normal and dystocic calving in dairy cows and heifers. *Applied Animal Behaviour Science* 132(1-2), S. 14–19, DOI: 10.1016/j.applanim.2011.03.003
- Miedema, H.M.; Cockram, M.S.; Dwyer, C.M.; Macrae, A.I. (2011b): Changes in the behaviour of dairy cows during the 24h before normal calving compared with behaviour during late pregnancy. *Applied Animal Behaviour Science* 131(1-2), S. 8–14, DOI: 10.1016/j.applanim.2011.01.012
- Miguel-Pacheco, G.G.; Kaler, J.; Remnant, J.; Cheyne, L.; Abbott, C.; French, A.P.; Pridmore, T.P.; Huxley, J.N. (2014): Behavioural changes in dairy cows with lameness in an automatic milking system. *Applied Animal Behaviour Science* 150, S. 1–8, DOI: 10.1016/j.applanim.2013.11.003
- Minegishi, K.; Heins, B.J.; Pereira, G.M. (2019): Peri-estrus activity and rumination time and its application to estrus prediction. Evidence from dairy

- herds under organic grazing and low-input conventional production. *Livestock Science* 221, S. 144–154, DOI: 10.1016/j.livsci.2019.02.003
- Mitlöhner, F.M.; Morrow-Tesch, J.L.; Wilson, S.C.; Dailey, J.W.; McGlone, J.J. (2001): Behavioral sampling techniques for feedlot cattle. *Journal of Animal Science* 79(5), S. 1189–1193, DOI: 10.2527/2001.7951189x
- Molfino, J.; Clark, C.E.F.; Kerrisk, K.L.; García, S.C. (2017): Evaluation of an activity and rumination monitor in dairy cattle grazing two types of forages. *Animal Production Science* 57(7), S. 1557–1562, DOI: 10.1071/AN16514
- Mondaca, M.R. (2019): Ventilation Systems for Adult Dairy Cattle. *Veterinary Clinics of North America: Food Animal Practice* 35(1), S. 139–156, DOI: 10.1016/j.cvfa.2018.10.006
- Morrow, C.J.; Kolver, E.S.; Verkerk, G.A.; Matthews, L.R. (2000): Urinary corticosteroids: an indicator of stress in dairy cattle. In: *Proceedings of the New Zealand Society of Animal Production*, S. 218–221
- Motupalli, P.R.; Sinclair, L.A.; Charlton, G.L.; Bleach, E.C.; Rutter, S.M. (2014): Preference and behavior of lactating dairy cows given free access to pasture at two herbage masses and two distances. *Journal of Animal Science* 92(11), S. 5175–5184, DOI: 10.2527/jas.2014-8046
- Müller, R.; Schrader, L. (2003): A new method to measure behavioural activity levels in dairy cows. *Applied Animal Behaviour Science* 83(4), S. 247–258, DOI: 10.1016/S0168-1591(03)00141-2
- Munksgaard, L.; Løvendahl, P. (1993): Effects of social and physical stressors on growth hormone levels in dairy cows. *Canadian Journal of Animal Science* 73(4), S. 847–853, DOI: 10.4141/cjas93-087
- Munksgaard, L.; Ternman, E.; Veissier, I.; Duthie, C.-A.; Baumont, R. (2020): Lying, standing, and eating behaviour. In: *Methods in cattle physiology and behaviour - Recommendations from the SmartCow consortium*. Hg. Mesgaran, S.D.; Baumont, R. et al., Cologne, PUBLISSO
- Müschner-Siemens, T.; Hoffmann, G.; Ammon, C.; Amon, T. (2020): Daily rumination time of lactating dairy cows under heat stress conditions. *Journal of Thermal Biology* 88, 102484, DOI: 10.1016/j.jtherbio.2019.102484
- Naguib, M.; Krause, E.T. (2020): *Methoden der Verhaltensbiologie*, Springer-Verlag GmbH, Berlin [u.a.], Deutschland. ISBN 978-3-662-60415-1
- National Research Council (U.S.) (Hg.) (1971): *A guide to environmental research on animals*, Washington, National Academy of Sciences
- Navarro, G.; Green, L.E.; Tadich, N. (2013): Effect of lameness and lesion specific causes of lameness on time budgets of dairy cows at pasture and when housed. *Veterinary Journal* 197(3), S. 788–793, DOI: 10.1016/j.tvjl.2013.05.012
- Navrátil, S.; Falta, D.; Chládek, G. (2017): Effect of Temperature Cumulation on Milk Yield of Czech Fleckvieh-Simmental Cattle. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis* 65(5), S. 1579–1584, DOI: 10.11118/actaun201765051579
- Neave, H.W.; Lomb, J.; Keyserlingk, M.A.G. von; Behnam-Shabahang, A.; Weary, D.M. (2017): Parity differences in the behavior of transition dairy cows. *Journal of Dairy Science* 100(1), S. 548–561, DOI: 10.3168/jds.2016-10987
- Nechanitzky, K.; Starke, A.; Vidondo, B.; Müller, H.; Reckardt, M.; Friedli, K.; Steiner, A. (2016): Analysis of behavioral changes in dairy cows associated with claw horn lesions. *Journal of Dairy Science* 99(4), S. 2904–2914, DOI: 10.3168/jds.2015-10109
- Nielsen, B.L.; Veerkamp, R.F.; Lawrence, A.B. (2000): Effects of Genotype, Feed

- Type and Lactational Stage on the Time Budget of Dairy Cows. *Acta Agriculturae Scandinavica, Section A - Animal Science* 50(4), S. 272–278, DOI: 10.1080/090647000750069467
- Nielsen, P.P. (2013): Automatic registration of grazing behaviour in dairy cows using 3D activity loggers. *Applied Animal Behaviour Science* 148(3-4), S. 179–184, DOI: 10.1016/j.applanim.2013.09.001
- Nielsen, P.P.; Fontana, I.; Sloth, K.H.; Guarino, M.; Blokhuis, H. (2018): Technical note. Validation and comparison of 2 commercially available activity loggers. *Journal of Dairy Science* 101(6), S. 5449–5453, DOI: 10.3168/jds.2017-13784
- Nikkhah, A.; Furedi, C.J.; Kennedy, A.D.; Scott, S.L.; Wittenberg, K.M.; Crow, G.H.; Plaizier, J.C. (2011): Morning vs. evening feed delivery for lactating dairy cows. *Canadian Journal of Animal Science* 91(1), S. 113–122, DOI: 10.4141/CJAS10012
- Nishida, T.; Hosoda, K.; Matsuyama, H.; Ishida, M. (2004): Effect of Lying Behavior on Uterine Blood Flow in Cows During the Third Trimester of Gestation. *Journal of Dairy Science* 87(8), S. 2388–2392, DOI: 10.3168/jds.S0022-0302(04)73360-3
- Nordlund, K.V.; Strassburg, P.; Bennett, T.B.; Oetzel, G.R.; Cook, N.B. (2019): Thermodynamics of standing and lying behavior in lactating dairy cows in freestall and parlor holding pens during conditions of heat stress. *Journal of Dairy Science* 102(7), S. 6495–6507, DOI: 10.3168/jds.2018-15891
- Norring, M.; Valros, A. (2016): The effect of lying motivation on cow behaviour. *Applied Animal Behaviour Science* 176, S. 1–5, DOI: 10.1016/j.applanim.2015.11.022
- Norring, M.; Valros, A.; Munksgaard, L. (2012): Milk yield affects time budget of dairy cows in tie-stalls. *Journal of Dairy Science* 95(1), S. 102–108, DOI: 10.3168/jds.2010-3458
- O'Driscoll, K.; Lewis, E.; Kennedy, E. (2015): Effect of feed allowance at pasture on lying behaviour and locomotory ability of dairy cows. *Applied Animal Behaviour Science* 166, S. 25–34, DOI: 10.1016/j.applanim.2015.02.008
- O'Driscoll, K.; Lewis, E.; Kennedy, E. (2019): Effect of feed allowance at pasture on the lying behaviour of dairy cows. *Applied Animal Behaviour Science* 213, S. 40–46, DOI: 10.1016/j.applanim.2019.02.002
- O'Connell, J.; Giller, P.S.; Meaney, W. (1989): A Comparison of Dairy Cattle Behavioural Patterns at Pasture and during Confinement. *Irish Journal of Agricultural Research* 28(1), S. 65–72
- Olmos, G.; Boyle, L.; Hanlon, A.; Patton, J.; Murphy, J.J.; Mee, J.F. (2009): Hoof disorders, locomotion ability and lying times of cubicle-housed compared to pasture-based dairy cows. *Livestock Science* 125(2-3), S. 199–207, DOI: 10.1016/j.livsci.2009.04.009
- Ortiz, X.A.; Smith, J.F.; Rojano, F.; Choi, C.Y.; Bruer, J.; Steele, T.; Schuring, N.; Allen, J.; Collier, R.J. (2015): Evaluation of conductive cooling of lactating dairy cows under controlled environmental conditions. *Journal of Dairy Science* 98(3), S. 1759–1771, DOI: 10.3168/jds.2014-8583
- Osborne, V.R.; Hacker, R.R.; McBride, B.W. (2002): Effects of heated drinking water on the production responses of lactating Holstein and Jersey cows. *Canadian Journal of Animal Science* 82(3), S. 267–273, DOI: 10.4141/A01-055
- Osei-Amponsah, R.; Dunshea, F.R.; Leury, B.J.; Cheng, L.; Cullen, B.; Joy, A.; Abhijith, A.; Zhang, M.H.; Chauhan, S.S. (2020): Heat Stress Impacts on Lactating Cows Grazing Australian Summer Pastures on an Automatic

