

Nutzung empirischer Methoden auf Basis einzeltierbezogener Daten zur Identifizierung von Leistungsabweichungen beim Milchrind

Christian Ammon, Joachim Spilke

AG Biometrie und Agrarinformatik
Institut für Agrar- und Ernährungswissenschaften
Martin-Luther-Universität Halle-Wittenberg
Ludwig-Wucherer-Strasse 82-85
06108 Halle (Saale)
christian.ammon@landw.uni-halle.de
joachim.spilke@landw.uni-halle.de

Abstract: Gemischte lineare Modelle, Fuzzy Logic-Systeme und künstliche neuronale Netze wurden verwendet, um negative Abweichungen von Milchmengen bei Milchkühen zu erkennen.

1 Einleitung

In Milchviehbetrieben stehen durch immer weiterentwickelte (Melk-)Technik zunehmend einzeltierbezogene Daten zur Verfügung. In Herdenmanagementprogrammen sind diese Daten zu Informationen z.B. zur Krankheitsfrüherkennung, zum Brunstverhalten oder zu Managementfehlern auf Ebene des Einzeltiers, der Tiergruppe oder der Herde aufzuwerten. Dazu sind Entscheidungsunterstützungssysteme erforderlich, die die Aufmerksamkeit des Personals auf bestimmte Tiere, Tiergruppen oder Sachverhalte im Herdenmanagement lenken. Anhand dieser Informationen muss der Betriebsleiter dann Managemententscheidungen treffen. Dabei kommt der Milchmenge als dem standardmäßig erfassten Merkmal eine überragende Bedeutung für die Bewertung des herden- und tierbezogenen Managements zu. Für diese Aufgaben steht eine Auswahl verschiedener Methoden zur Verfügung. Es werden in diesem Beitrag mit gemischten linearen Modellen, Fuzzy Logic und künstlichen neuronalen Netzen drei Methoden exemplarisch am Beispiel der Erkennung von negativen Milchmengenabweichungen vorgestellt. Dabei wird auf die notwendigen Voraussetzungen, Anwendungsmöglichkeiten und zu erwartenden Ergebnisse eingegangen.

2 Material und Methoden

Es standen Daten aus drei Betrieben zur Verfügung. Eine Kurzcharakteristik der Datenbestände ist Tabelle 1 zu entnehmen. Untersuchtes Merkmal war die Tagesmilchmenge.

Betrieb	Art	Melktechnik	Zeitraum (d)	Datensätze
Betrieb 1	Produktionsbetrieb	Automatisches Melksystem	281	32026
Betrieb 2	Produktionsbetrieb	Melkstand	935	182136
Betrieb 3	Versuchsbetrieb	Melkstand	245	10494

Tabelle 1: Übersicht über die Betriebe

Als Spezialfall eines gemischten linearen Modells [He90] wurde ein einzeltier- und laktationsspezifisches Random-Regression-Modell angewendet [AS04]. Der Laktationsverlauf wurde nach dem Ansatz von Ali & Schaeffer modelliert [AS87]. Mit den zum Zeitpunkt t geschätzten Regressionskoeffizienten wurde ein Vorhersagewert für $t+1$ berechnet und Grenzwerte anhand des Standardfehlers der Schätzung variiert. Unterschreiten dieses Grenzwerts durch die am nächsten Tag beobachtete tatsächliche Milchmenge wurde als Alarm gewertet. Die Vorhersagewerte wurden außerdem genutzt, um einen kurzfristigen aktuellen Trend für den Zeitraum $t-3$ bis $t+1$ zu berechnen und diesen mit dem beobachteten Trend für die Tagesmilchmengen ins Verhältnis zu setzen. Der so erhaltene Abweichungsfaktor wurde unter anderem als Eingabevariable in den im Folgenden beschriebenen Methoden Fuzzy Logic und neuronalen Netze verwendet.

