

Entwicklung eines Berechnungsmodells zur automatischen Lahmheitserkennung

Isabella Lorenzini¹, Katharina Grimm¹ und Bernhard Haidn¹

Abstract: Die Früherkennung von Lahmheit spielt bei der Vermeidung von Leistungseinbußen und Leiden für die Tiere eine wesentliche Rolle. In der vorliegenden Studie wurden auf vier Praxisbetrieben und einem Versuchsbetrieb Verhaltens- und Leistungsdaten sowie Daten zur Klauengesundheit von 638 Tieren gesammelt. Anhand der erfassten Daten wurde das Enet-BETA Modell, das eine Genauigkeit von 0,61 AUC² aufwies, und das gemischte lineare Modell, das eine AUC = 0,83 aufwies, als Vorhersagemodelle für Lahmheiten bei Milchkühen überprüft.

Keywords: Lahmheit, Vorhersagemodell, precision livestock farming

1 Einführung und Problemstellung

Lahmheit ist eine der häufigsten Produktionskrankheiten in der Milchviehhaltung. Lahmheit beeinflusst das Wohlbefinden der Tiere [BBS12] und ihr natürliches Verhalten [GB02]. Studien zeigen, dass Lahmheit sich auf das Liegeverhalten der Tiere auswirkt; im Vergleich zu nicht lahmen Tieren liegen lahme Tiere durchschnittlich mehr und stehen weniger oft auf [Gr19]. Außerdem wird durch Lahmheit das Futteraufnahmeverhalten beeinflusst; Tiere mit Klauenerkrankungen verbringen weniger Zeit am Futtertisch und besuchen diesen weniger oft [Gr19]. Auch die Milchleistung kann bei lahmen Tieren abnehmen [AGH10], was kombiniert mit einem erhöhten Arbeitsaufwand, Behandlungskosten und verkürzter Nutzungsdauer wirtschaftliche Einbußen für den Landwirt verursacht [BHS10]. Trotz der technologischen und züchterischen Fortschritte in der Milchviehhaltung hat sich die Lahmheitsprävalenz in den letzten Jahrzehnten auf europäischen Milchviehbetrieben nicht verändert [Sc09]. Die letzte bekannte Prävalenzstudie, die zum Thema Lahmheit in Deutschland durchgeführt wurde, stammt aus dem Jahr 2004 und gibt 45 % als durchschnittlichen Anteil lahmer Tiere pro Betrieb an [WB04]. Eine neuere Studie aus dem Jahr 2018, die in Großbritannien durchgeführt wurde, weist 31 % lahme Tiere pro Betrieb auf [GGO18].

¹ Bayerische Landesanstalt für Landwirtschaft (LfL), Institut für Landtechnik und Tierhaltung (ILT), Prof. Dürrwaechter-Platz 2, 85586 Grub, isabella.lorenzini@lfl.bayern.de, grimm.k@hotmail.com, bernhard.haidn@lfl.bayern.de

² Area under the curve, Fläche unter der Kurve

1.1 Lahmheitserkennung

Das Ausbleiben von Verbesserungen der Lahmheitsprävalenz könnte demnach unter Anderem an den Schwierigkeiten bei der Erkennung liegen. Landwirte neigen dazu, die Lahmheitsprävalenz auf ihren eigenen Betrieben signifikant zu unterschätzen [Šá11] und geben Zeit als limitierenden Faktor bei der frühzeitigen Erkennung und Behandlung von lahmen Tieren [Ho13] an.

Den Goldstandard für die Lahmheitserkennung stellt das Locomotionscoring dar, dabei werden Tiere anhand der Qualität ihres Ganges in verschiedene Kategorien eingeteilt. Ein gemeinsames Problem aller Gangbeurteilungssysteme ist die niedrige Inter- und Intrarater Reliabilität [Sc14].

Eine effiziente und arbeitersparende Alternative zur manuellen Gangbeurteilung ist die automatische Lahmheitserkennung. Bei der indirekten Lahmheitsdetektion werden Veränderungen in der Leistung und im Verhalten der Tiere als Indikatoren für Lahmheit eingesetzt. Van Hertem et al. (2013) erreichten mit ihren multivariaten Regressionsmodellen eine hohe Genauigkeit ($AUC = 0,89$) [Va13], während in einem Vorgängerprojekt am Institut für Landtechnik und Tierhaltung (ILT) Grimm et al. (2019) ein Berechnungsmodell zur automatischen Lahmheitsvorhersage mit einer $AUC = 0,94$ [Gr19] entwickelten. Das Ziel der hier vorgestellten Studie war es, das im Vorgängerprojekt von Grimm et al. (2019) entwickelte Berechnungsmodell anhand von Praxisdaten zu überprüfen und weiterzuentwickeln.