- Robotic Dairy. *Animals* 10(5), 869, DOI: 10.3390/ani10050869
- Oshiro, T.M.; Perez, P.S.; Baranauskas, J.A. (2012): How Many Trees in a Random Forest? In: *Machine Learning and Data Mining in Pattern Recognition*. 8th International Conference MLDM, 13.-20. Juli 2012, Berlin, Springer-Verlag GmbH, S. 154–168, DOI: 10.1007/978-3-642-31537-4\_13
- Oudshoorn, F.W.; Cornou, C.; Hellwing, A.; Hansen, H.H.; Munksgaard, L.; Lund, P.; Kristensen, T. (2013): Estimation of grass intake on pasture for dairy cows using tightly and loosely mounted di- and tri-axial accelerometers combined with bite count. *Computers and Electronics in Agriculture* 99, S. 227–235, DOI: 10.1016/j.compag.2013.09.013
- Ouellet, V.; Vasseur, E.; Heuwieser, W.; Burfeind, O.; Maldague, X.; Charbonneau, É. (2016): Evaluation of calving indicators measured by automated monitoring devices to predict the onset of calving in Holstein dairy cows. *Journal of Dairy Science* 99(2), S. 1539–1548, DOI: 10.3168/jds.2015-10057
- Owens, J.L.; Edey, T.N.; Bindon, B.M.; Piper, L.R. (1985): Parturient behaviour and calf survival in a herd selected for twinning. *Applied Animal Behaviour Science* 13(4), S. 321–333, DOI: 10.1016/0168-1591(85)90012-7
- Pahl, C.; Hartung, E.; Grothmann, A.; Mahlkow-Nerge, K.; Haeussermann, A. (2014): Rumination activity of dairy cows in the 24 hours before and after calving. *Journal of Dairy Science* 97(11), S. 6935–6941, DOI: 10.3168/jds.2014-8194
- Pakari, A.; Ghani, S. (2021): Comparison of different mechanical ventilation systems for dairy cow barns. CFD simulations and field measurements. *Computers and Electronics in Agriculture* 186, 106207, DOI: 10.1016/j.compag.2021.106207
- Palme, R. (2012): Monitoring stress hormone metabolites as a useful, non-invasive tool for welfare assessment in farm animals. *Animal Welfare* 21(3), S. 331–337, DOI: 10.7120/09627286.21.3.331
- Palme, R.; Fischer, P.; Schildorfer, H.; Ismail, M.N. (1996): Excretion of infused 14 C-steroid hormones via faeces and urine in domestic livestock. *Animal Reproduction Science* 43(1), S. 43–46, DOI: 10.1016/0378-4320(95)01458-6
- Palme, R.; Rettenbacher, S.; Touma, C.; El-Bahr, S.M.; Möstl, E. (2005): Stress hormones in mammals and birds: comparative aspects regarding metabolism, excretion, and noninvasive measurement in fecal samples. *Annals of the New York Academy of Sciences* 1040, S. 162–171, DOI: 10.1196/annals.1327.021
- Palme, R.; Robia, C.; Messmann, S.; Hofer, J.; Möstl, E. (1999): Measurement of faecal cortisol metabolites in ruminants: a non-invasive parameter of adrenocortical function. *Wiener Tierärztliche Wochenschrift* (86), S. 237–241
- Palmer, M.A.; Olmos, G.; Boyle, L.A.; Mee, J.F. (2012): A comparison of the estrous behavior of Holstein-Friesian cows when cubicle-housed and at pasture. *Theriogenology* 77(2), S. 382–388, DOI: 10.1016/j.theriogenology.2011.08.010
- Palo, P. de; Tateo, A.; Zezza, F.; Corrente, M.; Centoducati, P. (2006): Influence of Free-Stall Flooring on Comfort and Hygiene of Dairy Cows During Warm Climatic Conditions. *Journal of Dairy Science* 89(12), S. 4583–4595, DOI: 10.3168/jds.S0022-0302(06)72508-5
- Palombi, C.; Paolucci, M.; Stradaioli, G.; Corubolo, M.; Pascolo, P.B.; Monaci, M. (2013): Evaluation of remote monitoring of parturition in dairy cattle as a new tool for calving management. *BMC Veterinary Research* 9, 191, DOI: 10.1186/1746-6148-9-191
- Pastell, M.; Aisla, A.M.; Hautala, M.; Poikalainen, V.; Praks, J.; Veermäe, I.;

- Ahokas, J. (2006): Contactless measurement of cow behavior in a milking robot. *Behavior Research Methods* 38(3), S. 479–486, DOI: 10.3758/bf03192802
- Pavlenko, A.; Bergsten, C.; Ekesbo, I.; Kaart, T.; Aland, A.; Lidfors, L. (2011): Influence of digital dermatitis and sole ulcer on dairy cow behaviour and milk production. *Animal* 5(8), S. 1259–1269, DOI: 10.1017/S1751731111000255
- Peng, D.; Chen, S.; Li, G.; Chen, J.; Wang, J.; Gu, X. (2019): Infrared thermography measured body surface temperature and its relationship with rectal temperature in dairy cows under different temperature-humidity indexes. *International Journal of Biometeorology* 63(3), S. 327–336, DOI: 10.1007/s00484-018-01666-x
- Pereira, G.M.; Heins, B.J.; O'Brien, B.; McDonagh, A.; Lidauer, L.; Kicking, F. (2020): Validation of an ear tag-based accelerometer system for detecting grazing behavior of dairy cows. *Journal of Dairy Science* 103(4), S. 3529–3544, DOI: 10.3168/jds.2019-17269
- Pereira, G.M.; Sharpe, K.T.; Heins, B.J. (2021): Evaluation of the RumiWatch system as a benchmark to monitor feeding and locomotion behaviors of grazing dairy cows. *Journal of Dairy Science* 104(3), S. 3736–3750, DOI: 10.3168/jds.2020-18952
- Pérez-Ramírez, E.; Peyraud, J.L.; Delagarde, R. (2009): Restricting daily time at pasture at low and high pasture allowance. Effects on pasture intake and behavioral adaptation of lactating dairy cows. *Journal of Dairy Science* 92(7), S. 3331–3340, DOI: 10.3168/jds.2008-1951
- Pesenhofer, G.; Palme, R.; Pesenhofer, R.M.; Kofler, J. (2006): Comparison of two methods of fixation during functional claw trimming - walk-in crush versus tilt table - in dairy cows using faecal cortisol metabolite concentrations and daily milk yield as parameters. *Wiener Tierärztliche Mittheilung* 93(11), S. 288–294
- Phillips, C.; Leaver, J.D. (1986): The effect of forage supplementation on the behaviour of grazing dairy cows. *Applied Animal Behaviour Science* 16(3), S. 233–247, DOI: 10.1016/0168-1591(86)90116-4
- Phillips, C.; Morris, I.D. (2001): The Locomotion of Dairy Cows on Floor Surfaces with Different Frictional Properties. *Journal of Dairy Science* 84(3), S. 623–628, DOI: 10.3168/jds.S0022-0302(01)74517-1
- Phillips, C.; Rind, M.I. (2002): The Effects of Social Dominance on the Production and Behavior of Grazing Dairy Cows Offered Forage Supplements. *Journal of Dairy Science* 85(1), S. 51–59, DOI: 10.3168/jds.S0022-0302(02)74052-6
- Piñeiro, J.M.; Menichetti, B.T.; Barragan, A.A.; Relling, A.E.; Weiss, W.P.; Bas, S.; Schuenemann, G.M. (2019): Associations of pre- and postpartum lying time with metabolic, inflammation, and health status of lactating dairy cows. *Journal of Dairy Science* 102(4), S. 3348–3361, DOI: 10.3168/jds.2018-15386
- Pinheiro Machado Filho, L.C.; Teixeira, D.L.; Weary, D.M.; Keyserlingk, M.A.G. von; Hötzel, M.J. (2004): Designing better water troughs: dairy cows prefer and drink more from larger troughs. *Applied Animal Behaviour Science* 89(3-4), S. 185–193, DOI: 10.1016/j.applanim.2004.07.002
- Polsky, L.; Keyserlingk, M.A.G. von (2017): Invited review. Effects of heat stress on dairy cattle welfare. *Journal of Dairy Science* 100(11), S. 8645–8657, DOI: 10.3168/jds.2017-12651
- Potter, T.L.; Arndt, C.; Hristov, A.N. (2018): Short communication. Increased somatic cell count is associated with milk loss and reduced feed efficiency in lactating dairy cows. *Journal of Dairy Science* 101(10), S. 9510–9515,

- DOI: 10.3168/jds.2017-14062
- Prendiville, R.; Lewis, E.; Pierce, K.M.; Buckley, F. (2010): Comparative grazing behavior of lactating Holstein-Friesian, Jersey, and Jersey x Holstein-Friesian dairy cows and its association with intake capacity and production efficiency. *Journal of Dairy Science* 93(2), S. 764–774, DOI: 10.3168/jds.2009-2659
- Purwanto, B.P.; Abo, Y.; Sakamoto, R.; Furumoto, F.; Yamamoto, S. (1990): Diurnal patterns of heat production and heart rate under thermoneutral conditions in Holstein Friesian cows differing in milk production. *The Journal of Agricultural Science* 114(2), S. 139–142, DOI: 10.1017/S0021859600072117
- Ragsdale, A.C.; Thompson, H.J.; Worstell, D.M.; Brody, S. (1950): *Environmental Physiology. IX. Milk Production and Feed and Water Consumption Responses of Brahman, Jersey, and Holstein Cows to Changes in Temperature, 50° to 105° F. and 50° to 8° F. With Special Reference to Domestic Animals. Research Bulletin 460, Columbia, USA. Missouri Agricultural Experiment Station (Hg.)*
- Ragsdale, A.C.; Thompson, H.J.; Worstell, D.M.; Brody, S. (1953): *Environmental Physiology and Shelter Engineering. XXI. The Effect of Humidity on Milk Production and Composition, Feed and Water Consumption, and Body Weight in Cattle. With Special Reference to Domestic Animals. Research Bulletin 521, Columbia, USA. Missouri Agricultural Experiment Station; United States Department of Agriculture Cooperating (Hg.)*
- Rahman, A.; Smith, D.; Hills, J.; Bishop-Hurley, G.; Henry, D.; Rawnsley, R. (2016): A comparison of autoencoder and statistical features for cattle behaviour classification. In: 2016 International Joint Conference on Neural Networks (IJCNN). 2016 International Joint Conference on Neural Networks (IJCNN), 24.-29.07.2016, Vancouver, Canada, S. 2954–2960, DOI: 10.1109/IJCNN.2016.7727573
- Rahman, A.; Smith, D.V.; Little, B.; Ingham, A.B.; Greenwood, P.L.; Bishop-Hurley, G.J. (2018): Cattle behaviour classification from collar, halter, and ear tag sensors. *Information Processing in Agriculture* 5(1), S. 124–133, DOI: 10.1016/j.inpa.2017.10.001
- Rashid, S.A.; Tomar, A.K.S.; Verma, M.R.; Mehrotra, S.; Bharti, P.K. (2019): Effect of skin and coat characteristics on growth and milk production traits in Tharparkar cattle. *Indian Journal of Animal Science* 89(11), S. 1251–1254
- Rees, A.; Fischer-Tenhagen, C.; Heuwieser, W. (2016): Effect of Heat Stress on Concentrations of Faecal Cortisol Metabolites in Dairy Cows. *Reproduction in Domestic Animals* 51(3), S. 392–399, DOI: 10.1111/rda.12691
- Reinhardt, T.A.; Horst, R.L.; Goff, J.P. (1988): Calcium, Phosphorus, and Magnesium Homeostasis in Ruminants. *Veterinary Clinics of North America: Food Animal Practice* 4(2), S. 331–350, DOI: 10.1016/S0749-0720(15)31052-5
- Reiter, S.; Sattlecker, G.; Lidauer, L.; Kickinger, F.; Öhlschuster, M.; Auer, W.; Schweinzer, V.; Klein-Jöbstl, D.; Drillich, M.; Iwersen, M. (2018): Evaluation of an ear-tag-based accelerometer for monitoring rumination in dairy cows. *Journal of Dairy Science* 101(4), S. 3398–3411, DOI: 10.3168/jds.2017-12686
- Reith, S.; Hoy, S. (2012): Relationship between daily rumination time and estrus of dairy cows. *Journal of Dairy Science* 95(11), S. 6416–6420, DOI: 10.3168/jds.2012-5316
- Renaudeau, D.; Collin, A.; Yahav, S.; Basilio, V. de; Gourdine, J.L.; Collier, R.J. (2012): Adaptation to hot climate and strategies to alleviate heat stress in livestock production. *Animal* 6(5), S. 707–728,