Der Fuzzy Logic-Ansatz (vgl. [A197], [Bo03]) ermöglicht es, ein oder mehreren scharfen, exakten Merkmalswerten Zugehörigkeiten zu unscharfen linguistischen Termen ihrer Ausprägungen zuzuweisen. Mit umgangssprachlich formulierbaren Expertenregeln können den untersuchten Merkmalskombinationen entsprechende Zugehörigkeiten zu Ausprägungen der vorgesehenen Ausgabewerte zugeordnet werden. Aus diesen Zugehörigkeiten zu den Ausgabetermen kann ein exakter Ausgabewert berechnet werden, der im vorliegenden Fall Werte von 0 bis 1 annehmen kann. Als Eingabevariablen wurden die absolute und prozentuale Abweichung der Milchmenge gegenüber dem Vortag (jeweils sieben Terme von „stark negativ“ bis „stark positiv“) sowie in einer Variante der Abweichungsfaktor (fünf Terme von „stark negativ“ bis „stark positiv“) verwendet. Zugehörigkeitsfunktionen wurden sowohl allgemein als auch betriebspezifisch aufgestellt und verschiedene Regelvarianten untersucht. Als Alarm wurden Ausgabewerte von 0,5 und höher gewertet.

Mit einem künstlichen neuronalen Netz (KNN, vgl. [Bo03], [NKK96], [Pa96]) kann eine im Fuzzy Logic-Ansatz beschriebene Klassifikation von Eingabetupeln erreicht werden, jedoch ohne Zugehörigkeitsfunktionen oder Regelsysteme erstellen zu müssen. Das hier verwendete KNN besteht aus einer Eingabeschicht aus drei Neuronen (entsprechend den drei auch im Fuzzy Logic-Ansatz verwendeten Eingabevariablen), einer Zwischenschicht mit fünf Neuronen und einer Ausgabeschicht mit einem Ausgabeneuron. Die Verbindungen der Neuronen zwischen den Schichten sind mit unterschiedlichen Gewichtungen versehen, die durch Training des KNNes angepasst und auf Minimierung der Differenz von Ziel- und Ausgabewert des Netzwerkes optimiert werden. Für die Neuronen wurde eine log-sigmoide Transferfunktion gewählt, um

Ausgabewerte von 0 bis 1 zu erhalten. Auch hier wurde ein Ausgabewert von 0,5 oder höher als Alarm gewertet. Zielwerte waren die Tage mit negativen Milchmengenabweichungen. Diese wurden definiert als Tage, an denen die Milchmenge gegenüber dem Vortag und dem gleitenden 3-Tage-Mittel um 7% niedriger war.

Zur Bewertung wurden die Datensätze schließlich jeweils als wahr positiv (WP, Alarm bei Abweichung), wahr negativ (WN, kein Alarm bei keiner Abweichung), falsch positiv (FP, Alarm trotz keiner Abweichung) oder falsch negativ (FN, kein Alarm bei Abweichung) eingeordnet und entsprechende Erkennungs- ($WP/(WP+FN) \cdot 100$) und Fehlerraten ($FP/(WP+FP) \cdot 100$) sowie die Spezifität ($WN/(WN+FP) \cdot 100$) berechnet.

3 Ergebnisse

Die Ergebnisse der einzelnen Methoden sind in Tabelle 2 dargestellt.

Betrieb	Methode	Erkennungsrate	Fehlerrate	Spezifität
Betrieb 1	Gemischtes Modell	86.70	76.14	99.09
	Fuzzy Logic (allg.)	77.52	29.55	98.35
	Fuzzy & Abw.Faktor	82.81	37.28	98.72
	Fuzzy (betriebsspez.)	85.82	47.98	98.91
	Neuronales Netz	84.51	16.74	98.87
Betrieb 2	Gemischtes Modell	77.79	58.08	97.33
	Fuzzy Logic (allg.)	77.25	13.99	97.43
	Fuzzy & Abw.Faktor	69.32	6.88	96.60
	Fuzzy (betriebsspez.)	76.64	15.03	97.36
	Neuronales Netz	88.70	12.90	98.71
Betrieb 3	Gemischtes Modell	83.37	80.15	98.90
	Fuzzy Logic (allg.)	55.71	21.54	97.42
	Fuzzy & Abw.Faktor	77.40	48.32	98.62
	Fuzzy (betriebsspez.)	92.47	58.72	99.52
	Neuronales Netz	51.79	14.16	97.21