2 Tiere, Material und Methoden

2.1 Datenerfassung

Die Daten für diese Studie wurden über einen Zeitraum von 14 Monaten auf vier Praxisbetrieben und einem Versuchsbetrieb gesammelt. Insgesamt wurden Daten von 638 Kühen erfasst. Pedometer³, die am rechten Vorderbein aller Tiere befestigt wurden, erfassten die Aktivität sowie das Liege- und Futteraufnahmeverhalten der Tiere. Die Daten zur Leistung der Tiere wurden bei drei der fünf Projektbetriebe über die monatlichen Milchmengenmessungen des LKV Bayern⁴ erfasst, während bei den übrigen zwei Betrieben die Daten des AMS⁵ herangezogen wurden.

Die Referenzdaten für die Klauengesundheit der Tiere wurden manuell über Locomotionscoring, Videoanalyse und Klauenuntersuchungen erfasst. Alle vierzehn Tage wurde

³ „Track a Cow“, ENGS Dairy Solutions, Rosh Pina, Israel

⁴ Landeskuratorium der Erzeugerringe für tierische Veredelung in Bayern e.V.

⁵ Automatisches Melksystem.

über Videoaufnahmen ein Locomotionscore aller Tiere durchgeführt und anschließend wurden die lahmen Kühe untersucht und gegebenenfalls behandelt.

2.2 Datenanalyse

Nach der Versuchsphase wurden die erfassten Daten in einer postgresQL Datenbank zu Tagesdatensätzen für jedes Tier zusammengefasst. Die Datenanalyse wurde in RStudio⁶ durchgeführt. Die unbalanzierten Daten wurden skaliert, zentriert und in einen Trainings- und einen Testdatensatz aufgeteilt. Anhand des SMOTE Algorithmus [Ch02] wurden anschließend die stark überrepräsentierten positiven Lahmheitsfälle mit synthetisch generierten Kontrollfällen ausgeglichen.

Als erstes wurden anhand einer schrittweisen Regression relevante Interaktionsparameter zwischen den Prädiktoren hervorgehoben. Anschließend wurde das im Vorgängerprojekt bereits angewandte Enet-BETA [LL17] Modell anhand der erfassten Daten überprüft. Diese nach Liu und Li (2017) modifizierte Form des elastic net Modells ist ein Regressionsmodell, das sich für die Analyse von Datensätzen mit einer hohen Kollinearität und zahlreichen Variablen gut eignet. Durch die vom elastic net durchgeführte Variablenselektion entsteht ein sparsames und somit besser interpretierbares Modell [St12; ZH05].

Ferner wurden die Daten anhand einer generalisierten, gemischten linearen Regression (GGLR) mit dem Faktor „Betrieb“ (B) und „Einzeltier“ (BTN) als zufälligen Effekten analysiert. Die Genauigkeit der Modelle wurde mittels ROC⁷ Kurvenanalyse bestimmt. Bei der ROC Kurvenanalyse wird für verschiedene Grenzwerte des Modells die Richtigkeitsrate gegen die Falschpositivrate aufgetragen. Die Fläche unter der daraus resultierenden Kurve wird als AUC bezeichnet und beschreibt die Qualität einer Vorhersage. Bei einer Vorhersage, deren Genauigkeit dem Zufall entspricht, ist die AUC = 0,5, während bei einer perfekten Vorhersage die AUC = 1 beträgt [Me78].

3 Ergebnisse

Der Trainingsdatensatz mit Daten aller Projektbetriebe wurde anhand des Enet-BETA-Verfahrens mit einer 10-fachen Kreuzvalidierung analysiert. Das finale Enet-BETA-Modell wies 3 Prädiktoren auf. Diese waren C.MN⁸, C.MN:P⁹, sowie P¹⁰. Die AUC des Enet-BETA-Modells auf dem Trainingsdatensatz war 0,61 (KI 0,60 – 0,63). Das Modell wurde anschließend auf dem Testdatensatz überprüft und wies ebenso eine AUC von 0,61 (KI 0,58 – 0,65) auf.