- DOI: 10.1017/S1751731111002448
- Reuter, R.R.; Carroll, J.A.; Hulbert, L.E.; Dailey, J.W.; Galyean, M.L. (2010): Technical note. Development of a self-contained, indwelling rectal temperature probe for cattle research. *Journal of Animal Science* 88(10), S. 3291–3295, DOI: 10.2527/jas.2010-3093
- Riaboff, L.; Poggi, S.; Madouasse, A.; Couvreur, S.; Aubin, S.; Bédère, N.; Goumand, E.; Chauvin, A.; Plantier, G. (2020): Development of a methodological framework for a robust prediction of the main behaviours of dairy cows using a combination of machine learning algorithms on accelerometer data. *Computers and Electronics in Agriculture* 169, 105179, DOI: 10.1016/j.compag.2019.105179
- Rish, I. (2001): An empirical study of the naive Bayes classifier. In: *Proceedings of the Seventeenth International Joint Conference of Artificial Intelligence. Seventeenth International Joint Conference on Artificial Intelligence, 04.-10.08.2001, Seattle, USA*
- Rodtian, P.; King, G.; Subrod, S.; Pongpiachan, P. (1996): Oestrous behaviour of Holstein cows during cooler and hotter tropical seasons. *Animal Reproduction Science* 45(1-2), S. 47–58, DOI: 10.1016/S0378-4320(96)01576-X
- Roelofs, J.B.; Broek, C. vd; Dam, L. van; Karnstra, M.; Daniëls, M.; Van Erp-Van der Kooij, E. (2019): Performance of an in-cow sensor for estrus detection in dairy cattle during grazing season. In: *Proceedings of the 2nd International Precision Dairy Farming Conference. Conference on Precision Dairy Farming, 18.-20.06.2019, Rochester, Minnesota, USA, S. 27–28*
- Roelofs, J.B.; Eerdenburg, F.J.C.M. van; Soede, N.M.; Kemp, B. (2005): Various behavioral signs of estrous and their relationship with time of ovulation in dairy cattle. *Theriogenology* 63(5), S. 1366–1377, DOI: 10.1016/j.theriogenology.2004.07.009
- Rombach, M.; Münger, A.; Niederhauser, J.; Südekum, K.-H.; Schori, F. (2018): Evaluation and validation of an automatic jaw movement recorder (RumiWatch) for ingestive and rumination behaviors of dairy cows during grazing and supplementation. *Journal of Dairy Science* 101(3), S. 2463–2475, DOI: 10.3168/jds.2016-12305
- Rook, A.J.; Huckle, C.A. (1997): Activity bout criteria for grazing dairy cows. *Applied Animal Behaviour Science* 54(2-3), S. 89–96, DOI: 10.1016/S0168-1591(97)00065-8
- Ruckebusch, Y. (1972): The relevance of drowsiness in the circadian cycle of farm animals. *Animal Behaviour* 20(4), S. 637–643, DOI: 10.1016/S0003-3472(72)80136-2
- Ruckebusch, Y. (1974): Sleep deprivation in cattle. *Brain Research* 78(3), S. 495–499, DOI: 10.1016/0006-8993(74)90932-9
- Rulquin, H.; Caudal, J.P. (1992): Effects of lying or standing on mammary blood flow and heart rate of dairy cows. *Annales de Zootechnie* 41(1), 101, DOI: 10.1051/animres:19920155
- Ruuska, S.; Kajava, S.; Mughal, M.; Zehner, N.; Mononen, J. (2016): Validation of a pressure sensor-based system for measuring eating, rumination and drinking behaviour of dairy cattle. *Applied Animal Behaviour Science* 174, S. 19–23, DOI: 10.1016/j.applanim.2015.11.005
- Safavian, S.R.; Landgrebe, D. (1991): A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man, and Cybernetics* 21(3), S. 660–674, DOI: 10.1109/21.97458
- Sanders, A.H.; Shearer, J.K.; Vries, A. de (2009): Seasonal incidence of lameness and risk factors associated with thin soles, white line disease, ulcers, and sole

- punctures in dairy cattle. *Journal of Dairy Science* 92(7), S. 3165–3174, DOI: 10.3168/jds.2008-1799
- Scheibe, K.M.; Gromann, C. (2006): Application testing of a new three-dimensional acceleration measuring system with wireless data transfer (WAS) for behavior analysis. *Behavior Research Methods* 38(3), S. 427–433, DOI: 10.3758/BF03192796
- Schirmann, K.; Chapinal, N.; Weary, D.M.; Heuwieser, W.; Keyserlingk, M.A.G. von (2011): Short-term effects of regrouping on behavior of prepartum dairy cows. *Journal of Dairy Science* 94(5), S. 2312–2319, DOI: 10.3168/jds.2010-3639
- Schirmann, K.; Chapinal, N.; Weary, D.M.; Heuwieser, W.; Keyserlingk, M.A.G. von (2012): Rumination and its relationship to feeding and lying behavior in Holstein dairy cows. *Journal of Dairy Science* 95(6), S. 3212–3217, DOI: 10.3168/jds.2011-4741
- Schirmann, K.; Chapinal, N.; Weary, D.M.; Vickers, L.; Keyserlingk, M.A.G. von (2013): Short communication. Rumination and feeding behavior before and after calving in dairy cows. *Journal of Dairy Science* 96(11), S. 7088–7092, DOI: 10.3168/jds.2013-7023
- Schirmann, K.; Keyserlingk, M.A.G. von; Weary, D.M.; Veira, D.M.; Heuwieser, W. (2009): Technical note. Validation of a system for monitoring rumination in dairy cows. *Journal of Dairy Science* 92(12), S. 6052–6055, DOI: 10.3168/jds.2009-2361
- Schirmann, K.; Weary, D.M.; Heuwieser, W.; Chapinal, N.; Cerri, R.L.A.; Keyserlingk, M.A.G. von (2016): Short communication. Rumination and feeding behaviors differ between healthy and sick dairy cows during the transition period. *Journal of Dairy Science* 99(12), S. 9917–9924, DOI: 10.3168/jds.2015-10548
- Schmeling, L.; Elmamooz, G.; Hoang, P.T.; Kozar, A.; Nicklas, D.; Sünkel, M.; Thurner, S.; Rauch, E. (2021a): Training and Validating a Machine Learning Model for the Sensor-based Monitoring of Lying Behavior in Dairy Cows on Pasture and in the Barn. *Animals* 11(9), 2660, DOI: 10.3390/ani11092660
- Schmeling, L.; Elmamooz, G.; Nicklas, D.; Rauch, E.; Thurner, S. (2021b): Evaluation of a sensor-based system for monitoring rumination in dairy cows with access to pasture. In: *EurAgEng 2021 Conference*. EurAgEng 2021, 05.-08.07.2021, Online, S. 154–155
- Schmeling, L.; Thurner, S.; Nicklas, D.; Erhard, M.; Rauch, E. (2021c): Automated detection of grazing behaviour with a collar-based monitoring system. In: *Sensing - New Insights into Grassland and Science and Practice*. 21st Symposium of the European Grassland Federation, Universität Kassel, Grassland Science and Renewable Plant Resources, 17.-19.05.2021, Online, S. 193–195
- Schneider, P.L.; Beede, D.K.; Wilcox, C.J. (1986): Responses of Lactating Cows to Dietary Sodium Source and Quantity and Potassium Quantity During Heat Stress. *Journal of Dairy Science* 69(1), S. 99–110, DOI: 10.3168/jds.S0022-0302(86)80374-5
- Schuenemann, G.M.; Nieto, I.; Bas, S.; Galvão, K.N.; Workman, J. (2011): Assessment of calving progress and reference times for obstetric intervention during dystocia in Holstein dairy cows. *Journal of Dairy Science* 94(11), S. 5494–5501, DOI: 10.3168/jds.2011-4436
- Schüller, L.K.; Burfeind, O.; Heuwieser, W. (2014): Impact of heat stress on conception rate of dairy cows in the moderate climate considering different temperature-humidity index thresholds, periods relative to breeding, and heat