Tabelle 2: Ergebnisse der Methoden, Werte in %

Das als „Fuzzy Logic (allg.)“ bezeichnete Modell sah für alle drei Betriebe identische Zugehörigkeitsfunktionen vor, es wurden jeweils alle drei Eingabevariablen benutzt. Das Modell „Fuzzy & Abw.Faktor“ sah auf den Standardabweichungen der Milchmengenabweichungen gegenüber dem Vortag basierende betriebsspezifische Zugehörigkeitsfunktionen vor. In der Variante „Fuzzy (betriebsspezifisch)“ wurde auf den Abweichungsfaktor verzichtet. Betrieb 3 fällt durch niedrige Erkennungsraten auf, die sich durch die in diesem Betrieb geringeren mittleren Milchmengenabweichungen gegenüber dem Vortag erklären lassen. Bei einem Grenzwert von weniger als 0,5 für einen Alarm lassen sich auch hier höhere Erkennungsraten erreichen, allerdings auf Kosten einer steigenden Fehlerrate. Die hohe Spezifität aller Methoden und Modelle kommt durch die hohe Anzahl der wahr negativen Datensätze zustande.

4 Diskussion und Schlussfolgerungen

Gemischte lineare Modelle benötigen höheren Rechenaufwand und eine mehrwöchige Datenbasis, um verlässliche Vorhersagewerte zu erhalten. Bei Überschätzung der tatsächlichen Milchleistung werden jedoch gehäuft falsche Abweichungsalarme auftreten, während bei Unterschätzung Abweichungen nicht erkannt werden könnten. Beides führt zu schlechten Ergebnissen gegenüber den beiden anderen Methoden. Es zeigt sich jedoch, dass der aus diesen Vorhersagen ermittelte Abweichungsfaktor, der unabhängig von dieser Über- oder Unterschätzung ist, zur Verringerung der Fehlerrate im Fuzzy-System verwendbar ist. Das Fuzzy-System selbst ist nicht rechenaufwändig, erfordert aber Expertenkenntnisse zum Aufstellen und Anpassen der Zugehörigkeitsfunktionen und Regeln. Vor allem die Möglichkeit zur Hinzunahme weiterer Merkmale zur Verringerung der Fehlerrate im betriebsspezifischen Modell (und somit „unnötiger“ Arbeit des Betriebsleiters) ist als vorteilhaft zu erachten. Dies gilt auch für die KNNs, die ebenfalls mehrere Merkmale bei geringem Rechenaufwand gleichzeitig verarbeiten können. Expertenkenntnisse zur Erstellung von Regeln sind dazu nicht notwendig, allerdings wird eine gute Datenbasis zum Training des KNNs benötigt, in der die Zielwerte bekannt sind. Ist diese Voraussetzung gegeben, lassen sich bei Betrachtung von sowohl Erkennungs- als auch Fehlerrate von den in diesem Beitrag untersuchten Methoden die besten Ergebnisse erzielen.

Danksagung

Dieses Projekt wird durch die Deutsche Forschungsgemeinschaft (DFG) gefördert (Projektkennzeichen SP 613/4).

Literaturverzeichnis

- [Al97] Altrock, C. von: Fuzzy logic and NeuroFuzzy applications in business and finance, Prentice Hall PTR, New Jersey 1997.
- [AS87] Ali, T.E.; Schaeffer, L.R.: Accounting for covariance among test day milk yields in dairy cows. Canadian Journal of Animal Science 67, 1987; S. 637-644.
- [AS04] Ammon, C.; Spilke, J.: Vergleich von Fixed- und Random-Regression Modellen bei verschiedenen Funktionsansätzen für Laktationskurven zur Vorhersage von Milchleistungen. In (Schiefer, G.; Wagner, P.; Morgenstern, M.; Rickert, U., Hrsg.): Integration und Datensicherheit - Anforderungen, Konflikte und Perspektiven: Referate der 25. GIL Jahrestagung, Bonn 2004; S.149-152.
- [Bo03] Borgelt, C. et al.: Neuro-Fuzzy-Systeme, Vieweg, Wiesbaden 2003.
- [He90] Henderson, C.R.: Statistical method in animal improvement: historical overview. In (Gianola, D., Hammond, K., Hrsg.): Advances in Statistical Methods for Genetic Improvement of Livestock, Springer, New York 1990.
- [NKK96] Nauck, D.; Klawonn, F.; Kruse, R.: Neuronale Netze und Fuzzy-Systeme, Vieweg, Braunschweig/Wiesbaden 1996.
- [Pa96] Patterson, D.W.: Künstliche neuronale Netze: das Lehrbuch, Prentice Hall, München, London u.a. 1996.