⁶ 1.0.136 Version, RStudio Team, MA.

⁷ Receiver operating characteristics

⁸ Anzahl der Futtertischbesuche

⁹ Interaktionsparameter zwischen Anzahl an Futtertischbesuche und die Parität

¹⁰ Parität

Nachdem, wie beim Enet-BETA-Verfahren, die relevanten Interaktionsparameter der GGLR anhand einer schrittweisen Regression hervorgehoben wurden, wurden die statistisch nicht signifikanten Prädiktoren schrittweise vom Modell entfernt. Das finale Modell war wie folgt aufgebaut:

$$\text{Lahmheitsstatus} \sim \text{AC} + \text{ACR} + \text{C.FDM} + \text{DIM} + \text{FD} + \text{FDR} + \text{LDB} + \text{LDR} + \text{MMY} + \text{P} + \text{DIM:FD} + \text{FD:MMY} + (1 \mid \text{B/BTN})^{11} \quad (1)$$

Die GGLR wies 13 Prädiktoren auf, mit zwei Interaktionsparametern zwischen jeweils den Tagen in Milch und der Tagesmilchleistung bzw. der Futteraufnahmedauer, und hatte eine AUC von 0,88 (KI 0,87 – 0,89). Auf den Testdaten wies die GGLR eine AUC von 0,83 (KI 0,80 – 0,85) auf. Die GGLR wurde dann mit Daten der einzelnen Betriebe überprüft und hatte eine hohe Genauigkeit mit einer AUC zwischen 0,89 und 0,96 auf den Trainingsdatensätzen.

4 Diskussion und Schlussfolgerung

Das im Vorgängerprojekt mit Daten aus dem Versuchsbetrieb der LfL¹² entwickelte Enet-BETA-Modell wies eine viel höhere Genauigkeit auf als das Modell, das im Rahmen dieser Studie berechnet wurde. Der Ursprung der Daten aus verschiedenen Betrieben spielte wahrscheinlich eine große Rolle dabei; dies wird auch durch die höhere Genauigkeit der GGLR, die die unterschiedliche Varianz der Daten innerhalb der Betriebe im Vergleich zur Gesamtvarianz berücksichtigt, bestätigt. Außerdem war die Genauigkeit der GGLR bei den mit Daten der einzelnen Betriebe berechneten Modellen höher. Der in der GGLR berücksichtigte zufällige Effekt des Einzeltiers war ebenso von großer Bedeutung. Die unterschiedliche Varianz der Verhaltens- und Leistungsdaten zwischen den Einzeltieren war groß, somit war die Genauigkeit der Vorhersage beim Enet-BETA-Modell, das diesen Faktor nicht berücksichtigte, niedriger.

Obwohl es nicht möglich war, die hohe Genauigkeit des im Vorgängerprojekt berechneten Enet-BETA-Modells mit Daten aus Praxisbetrieben zu reproduzieren, zeigten die Ergebnisse dieser Studie, dass es möglich ist, Lahmheit mit einem verhältnismäßig niedrigen technologischen Aufwand vorherzusagen. Um eine praktische Anwendung zu ermöglichen, müsste die Genauigkeit der Vorhersagen durch eine stärkere Berücksichtigung von Managementfaktoren, die Betriebe voneinander unterscheiden, noch verbessert werden. Außerdem könnte eine Zeitreihenanalyse eingesetzt werden, um Abweichungen vom tierindividuellen Verhaltensmuster, die mit einer Klauenerkrankung einhergehen, zu identifizieren und somit die Lahmheit frühzeitig zu detektieren.

¹¹ AC: Aktivität, ACR: Aktivität tagsüber, C.FDM: Futteraufnahmedauer pro Mahlzeit, DIM: Tage in Milch, FD: Futteraufnahmedauer, FDR: Futteraufnahmedauer tagsüber, LDB: Liegedauer pro Liegeereignis, LDR: Liegedauer tagsüber, MMY: Durchschnittliche Tagesmilchleistung, P: Parität, B: Betrieb, BTN: Tiernummer