- load indices. *Theriogenology* 81(8), S. 1050–1057,  
DOI: 10.1016/j.theriogenology.2014.01.029
- Schütz, K.E.; Cox, N.R.; Matthews, L.R. (2008): How important is shade to dairy cattle? Choice between shade or lying following different levels of lying deprivation. *Applied Animal Behaviour Science* 114(3-4), S. 307–318,  
DOI: 10.1016/j.applanim.2008.04.001
- Schütz, K.E.; Rogers, A.R.; Cox, N.R.; Tucker, C.B. (2009): Dairy cows prefer shade that offers greater protection against solar radiation in summer: Shade use, behaviour, and body temperature. *Applied Animal Behaviour Science* 116(1), S. 28–34, DOI: 10.1016/j.applanim.2008.07.005
- Schütz, K.E.; Rogers, A.R.; Cox, N.R.; Webster, J.R.; Tucker, C.B. (2011): Dairy cattle prefer shade over sprinklers. Effects on behavior and physiology. *Journal of Dairy Science* 94(1), S. 273–283, DOI: 10.3168/jds.2010-3608
- Schütz, K.E.; Rogers, A.R.; Poulouin, Y.A.; Cox, N.R.; Tucker, C.B. (2010): The amount of shade influences the behavior and physiology of dairy cattle. *Journal of Dairy Science* 93(1), S. 125–133, DOI: 10.3168/jds.2009-2416
- Schweinzer, V.; Gusterer, E.; Kanz, P.; Krieger, S.; Süß, D.; Lidauer, L.; Berger, A.; Kicking, F.; Öhlschuster, M.; Auer, W.; Drillich, M.; Iwersen, M. (2019): Evaluation of an ear-attached accelerometer for detecting estrus events in indoor housed dairy cows. *Theriogenology* 130, S. 19–25,  
DOI: 10.1016/j.theriogenology.2019.02.038
- Sepúlveda-Varas, P.; Lomb, J.; Keyserlingk, M.A.G. von; Held, R.; Bustamante, H.; Tadich, N. (2018): Claw horn lesions in mid-lactation primiparous dairy cows under pasture-based systems. Association with behavioral and metabolic changes around calving. *Journal of Dairy Science* 101(10), S. 9439–9450,  
DOI: 10.3168/jds.2018-14674
- Sepúlveda-Varas, P.; Proudfoot, K.L.; Weary, D.M.; Keyserlingk, M.A.G. von (2016): Changes in behaviour of dairy cows with clinical mastitis. *Applied Animal Behaviour Science* 175, S. 8–13,  
DOI: 10.1016/j.applanim.2014.09.022
- Sepúlveda-Varas, P.; Weary, D.M.; Keyserlingk, M.A.G. von (2014): Lying behavior and postpartum health status in grazing dairy cows. *Journal of Dairy Science* 97(10), S. 6334–6343, DOI: 10.3168/jds.2014-8357
- Sgorlon, S.; Fanzago, M.; Guiatti, D.; Gabai, G.; Stradaoli, G.; Stefanon, B. (2015): Factors affecting milk cortisol in mid lactating dairy cows. *BMC Veterinary Research* 11, 259, DOI: 10.1186/s12917-015-0572-9
- Shalloo, L.; Cromie, A.; McHugh, N. (2014): Effect of fertility on the economics of pasture-based dairy systems. *Animal* 8(s1), S. 222–231,  
DOI: 10.1017/S1751731114000615
- Sheahan, A.J.; Gibbs, S.J.; Roche, J.R. (2013): Timing of supplementation alters grazing behavior and milk production response in dairy cows. *Journal of Dairy Science* 96(1), S. 477–483, DOI: 10.3168/jds.2012-5781
- Shehab-El-Deen, M.A.M.M.; Fadel, M.S.; Soom, A. van; Saleh, S.Y.; Maes, D.; Leroy, J.L.M.R. (2010): Circadian rhythm of metabolic changes associated with summer heat stress in high-producing dairy cattle. *Tropical Animal Health and Production* 42(6), S. 1119–1125, DOI: 10.1007/s11250-010-9534-1
- Shepard, E.L.; Wilson, R.P.; Quintana, F.; Gómez Laich, A.; Liebsch, N.; Albareda, D.A.; Halsey, L.G.; Gleiss, A.; Morgan, D.T.; Myers, A.E.; Newman, C.; McDonald, D.W. (2010): Identification of animal movement patterns using tri-axial accelerometry. *Endangered Species Research* 10, S. 47–60, DOI: 10.3354/esr00084

- Sheriff, M.J.; Dantzer, B.; Delehanty, B.; Palme, R.; Boonstra, R. (2011): Measuring stress in wildlife. Techniques for quantifying glucocorticoids. *Oecologia* 166(4), S. 869–887, DOI: 10.1007/s00442-011-1943-y
- Shoshani, E.; Hetzroni, A. (2013): Optimal barn characteristics for high-yielding Holstein cows as derived by a new heat-stress model. *Animal* 7(1), S. 176–182, DOI: 10.1017/S1751731112001085
- Shu, H.; Wang, W.; Guo, L.; Bindelle, J. (2021): Recent Advances on Early Detection of Heat Strain in Dairy Cows Using Animal-Based Indicators. A Review. *Animals* 11(4), 980, DOI: 10.3390/ani11040980
- Siivonen, J.; Taponen, S.; Hovinen, M.; Pastell, M.; Lensink, B.J.; Pyörälä, S.; Hänninen, L. (2011): Impact of acute clinical mastitis on cow behaviour. *Applied Animal Behaviour Science* 132(3-4), S. 101–106, DOI: 10.1016/j.applanim.2011.04.005
- Silva, R.G. da; Morais, D.A.E.F.; Guilhermino, M.M. (2007): Evaluation of thermal stress indexes for dairy cows in tropical regions. *Revista Brasileira de Zootecnia* 36(4), S. 1192–1198, DOI: 10.1590/S1516-35982007000500028
- Simon, J.; Bauhofer, B.; Geischeder, S.; Oberhardt, F.; Stötzel, P. (2018): Sommerlicher Hitzeschutz und Außenklimareize. Besondere Herausforderungen an den Bau eines Milchviehstalls. In: *Milchviehhaltung - Lösungen für die Zukunft. Landtechnisch-bauliche Jahrestagung 2018*, Bayerische Landesanstalt für Landwirtschaft (LfL), 29.11.2018, Grub, Deutschland, S. 61–63
- Sjöström, K.; Fall, N.; Blanco-Penedo, I.; Duval, J.E.; Krieger, M.; Emanuelson, U. (2018): Lameness prevalence and risk factors in organic dairy herds in four European countries. *Livestock Science* 208, S. 44–50, DOI: 10.1016/j.livsci.2017.12.009
- Smid, A.M.C.; Burgers, E.E.A.; Weary, D.M.; Bokkers, E.A.M.; Keyserlingk, M.A.G. von (2019): Dairy cow preference for access to an outdoor pack in summer and winter. *Journal of Dairy Science* 102(2), S. 1551–1558, DOI: 10.3168/jds.2018-15007
- Smith, D.; Rahman, A.; Bishop-Hurley, G.J.; Hills, J.; Shahriar, S.; Henry, D.; Rawnsley, R. (2016): Behavior classification of cows fitted with motion collars. Decomposing multi-class classification into a set of binary problems. *Computers and Electronics in Agriculture* 131(164), S. 40–50, DOI: 10.1016/j.compag.2016.10.006
- Soriani, N.; Panella, G.; Calamari, L. (2013): Rumination time during the summer season and its relationships with metabolic conditions and milk production. *Journal of Dairy Science* 96(8), S. 5082–5094, DOI: 10.3168/jds.2013-6620
- Sousa, K.T. de; Deniz, M.; Moro, M.F.; Gomes, I.C.; Vale, M.M. do; Dittrich, J.R. (2021): Developing of a model to predict lying behavior of dairy cows on silvopastoral system during the winter season. *International Journal of Biometeorology*, DOI: 10.1007/s00484-021-02121-0
- Spörndly, E.; Wredle, E. (2004): Automatic Milking and Grazing—Effects of Distance to Pasture and Level of Supplements on Milk Yield and Cow Behavior. *Journal of Dairy Science* 87(6), S. 1702–1712, DOI: 10.3168/jds.S0022-0302(04)73323-8
- Sprecher, D.J.; Hostetler, D.E.; Kaneene, J.B. (1997): A lameness scoring system that uses posture and gait to predict dairy cattle reproductive performance. *Theriogenology* 47(6), S. 1179–1187, DOI: 10.1016/S0093-691X(97)00098-8
- Srikandakmar, A.; Johnson, E.H. (2004): Effect of heat stress on milk production, rectal temperature, respiratory rate and blood chemistry in Holstein, Jersey and Australian Milking Zebu cows. *Tropical Animal Health and Production* 7(36),

- S. 685–692, DOI: 10.1023/b:trop.0000042868.76914.a9
- Stančin, S.; Tomažič, S. (2011): Angle estimation of simultaneous orthogonal rotations from 3D gyroscope measurements. *Sensors* 11(9), S. 8536–8549, DOI: 10.3390/s110908536
- Stangaferro, M.L.; Wijma, R.; Caixeta, L.S.; Al-Abri, M.A.; Giordano, J.O. (2016a): Use of rumination and activity monitoring for the identification of dairy cows with health disorders. Part I. Metabolic and digestive disorders. *Journal of Dairy Science* 99(9), S. 7395–7410, DOI: 10.3168/jds.2016-10907
- Stangaferro, M.L.; Wijma, R.; Caixeta, L.S.; Al-Abri, M.A.; Giordano, J.O. (2016b): Use of rumination and activity monitoring for the identification of dairy cows with health disorders. Part II. Mastitis. *Journal of Dairy Science* 99(9), S. 7411–7421, DOI: 10.3168/jds.2016-10908
- Stangaferro, M.L.; Wijma, R.; Caixeta, L.S.; Al-Abri, M.A.; Giordano, J.O. (2016c): Use of rumination and activity monitoring for the identification of dairy cows with health disorders. Part III. Metritis. *Journal of Dairy Science* 99(9), S. 7422–7433, DOI: 10.3168/jds.2016-11352
- Statistisches Bundesamt (Destatis) (2021): Land und Forstwirtschaft, Fischerei. Viehbestand. Reihe 4.1, 3. Aufl.
- Steele, M. (2020): Age at first calving in dairy cows. Which months do you aim for to maximise productivity? *Veterinary Evidence* 5(1), DOI: 10.18849/ve.v5i1.248
- Steensels, M.; Antler, A.; Bahr, C.; Berckmans, D.; Maltz, E.; Halachmi, I. (2016): A decision-tree model to detect post-calving diseases based on rumination, activity, milk yield, BW and voluntary visits to the milking robot. *Animal* 10(9), S. 1493–1500, DOI: 10.1017/S1751731116000744
- Steinmetz, M.; Soosten, D. von; Hummel, J.; Meyer, U.; Dänicke, S. (2020): Validation of the RumiWatch Converter V0.7.4.5 classification accuracy for the automatic monitoring of behavioural characteristics in dairy cows. *Animal Nutrition* 74(2), S. 164–172, DOI: 10.1080/1745039X.2020.1721260.
- Steinwigger, A.; Gasteiner, J. (2017): 8 Tipps gegen Hitzestress bei Milchkühen. <https://landwirt-media.com/8-tipps-gegen-hitzestress-bei-milchkuehen/>, Zugriff am 16.9.2021
- Stermer, R.A.; Brasington, C.F.; Coppock, C.E.; Lanham, J.K.; Milam, K.Z. (1986): Effect of Drinking Water Temperature on Heat Stress of Dairy Cows. *Journal of Dairy Science* 69(2), S. 546–551, DOI: 10.3168/jds.S0022-0302(86)80436-2
- Stewart, R.E.; Brody, S. (1954): Environmental Physiology and Shelter Engineering. XXIX. Effect of Radiation Intensity on Hair and Skin Temperatures and on Respiration Rates of Holstein, Jersey, and Brahman Cattle. With Special Reference to Domestic Animals. Research Bulletin 561, Columbia, USA. Missouri Agricultural Experiment Station (Hg.)
- Stone, A.E. (2020): Symposium review. The most important factors affecting adoption of precision dairy monitoring technologies. *Journal of Dairy Science* 103(6), S. 5740–5745, DOI: 10.3168/jds.2019-17148
- Stone, A.E.; Jones, B.W.; Becker, C.A.; Bewley, J.M. (2017): Influence of breed, milk yield, and temperature-humidity index on dairy cow lying time, neck activity, reticulorumen temperature, and rumination behavior. *Journal of Dairy Science* 100(3), S. 2395–2403, DOI: 10.3168/jds.2016-11607
- Stringleman, H.; Scrimgeour, F. (2008): Dairying and dairy products. <http://www.TeAra.govt.nz/en/dairying-and-dairy-products>, Zugriff am 16.9.2021
- Stygar, A.H.; Gómez, Y.; Berteselli, G.V.; Dalla Costa, E.; Canali, E.; Niemi,

- J.K.; Llonch, P.; Pastell, M. (2021): A Systematic Review on Commercially Available and Validated Sensor Technologies for Welfare Assessment of Dairy Cattle. *Frontiers in Veterinary Science* 8, 634338, DOI: 10.3389/fvets.2021.634338
- Suthar, V.; Burfeind, O.; Maeder, B.; Heuwieser, W. (2013): Agreement between rectal and vaginal temperature measured with temperature loggers in dairy cows. *Journal of Dairy Research* 80(2), S. 240–245, DOI: 10.1017/S0022029913000071
- Suzuki, T.; Kamiya, Y.; Tanaka, M.; Hattori, I.; Sakaigaichi, T.; Terauchi, T.; Nonaka, I.; Terada, F. (2014): Effect of fiber content of roughage on energy cost of eating and rumination in Holstein cows. *Animal Feed Science and Technology* 196, S. 42–49, DOI: 10.1016/j.anifeedsci.2014.07.005
- Svotwa, E.; Makarau, A.; Hamudikuwanda, H. (2007): Heat tolerance of Mashona, Brahman and Simmental cattle breed under warm humid summer conditions of natural region II area of Zimbabwe. *Electronic Journal of Environmental, Agricultural and Food Chemistry* 6(4), S. 1934–1944
- Szenci, O.; Baumgartner, W.; Hejel, M.; Rózsa, L.; Kovács, L. (2020): Subacute ruminal acidosis in dairy cows - physiological background, risk factors and diagnostic methods. *Veterinarska stanica* 51(1), S. 5–17, DOI: 10.46419/vs.51.1.1
- Tapkı, İ.; Şahin, A. (2006): Comparison of the thermoregulatory behaviours of low and high producing dairy cows in a hot environment. *Applied Animal Behaviour Science* 99(1-2), S. 1–11, DOI: 10.1016/j.applanim.2005.10.003
- Telezhenko, E. (2009): Measurement of spatial gait parameters from footprints of dairy cows. *Animal* 3(12), S. 1746–1753, DOI: 10.1017/S1751731109990644
- Ternman, E.; Nilsson, E.; Nielsen, P.P.; Pastell, M.; Hänninen, L.; Agenäs, S. (2019): Rapid eye movement sleep time in dairy cows changes during the lactation cycle. *Journal of Dairy Science* 102(6), S. 5458–5465, DOI: 10.3168/jds.2018-15950
- Ternman, E.; Pastell, M.; Agenäs, S.; Strasser, C.; Winckler, C.; Nielsen, P.P.; Hänninen, L. (2014): Agreement between different sleep states and behaviour indicators in dairy cows. *Applied Animal Behaviour Science* 160, S. 12–18, DOI: 10.1016/j.applanim.2014.08.014
- Ternman, E.; Pastell, M.; Hänninen, L.; Agenäs, S.; Nielsen, P.P. (2018): First-night effect on sleep time in dairy cows. *PloS ONE* 13(4), e0195593, DOI: 10.1371/journal.pone.0195593
- Thom, E.C. (1958): Cooling degree-days. Air conditioning, heating, and ventilation, US Department of Commerce
- Thom, E.C. (1959): The Discomfort Index. *Weatherwise* 12(2), S. 57–61, DOI: 10.1080/00431672.1959.9926960
- Thorup, V.M.; Munksgaard, L.; Robert, P.-E.; Erhard, H.W.; Thomsen, P.T.; Friggens, N.C. (2015): Lameness detection via leg-mounted accelerometers on dairy cows on four commercial farms. *Animal* 9(10), S. 1704–1712, DOI: 10.1017/S1751731115000890
- Titler, M.; Maquivar, M.G.; Bas, S.; Rajala-Schultz, P.J.; Gordon, E.; McCullough, K.; Federico, P.; Schuenemann, G.M. (2015): Prediction of parturition in Holstein dairy cattle using electronic data loggers. *Journal of Dairy Science* 98(8), S. 5304–5312, DOI: 10.3168/jds.2014-9223
- Tolkamp, B.J.; Allcroft, D.J.; Austin, E.J.; Nielsen, I.; Kyriazakis, I. (1998): Satiety splits feeding behaviour into bouts. *Journal of Theoretical Biology* 194(2), S. 235–250, DOI: 10.1006/jtbi.1998.0759
- Tolkamp, B.J.; Friggens, N.C.; Emmans, G.C.; Kyriazakis, I.; Oldham, J.D.

- (2002): Meal patterns of dairy cows consuming mixed foods with a high or a low ratio of concentrate to grass silage. *Animal Science* 74(2), S. 369–382, DOI: 10.1017/S1357729800052528
- Tolkamp, B.J.; Haskell, M.J.; Langford, F.M.; Roberts, D.J.; Morgan, C.A. (2010): Are cows more likely to lie down the longer they stand? *Applied Animal Behaviour Science* 124(1-2), S. 1–10, DOI: 10.1016/j.applanim.2010.02.004
- Trevisi, E.; Zecconi, A.; Cogrossi, S.; Razzuoli, E.; Grossi, P.; Amadori, M. (2014): Strategies for reduced antibiotic usage in dairy cattle farms. *Research in Veterinary Science* 96(2), S. 229–233, DOI: 10.1016/j.rvsc.2014.01.001
- Tucker, C.B.; Cox, N.R.; Weary, D.M.; Špinka, M. (2009): Laterality of lying behaviour in dairy cattle. *Applied Animal Behaviour Science* 120(3-4), S. 125–131, DOI: 10.1016/j.applanim.2009.05.010
- Tucker, C.B.; Dalley, D.E.; Burke, J.-L.K.; Clark, D.A. (2007a): Milking cows once daily influences behavior and udder firmness at peak and mid lactation. *Journal of Dairy Science* 90(4), S. 1692–1703, DOI: 10.3168/jds.2006-577.
- Tucker, C.B.; Rogers, A.R.; Schütz, K.E. (2008): Effect of solar radiation on dairy cattle behaviour, use of shade and body temperature in a pasture-based system. *Applied Animal Behaviour Science* 109(2-4), S. 141–154, DOI: 10.1016/j.applanim.2007.03.015
- Tucker, C.B.; Rogers, A.R.; Verkerk, G.A.; Kendall, P.E.; Webster, J.R.; Matthews, L.R. (2007b): Effects of shelter and body condition on the behaviour and physiology of dairy cattle in winter. *Applied Animal Behaviour Science* 105(1-3), S. 1–13, DOI: 10.1016/j.applanim.2006.06.009
- Tucker, C.B.; Weary, D.M. (2004): Bedding on Geotextile Mattresses. How Much is Needed to Improve Cow Comfort? *Journal of Dairy Science* 87(9), S. 2889–2895, DOI: 10.3168/jds.S0022-0302(04)73419-0
- Tucker, C.B.; Weary, D.M.; Fraser, D. (2004): Free-Stall Dimensions. Effects on Preference and Stall Usage. *Journal of Dairy Science* 87(5), S. 1208–1216, DOI: 10.3168/jds.S0022-0302(04)73271-3
- Tucker, C.B.; Zdanowicz, G.; Weary, D.M. (2006): Brisket Boards Reduce Freestall Use. *Journal of Dairy Science* 89(7), S. 2603–2607, DOI: 10.3168/jds.S0022-0302(06)72337-2
- Tullo, E.; Fontana, I.; Gottardo, D.; Sloth, K.H.; Guarino, M. (2016): Technical note: Validation of a commercial system for the continuous and automated monitoring of dairy cow activity. *Journal of Dairy Science* 99(9), S. 7489–7494, DOI: 10.3168/jds.2016-11014
- Tyler, S. (1979): Time-sampling. A matter of convention. *Animal Behaviour* 27, S. 801–810, DOI: 10.1016/0003-3472(79)90016-2
- Ungerfeld, R.; Cajarville, C.; Rosas, M.I.; Repetto, J.L. (2014): Time budget differences of high- and low-social rank grazing dairy cows. *New Zealand Journal of Agricultural Research* 57(2), S. 122–127, DOI: 10.1080/00288233.2014.893892
- Val-Laillet, D.; Passillé, A.M. de; Rushen, J.; Keyserlingk, M.A.G. von (2008): The concept of social dominance and the social distribution of feeding-related displacements between cows. *Applied Animal Behaviour Science* 111(1-2), S. 158–172, DOI: 10.1016/j.applanim.2007.06.001
- Valtorta, S.E.; Gallardo, M.R. (2004): Evaporative cooling for Holstein dairy cows under grazing conditions. *International Journal of Biometeorology* 48(4), S. 213–217, DOI: 10.1007/s00484-003-0196-9
- Van den Pol-van Dasselaar, A.; Hennessy, D.; Isselstein, J. (2020): Grazing of Dairy Cows in Europe—An In-Depth Analysis Based on the Perception of