¹² Bayerische Landesanstalt für Landwirtschaft

Literaturverzeichnis

- [AGH10] Archer, S. C.; Green, M. J.; Huxley J. N.: Association between milk yield and serial locomotion score assessments in UK dairy cows. *Journal of Dairy Science* 09/10, S. 4045-4053, 2010.
- [BHS10] Bruijnis, M. R. N.; Hogeveen, H.; Stassen, E. N.: Assessing economic consequences of foot disorders in dairy cattle using a dynamic stochastic simulation model. *Journal of Dairy Science* 06/10, S. 2419-2432, 2010.
- [BBS12] Bruijnis, M. R. N.; Beerda, B.; Stassen, E. N.: Assessing the welfare impact of foot disorders in dairy cattle by a modeling approach. *Journal of Dairy Science* 06/12, S. 962-970, 2012.
- [Ch02] Chawla, N.V.; Bowyer, K.W.; Hall, L.O.; Kegelmeyer, W.P.: SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research* 01/02, S. 321-357, 2002.
- [GB02] Galindo, F.; Broom, D.M.: The Effects of Lameness on Social and Individual Behavior of Dairy Cows. *Journal of Applied Animal Welfare Science* 03/02, S. 193-201, 2002.
- [GGO18] Griffiths, B. E.; Grove White, D.; Oikonomou, G.: A Cross-Sectional Study Into the Prevalence of Dairy Cattle Lameness and Associated Herd-Level Risk Factors in England and Wales. *Frontiers in Veterinary Science* 05/18, S. 65, 2018.
- [Gr19] Grimm, K.; Haidn, B.; Erhard, M.; Tremblay, M.; Döpfer, D.: New Insights into the Association between Lameness, Behavior, and Performance in Simmental Cows. *Journal of Dairy Science* 03/19, S. 2453-2468, 2019.
- [Ho13] Horseman, S. V.; Whay, H. R.; Huxley, J. N.; Bell, N. J.; Mason, C. S.: A Survey of the On-Farm Treatment of Sole Ulcer and White Line Disease in Dairy Cattle. *The Veterinary Journal* 02/13, S. 461-467, 2013.
- [LL17] Liu, W.; Li, Q.: An Efficient Elastic Net with Regression Coefficients Method for Variable Selection of Spectrum Data. *PLOS ONE* 02/17, 2017.
- [Me78] Metz, C. E.: Basic Principles of ROC Analysis. *Seminars in Nuclear Medicine* 04/78, S. 283-298, 1978.
- [Šá11] Šárová, R.; Stehulova, I.; Kratinová, P.; Firla, P.; Spinka, M.: Farm Managers Underestimate Lameness Prevalence in Czech Dairy Herds. *Animal Welfare* 02/11, S. 201-204, 2011.
- [Sc09] European Food Safety Authority (EFSA). Scientific Report on the Effects of Farming Systems on Dairy Cow Welfare and Disease. *EFSA Journal* 07/09, 2009.
- [Sc14] Schlageter-Tello, A.; Bokkers, E. A. M.; Koerkamp, P. W. G. G.; Van Hertem, T.; Viuzzi, S.; Romanini, C. E. B.; Halachmi, I.; Bahr, C.; Berckmans, D.; Lokhorst, K.: Manual and Automatic Locomotion Scoring Systems in Dairy Cows: A Review. *Preventive Veterinary Medicine* 09/14, S. 12-25, 2014.
- [St12] Stuckart, C.: Methoden des Elastic Net zur sparsamen Variablenselektion und deren Anwendung in der Genetik, Ludwig-Maximilians-Universität München, Fakultät für Mathematik, Informatik und Statistik, Institut für Statistik, 2012.

- [Va13] Van Hertem, T.; Maltz, E.; Antler, A.; Romanini, C. E. B.; Viazzi, S.; Bahr, C.; Schlageter-Tello, A.; Lokhorst, C.; Berckmans, D.; Halachmi, I.: Lameness Detection Based on Multivariate Continuous Sensing of Milk Yield, Rumination, and Neck Activity. *Journal of Dairy Science* 07/13, S. 4286-4298, 2013.
- [WB04] Winckler, C.; Brill, G.: Lameness Prevalence and Behavioural Traits in Cubicle Housed Dairy Herds - a Field Study. In *Proceedings of the 13th International Symposium and Conference on Lameness in Ruminants*. Univerzitetna knjižnica Maribor Slovenia, 2004.
- [ZH05] Zou, H.; Hastie, T.: Regularization and Variable Selection via the Elastic Net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)* 02/05, S. 301-320, 2005.