- Grassland Experts. Sustainability 12(3), 1098, DOI: 10.3390/su12031098
- Van Erp-Van der Kooij, E.; Van de Brug, M.; Roelofs, J.B. (2016): Validation of Nedap Smarttag Leg and Neck to assess behavioural activity level in dairy cattle. In: Proceedings Precision Dairy Farming 2016. Precision Dairy Farming 2016, Leeuwarden, The Netherlands, S. 321–326
- Van Laer, E.; Tuytens, F.A.M.; Ampe, B.; Sonck, B.; Moons, C.P.H.; Vandaele, L. (2015): Effect of summer conditions and shade on the production and metabolism of Holstein dairy cows on pasture in temperate climate. *Animal* 9(9), S. 1547–1558, DOI: 10.1017/S1751731115000816
- Van Nuffel, A.; Zwertvaegher, I.; Pluym, L.; van Weyenberg, S.; Thorup, V.M.; Pastell, M.; Sonck, B.; Saeys, W. (2015): Lameness Detection in Dairy Cows. Part 1. How to Distinguish between Non-Lame and Lame Cows Based on Differences in Locomotion or Behavior. *Animals* 5(3), S. 838–860, DOI: 10.3390/ani5030387
- Vázquez Diosdado, J.A.; Barker, Z.E.; Hodges, H.R.; Amory, J.R.; Croft, D.P.; Bell, N.J.; Codling, E.A. (2015): Classification of behaviour in housed dairy cows using an accelerometer-based activity monitoring system. *Animal Biotelemetry* 3(1), 2163, DOI: 10.1186/s40317-015-0045-8
- Veissier, I.; Mialon, M.-M.; Sloth, K.H. (2017): Short communication. Early modification of the circadian organization of cow activity in relation to disease or estrus. *Journal of Dairy Science* 100(5), S. 3969–3974, DOI: 10.3168/jds.2016-11853
- Veissier, I.; Van Laer, E.; Palme, R.; Moons, C.P.H.; Ampe, B.; Sonck, B.; Andanson, S.; Tuytens, F.A.M. (2018): Heat stress in cows at pasture and benefit of shade in a temperate climate region. *International Journal of Biometeorology* 62(4), S. 585–595, DOI: 10.1007/s00484-017-1468-0
- Vickers, L.A.; Burfeind, O.; Keyserlingk, M.A.G. von; Veira, D.M.; Weary, D.M.; Heuwieser, W. (2010): Technical note. Comparison of rectal and vaginal temperatures in lactating dairy cows. *Journal of Dairy Science* 93(11), S. 5246–5251, DOI: 10.3168/jds.2010-3388
- Vitali, A.; Felici, A.; Lees, A.M.; Giacinti, G.; Maresca, C.; Bernabucci, U.; Gaughan, J.B.; Nardone, A.; Lacetera, N. (2020): Heat load increases the risk of clinical mastitis in dairy cattle. *Journal of Dairy Science* 103(9), S. 8378–8387, DOI: 10.3168/jds.2019-17748
- Vizzotto, E.F.; Fischer, V.; Thaler Neto, A.; Abreu, A.S.; Stumpf, M.T.; Werncke, D.; Schmidt, F.A.; McManus, C.M. (2015): Access to shade changes behavioral and physiological attributes of dairy cows during the hot season in the subtropics. *Animal* 9(9), S. 1559–1566, DOI: 10.1017/S1751731115000877
- Voelker, J.A.; Allen, M.S. (2003): Pelleted Beet Pulp Substituted for High-Moisture Corn. 1. Effects on Feed Intake, Chewing Behavior, and Milk Production of Lactating Dairy Cows. *Journal of Dairy Science* 86(11), S. 3542–3552, DOI: 10.3168/jds.S0022-0302(03)73959-9
- Voß, A.L.; Fischer-Tenhagen, C.; Bartel, A.; Heuwieser, W. (2021): Sensitivity and specificity of a tail-activity measuring device for calving prediction in dairy cattle. *Journal of Dairy Science* 104(3), S. 3353–3363, DOI: 10.3168/jds.2020-19277
- Walker, S.L.; Smith, R.F.; Routly, J.E.; Jones, D.N.; Morris, M.J.; Dobson, H. (2008): Lameness, activity time-budgets, and estrus expression in dairy cattle. *Journal of Dairy Science* 91(12), S. 4552–4559, DOI: 10.3168/jds.2008-1048
- Wang, X.; Gao, H.; Gebremedhin, K.G.; Bjerg, B.S.; Van Os, J.; Tucker, C.B.; Zhang, G. (2018): A predictive model of equivalent temperature index for

- dairy cattle (ETIC). *Journal of Thermal Biology* 76, S. 165–170, DOI: 10.1016/j.jtherbio.2018.07.013
- Wankar, A.K.; Rindhe, S.N.; Doijad, N.S. (2021): Heat stress in dairy animals and current milk production trends, economics, and future perspectives. The global scenario. *Tropical Animal Health and Production* 53(1), 70, DOI: 10.1007/s11250-020-02541-x
- Wathes, C.M.; Kristensen, H.H.; Aerts, J.-M.; Berckmans, D. (2008): Is precision livestock farming an engineer's daydream or nightmare, an animal's friend or foe, and a farmer's panacea or pitfall? *Computers and Electronics in Agriculture* 64(1), S. 2–10, DOI: 10.1016/j.compag.2008.05.005
- Webster, J.R.; Stewart, M.; Rogers, A.R.; Verkerk, G.A. (2008): Assessment of welfare from physiological and behavioural responses of New Zealand dairy cows exposed to cold and wet conditions. *Animal Welfare* 17(1), S. 19–26
- Wechsler, B.; Schaub, J.; Friedli, K.; Hauser, R. (2000): Behaviour and leg injuries in dairy cows kept in cubicle systems with straw bedding or soft lying mats. *Applied Animal Behaviour Science* 69(3), S. 189–197, DOI: 10.1016/s0168-1591(00)00134-9
- Weigele, H.C.; Gygax, L.; Steiner, A.; Wechsler, B.; Burla, J.-B. (2018): Moderate lameness leads to marked behavioral changes in dairy cows. *Journal of Dairy Science* 101(3), S. 2370–2382, DOI: 10.3168/jds.2017-13120
- Welfare Quality® Consortium (2009): Welfare Quality® Assessment protocol for cattle, Lelystad, Netherlands. Welfare Quality® Consortium (Hg.)
- Werner, J.; Leso, L.; Umstatter, C.; Niederhauser, J.; Kennedy, E.; Geoghegan, A.; Shalloo, L.; Schick, M.; O'Brien, B. (2018): Evaluation of the RumiWatchSystem for measuring grazing behaviour of cows. *Journal of Neuroscience Methods* 300, S. 138–146, DOI: 10.1016/j.jneumeth.2017.08.022
- Werner, J.; Umstatter, C.; Leso, L.; Kennedy, E.; Geoghegan, A.; Shalloo, L.; Schick, M.; O'Brien, B. (2019): Evaluation and application potential of an accelerometer-based collar device for measuring grazing behavior of dairy cows. *Animal* 13(9), S. 2070–2079, DOI: 10.1017/S1751731118003658
- West, J.W. (2003): Effects of Heat-Stress on Production in Dairy Cattle. *Journal of Dairy Science* (86), S. 2131–2144, DOI: 10.3168/jds.S0022-0302(03)73803-X
- Wheelock, J.B.; Rhoads, R.P.; Vanbaale, M.J.; Sanders, S.R.; Baumgard, L.H. (2010): Effects of heat stress on energetic metabolism in lactating Holstein cows. *Journal of Dairy Science* 93(2), S. 644–655, DOI: 10.3168/jds.2009-2295
- Wildridge, A.M.; Thomson, P.C.; Garcia, S.C.; John, A.J.; Jongman, E.C.; Clark, C.E.F.; Kerrisk, K.L. (2018): Short communication. The effect of temperature-humidity index on milk yield and milking frequency of dairy cows in pasture-based automatic milking systems. *Journal of Dairy Science* 101(5), S. 4479–4482, DOI: 10.3168/jds.2017-13867
- Williams, H.J.; Holton, M.D.; Shepard, E.L.C.; Largey, N.; Norman, B.; Ryan, P.G.; Duriez, O.; Scantlebury, M.; Quintana, F.; Magowan, E.A.; Marks, N.J.; Alagaili, A.N.; Bennett, N.C.; Wilson, R.P. (2017): Identification of animal movement patterns using tri-axial magnetometry. *Movement Ecology* 5, 6, DOI: 10.1186/s40462-017-0097-x
- Winckler, C.; Tucker, C.B.; Weary, D.M. (2015): Effects of under- and overstocking freestalls on dairy cattle behaviour. *Applied Animal Behaviour Science* 170, S. 14–19, DOI: 10.1016/j.applanim.2015.06.003
- Wobschall, A.S. (2017): Sensorbasierte Analyse des Fress- und

- Wiederkauverhaltens von Kühen. Dissertation, Humboldt-Universität zu Berlin, Berlin
- Wolfert, S.; Ge, L.; Verdouw, C.; Bogaardt, M.-J. (2017): Big Data in Smart Farming – A review. *Agricultural Systems* 153, S. 69–80, DOI: 10.1016/j.agsy.2017.01.023
- Wood, S.N. (2011): Fast stable restricted maximum likelihood and marginal likelihood estimation of semiparametric generalized linear models. *Journal of the Royal Statistical Society (B)* 73(1), S. 3–36, DOI: 10.1111/j.1467-9868.2010.00749.x
- Xiong, Y.; Gates, R.S. (2017): Characterizing water utilization in modern US dairies to identify opportunities for reutilization. In: 2017 ASABE Annual International Meeting, 16.-19.07.2017, St. Joseph, USA, DOI: 10.13031/aim.201701034
- Yadav, B.; Singh, G.; Wankar, A. (2021): Acclimatization dynamics to extreme heat stress in crossbred cattle. *Biological Rhythm Research* 52(4), S. 524–534, DOI: 10.1080/09291016.2019.1610627
- Yan, G.; Li, H.; Zhao, W.; Shi, Z. (2020): Evaluation of thermal indices based on their relationships with some physiological responses of housed lactating cows under heat stress. *International Journal of Biometeorology* 64(12), S. 2077–2091, DOI: 10.1007/s00484-020-01999-6
- Zahedi, F. (1991): An Introduction to Neural Networks and a Comparison with Artificial Intelligence and Expert Systems. *Interfaces* 21(2), S. 25–38, DOI: 10.1287/inte.21.2.25
- Zahner, J. (2020): Technische Maßnahmen zur Reduzierung von Hitzestress in Rinderställen. In: Beiträge zum Thema Stallklima in der Tierhaltung 2020. Arbeitsgruppe "Stallklima und Emissionen" der Koordinierungsgruppe Tierhaltung. Hg. Hansen, C.; Tober, O. et al., Dummerstorf, S. 40–44
- Zähner, M.; Schrader, L.; Hauser, R.; Keck, M.; Langhans, W.; Wechsler, B. (2004): The influence of climatic conditions on physiological and behavioural parameters in dairy cows kept in open stables. *Animal Science* 78(1), S. 139–147, DOI: 10.1017/S1357729800053923
- Zambelis, A.; Gagnon-Barbin, M.; St John, J.; Vasseur, E. (2019a): Development of scoring systems for abnormal rising and lying down by dairy cattle, and their relationship with other welfare outcome measures. *Applied Animal Behaviour Science* 220, 104858, DOI: 10.1016/j.applanim.2019.104858
- Zambelis, A.; Wolfe, T.; Vasseur, E. (2019b): Technical note. Validation of an ear-tag accelerometer to identify feeding and activity behaviors of tiestall-housed dairy cattle. *Journal of Dairy Science* 102(5), S. 4536–4540, DOI: 10.3168/jds.2018-15766
- Zebari, H.M.; Rutter, S.M.; Bleach, E.C. (2018): Characterizing changes in activity and feeding behaviour of lactating dairy cows during behavioural and silent oestrus. *Applied Animal Behaviour Science* 206, S. 12–17, DOI: 10.1016/j.applanim.2018.06.002
- Zebeli, Q.; Tafaj, M.; Steingass, H.; Metzler, B.; Drochner, W. (2006): Effects of Physically Effective Fiber on Digestive Processes and Milk Fat Content in Early Lactating Dairy Cows Fed Total Mixed Rations. *Journal of Dairy Science* 89(2), S. 651–668, DOI: 10.3168/jds.S0022-0302(06)72129-4
- Zehner, N.; Umstätter, C.; Niederhauser, J.J.; Schick, M. (2017): System specification and validation of a noseband pressure sensor for measurement of ruminating and eating behavior in stable-fed cows. *Computers and Electronics in Agriculture* 136, S. 31–41, DOI: 10.1016/j.compag.2017.02.021
- Zimelman, R.B.; Rhoads, R.; Rhoads, M.L.; Duff, G.C.; Baumgard, L.H.;

---

Collier, R.J. (2009): A Re-Evaluation of the Impact of Temperature Humidity Index (THI) and Black Globe Humidity Index (BGHI) on Milk Production in High Producing Dairy Cows. In: Proceedings of the Southwest Nutrition and Management Conference. Southwest Nutrition and Management Conference, 26.-27.02.2009, S. 158–168

## XIII. VERZEICHNIS DER ABBILDUNGEN UND TABELLEN

### 1. Abbildungsverzeichnis

#### 1.1. Abbildungen aus den Kapiteln III, IV und VII

Abbildung 1: Mögliche Körperstellen für die Anbringung von Monitoringsystemen bei Milchkühen: (1) als Ohrmarke, (2) am Halfter, (3) am Schwanz, (4) am Halsband, (5) als Pansenbolus eingebracht in den Pansen, (6) als Pedometer an der Gliedmaße (©Anna Hofbauer) .....	39
Abbildung 2: Darstellung der verschiedenen Fenstertypen inklusive ihrer Fenstergröße, Schrittweite und Überlappung.....	51
Abbildung 3: Übersicht über die Datenerfassung zur Entwicklung maschineller Lernmodelle für die automatisierte Verhaltenserkennung bei Milchkühen	108
Abbildung 4: Aufbau des Monitoringsystems mit Lithiumbatterien, Sensorplatine und Gehäuse .....	109
Abbildung 5: Kameraaufbau für die Verhaltensbeobachtungen auf der Weide .	111
Abbildung 6: Übersicht über die Datenerfassung in Durchgang 1 (Juni 2020) zur Untersuchung einer beginnenden Hitzebelastung.....	116
Abbildung 7: Übersicht über die Datenerfassung in Durchgang 2 (August 2020) zur Untersuchung einer beginnenden Hitzebelastung.....	116
Abbildung 8: Verlauf des Wiederkau-, Liege- und Graseverhaltens der Tiere bei Durchgang 1 auf Betrieb 1 innerhalb von 24 h.....	163
Abbildung 9: Verlauf des Wiederkau-, Liege- und Graseverhaltens der Tiere bei Durchgang 2 auf Betrieb 1 innerhalb von 24 h.....	163
Abbildung 10: Verlauf des Wiederkau-, Liege- und Graseverhaltens der Tiere auf Betrieb 2 innerhalb von 24 h.....	164
Abbildung 11: Verlauf des Wiederkau- und Liegeverhaltens der Tiere bei auf Betrieb 3 innerhalb von 24 h.....	164

## 1.2. Abbildungen in der ersten Publikation

- Figure 1: Composition of the prototype of the monitoring system from Blaupunkt Telematics GmbH (Hildesheim, Germany) and the included sensor board..... 122
- Figure 2: Prototype of the monitoring system (Blaupunkt Telematics GmbH; Hildesheim Germany) mounted on the collar of a Simmental cow grazing pasture.....
- Fehler! Textmarke nicht definiert.**
- Figure 3: Procedure of the training phase that consists of two steps: preprocessing and model training. The goal of this step is to create prediction models that can be applied to new sensor data..... 124
- Figure 4: Procedure of the prediction phase, which includes applying new data to the trained models for validation of their prediction performance..... 125
- Figure 5: Accuracy comparison of the different classifiers (random forest, decision tree, naive Bayes and support vector machine) based on different sampling rates (1-10 Hz). The postprocessing filter was not applied for this comparison..... 130
- Figure 6: Accuracy comparison of the different classifiers (random forest, decision tree, naive Bayes and support vector machine) based on different window sizes (1-20 s). The postprocessing filter was not applied for this comparison..... 130
- Figure 7: Detection of individual lying bouts and non-lying bouts including detected, merged, divided and added bouts..... 133
- Figure 8: Deviation in detected beginnings (left) and endings (right) of lying bouts by the model compared to Ground Truth..... 134

### 1.3. Abbildungen in der zweiten Publikation

Figure 1: Development of respiration rate (A,B), milk yield (C,E,F), milk composition (G,H), somatic cell count (D), and fecal cortisol level (I,J) in r1 from d0 to d4. “\*\*\*\*” indicates highly significant cell count (D), and fecal cortisol level (I,J) in r1 from d0 to d4. “\*\*\*\*” indicates highly significant differences ( $p < 0.01$ ), and “\*\*\*” indicates significant differences ( $p < 0.05$ ). .....151

Figure 2: Development of respiration rate (A,B), milk yield (C,E,F), milk composition (G,H), somatic cell count (D), and fecal cortisol level (I,J) in r2 from d1 to d7. “\*\*\*\*” indicates highly significant cell count (D), and fecal cortisol level (I,J) in r2 from d1 to d7. “\*\*\*\*” indicates highly significant differences ( $p < 0.01$ ), and “\*\*\*” indicates significant differences ( $p < 0.05$ )..... 152

## 2. Tabellenverzeichnis

### 2.1. Tabellen aus den Kapiteln III, IV und VII

Tabelle 1: Verschiedene Abweichungen im Ablegeverhalten von Milchkühen mit der Häufigkeit ihres Auftretens (%) in den Studien von ZAMBELIS et al. (2019a) und DIRKSEN et al. (2020).....	9
Tabelle 2: Verschiedene Abweichungen im Aufstehverhalten von Milchkühen mit der Häufigkeit ihres Auftretens (%) in den Studien von ZAMBELIS et al. (2019a) und DIRKSEN et al. (2020).....	10
Tabelle 3: Übersicht über Haltungs- und Managementfaktoren, die das Verhalten von Milchkühen beeinflussen .....	15
Tabelle 4: Übersicht über die zur Verhaltenserfassung bei Milchkühen genutzten Sensoren bzw. Sensorkombinationen.....	38
Tabelle 5: Übersicht über die zur Verhaltenserfassung bei Milchkühen genutzten Anbringungsorte bzw. Kombination aus Anbringungsorten für Sensoren am Tier .....	40
Tabelle 6: Übersicht über die von Monitoringsystemen für Milchkühe für die Verhaltenserfassung genutzten Algorithmen .....	48
Tabelle 7: Übersicht über die von Monitoringsystemen für Milchkühe für die Erkennung der Brunst, der Abkalbung, von Erkrankungen oder Belastungen der Tiergesundheit genutzten Algorithmen.....	50
Tabelle 8: Übersicht über die für Monitoringsysteme genutzten Datenerfassungsfrequenzen und Fenstergrößen zur Erkennung verschiedener Verhaltensweisen .....	52
Tabelle 9: Übersicht über die für die Erkennung der Brunst, der Abkalbung, von Erkrankungen und Belastungen der Tiergesundheit mit Monitoringsystemen betrachteten Zeiträume.....	54
Tabelle 10: Übersicht über die zur Erkennung der Brunst, der Abkalbung, von Erkrankungen und Belastungen der Tiergesundheit genutzten Features und ihre Änderung.....	56
Tabelle 11: Übersicht über erhältliche Systeme zur automatisierten Erfassung des Liegeverhaltens bei Milchkühen und ihre Performance .....	60
Tabelle 12: Übersicht über erhältliche Systeme zur automatisierten Erfassung einzelner Liegeperioden bei Milchkühen und ihre Performance .....	61

Tabelle 13: Übersicht über erhältliche Systeme zur automatisierten Erfassung des Stehverhaltens bei Milchkühen und ihre Performance .....	62
Tabelle 14: Übersicht über erhältliche Systeme zur automatisierten Erfassung des Gehverhaltens bei Milchkühen und ihre Performance.....	64
Tabelle 15: Übersicht über erhältliche Systeme zur automatisierten Erfassung der Schrittzahl bei Milchkühen und ihre Performance.....	65
Tabelle 16: Übersicht über erhältliche Systeme zur automatisierten Erfassung des Fressverhaltens bei Milchkühen und ihre Performance .....	66
Tabelle 17: Übersicht über erhältliche Systeme zur automatisierten Erfassung des Graseverhaltens bei Milchkühen und ihre Performance .....	67
Tabelle 18: Übersicht über erhältliche Systeme zur automatisierten Erfassung des Wiederkauverhaltens bei Milchkühen und ihre Performance .....	69
Tabelle 19: Übersicht über erhältliche Systeme zur automatisierten Erfassung einzelner Wiederkauperioden bei Milchkühen und ihre Performance.....	70
Tabelle 20: Übersicht über erhältliche Systeme zur automatisierten Erfassung einzelner Wiederkauschläge bei Milchkühen und ihre Performance.....	71
Tabelle 21: Übersicht über die auf dem Markt erhältlichen Monitoringsysteme zur Brunsterkennung inklusive ihrer Performance.....	73
Tabelle 22: Übersicht über die auf dem Markt erhältlichen Monitoringsysteme zur Erkennung der Abkalbung inklusive ihrer Performance.....	74
Tabelle 23: Kriterien, nach denen peripartale Gesundheitsstörungen in der Ground Truth für die Validierung von Monitoringsystemen definiert wurden.....	75
Tabelle 24: Übersicht über die auf dem Markt erhältlichen Monitoringsysteme zur Erkennung von Lahmheiten inklusive ihrer Performance .....	77
Tabelle 25: Formeln zur Berechnung der verschiedenen Witterungsindices, die zur Einschätzung der Hitzebelastung von Milchkühen Anwendung finden .....	91
Tabelle 26: Übersicht über die Zahl der mit einem Monitoringsysteme ausgestatteten Tiere und Anzahl der davon gelaufenen Systeme auf den verschiedenen Betrieben je Durchgang und Tag .....	110
Tabelle 27: Zahl der Tiere auf den verschiedenen Betrieben je Durchgang und Tag, deren Videodaten detailliert bzw. mit Liegen/Nicht-Liegen gelabelt wurden.....	111
Tabelle 28: Übersicht über die für die verschiedenen Verhaltensweisen verwendeten Modelle inklusive ihrer Parameter.....	112

---

Tabelle 29: Übersicht über die für die Evaluation der Modelle genutzte Datenmenge.....	160
Tabelle 30: Sensitivität, Spezifität, Genauigkeit der Modelle in der Erkennung der verschiedenen Verhaltensweisen (Liegen, Grasen, Wiederkauen) .....	160
Tabelle 31: Mittlere Liege-, Wiederkau- und Grasedauer ( $\pm$ Standardabweichung) auf den verschiedenen Betrieben über 24 h, tagsüber (06:00 bis 18:00 Uhr) und nachts (18:00 bis 06:00 Uhr).....	161
Tabelle 32: Synchronitäts( $\kappa_F$ )-Werte für das Liege-, Wiederkau- und Graseverhalten für die verschiedenen Durchgänge.....	165
Tabelle 33: Parität, Tage in Milch, Body Condition Score (BCS), Milchleistung, Milchfett- und Milchproteingehalt der in die Durchgänge auf den verschiedenen Betrieben eingeschlossenen Milchkühe (Mittelwert $\pm$ Standardabweichung).....	165
Tabelle 34: Parität, Tage in Milch, Body Condition Score (BCS), Milchleistung, Milchfett- und Milchproteingehalt der in die Durchgänge auf den verschiedenen Betrieben eingeschlossenen Milchkühe (Mittelwert $\pm$ Standardabweichung).....	166

## 2.2. Tabellen in der ersten Publikation

Table 1: Sward composition (grasses, herbs and legumes) of pastures on farm 1 and farm 2.....	121
Table 2: Ethogram of dairy cow behavior used for labeling the video data in order to generate ground truth data. Definitions were derived from MARTISKAINEN et al. (2009), REITER et al. (2018) and WERNER et al. (2018).....	124
Table 3: Classifiers with corresponding selected hyperparameters. The hyperparameters were tuned by an exhaustive grid search method in order to find the optimized parameters for each model.....	126
Table 4: Behavior instances distribution used for training the model. The training dataset contains the data of three animals from farm 1.....	129
Table 5: Amount of datasets collected for the evaluation of the mode. Differences in amount of collected datasets are based on different availability and runtime of sensors between farms, rounds and days.....	129
Table 6: The two selected models based on the random forest classifier with two different sets of features (orientation-dependent/orientation-independent)...	131
Table 7: Accuracy of the two models with different features sets (orientation-dependent/orientation-independent) when both trained and tested on farm 1 (=same sensor orientation).....	131
Table 8: Accuracy of the two models with different feature sets (orientation-dependent/orientation-independent) when trained on farm 1 and tested on farm 2 (=different sensor orientation).....	131
Table 9: Comparison of lying times (mean $\pm$ standard deviation) over 24 h and during daytime (06.00 to 18.00 h) and nighttime (18.00 to 06.00 h) between the different farms (=husbandry systems).....	134
Table 10: Performance of the model compared to the results of other model evaluations.....	137

### 2.3. Tabellen in der zweiten Publikation

Table 1: Mean DBT <sup>1</sup> , RH <sup>2</sup> , RAD <sup>3</sup> , WS <sup>4</sup> , THI <sup>5</sup> , and BGHI <sup>6</sup> per 6 h period (0:00–06:00, 06:00–12:00, 12:00–18:00, and 18:00–24:00 h) and per day (06:00–06:00 h) in r1 on d1 to d4.....	149
Table 2: Mean DBT <sup>1</sup> , RH <sup>2</sup> , RAD <sup>3</sup> , WS <sup>4</sup> , THI <sup>5</sup> , and BGHI <sup>6</sup> per 6 h period (0:00–06:00, 06:00–12:00, 12:00–18:00, and 18:00–24:00 h) and per day (06:00–06:00 h) in r2 on d1 to d7.....	150
Table 3: Grazing and ruminating behavior per day (d; 06:00–06:00 h) and separately for daytime (06:00–18:00 h) and nighttime (06:00–18:00 h) for d1 to d3 in r1 and for d1 to d4 in r2. For behavior evaluation, previously validated machine learning models [45,46,60] for each behavioral pattern were applied to the sensor data from 5 animals.....	153
Table 4: Fleiss' Kappa ( $\kappa_F$ ) values for the evaluation of synchrony of grazing and ruminating behavior in the two rounds from 5 animals for each day (d; 06:00–06:00 h) and during daytime (06:00–18:00 h) and nighttime (06:00–18:00 h) for d1 to d3 in r1 and for d1 to d4 in r2.....	154

## XIV. DANKSAGUNG

Zunächst möchte ich Herrn Prof. Dr. Michael Erhard für die Möglichkeit der Promotion am Lehrstuhl für Tierschutz, Verhaltenskunde, Tierhygiene und Tierhaltung danken. Besonderer Dank gilt meiner Betreuerin Frau PD Dr. Elke Rauch für die hervorragende Betreuung bei der Planung der Versuche, die wertvollen Anregungen zur Auswertung, sowie die hilfreichen Korrekturen der Publikationen und der Doktorarbeit.

Besonderer Dank gilt auch Herrn Stefan Thurner von der Bayerischen Landesanstalt für Landwirtschaft (LfL) für die Möglichkeit, im Rahmen meiner Stelle im Projekt „Rindertracking“ die Doktorarbeit schreiben zu können. Vielen Dank für die hervorragende Hilfestellung bei der Planung und Durchführung der Versuche und die wertvolle Kritik bei der Anfertigung der Publikationen und der Doktorarbeit, sowie für die tolle Zusammenarbeit in meiner Zeit an der LfL. Danken möchte ich auch meinen Kolleginnen und Kollegen von der LfL für die fachliche, tatkräftige und seelische Unterstützung bei der Planung und Durchführung der Versuche.

Der Bayerischen Forschungsstiftung danke ich für die finanzielle Unterstützung.

Ganz besonderer Dank gilt zudem den Landwirten und Landwirtinnen für die Möglichkeit der Datenerhebung auf ihren Betrieben und die tatkräftige Hilfestellung bei der Probennahme. Ohne sie wäre die Durchführung der Versuche nicht möglich gewesen.

Vielen Dank auch an den Lehrstuhl für Mobile Systeme der Universität Bamberg und besonders Frau Prof. Dr. Daniela Nicklas, sowie Herrn Michael Sünkel, Frau Golnaz Elmamooz, Herrn Phan Thai Hoang und Frau Anastasiia Kozar für die gute Zusammenarbeit im Projekt und bei der Anfertigung der Publikation. Großer Dank gilt auch Herrn Hendrik Vogel für das Datenmanagement.

Der Blaupunkt Telematics GmbH und besonders Herrn Alexander Süsse möchte ich für die Bereitstellung der Monitoringsysteme, sowie den technischen Support danken.

Vielen Dank an das Labor des Lehrstuhls für Tierschutz, Verhaltenskunde, Tierhygiene und Tierhaltung für die Vorbereitung und Herrn Prof. Dr. Palme vom Institut für Physiologie, Pathophysiologie und Biophysik der Vetmeduni Wien und seinem Team für die Auswertung der Kotproben. Danke an Herrn Meßner und Herrn Lohmaier vom Milchprüfing Bayern e.V. für die unkomplizierte Organisation der Milchprobenanalyse.

Ein spezieller Dank gilt meiner Familie – meinen Eltern, meiner Schwester und meinen Großeltern – für die vorbehaltlose Unterstützung bei all meinen Vorhaben. Nicht zuletzt möchte ich meinem Freund Tobi danken, der mich in der Zeit der Doktorarbeit unermüdlich gestärkt, motiviert und kulinarisch versorgt hat.