

USO DE MODELOS DE APRENDIZADO DE MÁQUINA PARA A PREDIÇÃO DE METRITE EM BOVINOS LEITEIROS

LEONARDO MARINS¹; RÔMULO TELES FRANÇA²; MILENE LOPES DOS SANTOS³; CARLA AUGUSTA SASSI DA COSTA GARCIA⁴; ELIZA ROSSI KOMNINOU⁵; MARCIO NUNES CORRÊA⁶

¹Universidade Federal de Pelotas/NUPEEC HUB – Indmarins@gmail.com

² Universidade Federal de Pelotas/NUPEEC HUB – romulotfranca@gmail.com

³ Universidade Federal de Pelotas/NUPEEC HUB – milenelopessantos0312@gmail.com

⁴ Universidade Federal de Pelotas/NUPEEC HUB – gutascgarcia@gmail.com

⁵ Departamento de Clínicas Veterinária (UFPel) - elizarossikom@gmail.com

⁶ Departamento de Clínicas Veterinária (UFPel) – marcio.nunescorreia@gmail.com

1. INTRODUÇÃO

A metrite é uma doença de elevada prevalência em bovinos leiteiros, caracterizada como a inflamação das camadas do útero nos primeiros 21 dias pós-parto. Seu diagnóstico pode ser realizado a partir da observação do corrimento vaginal de aspecto aquoso, vermelho-amarronzado, purulento, podendo ou não conter sangue e de odor fétido (SHELDON et al., 2006). Além disso, sinais sistêmicos como febre, apatia e anorexia também podem ser observados. A metrite gera consequências negativas como redução na produção de leite, menor desempenho reprodutivo e maior chance de descarte precoce de animais (VÁRHIDI et al., 2024).

O diagnóstico precoce de metrite é essencial para a adoção de estratégias que possam evitar o agravamento do quadro clínico e, dessa forma, minimizar os impactos negativos gerados por esta doença. Neste sentido, a detecção de doenças por meio de algoritmos de aprendizado de máquina vem crescendo na área da saúde (DELPINO et al., 2022). O crescente uso de tecnologias aplicadas à pecuária, permitiu um grande acúmulo de dados, os quais podem ser utilizados para o desenvolvimento de modelos preditivos direcionados à saúde animal (DE VRIES et al., 2023). Estes modelos apresentam diversas vantagens sobre os métodos estatísticos tradicionais, como o fato de lidarem bem com grandes conjuntos de dados, grande número de variáveis independentes e conseguirem identificar padrões não lineares entre as variáveis. Dessa forma, os modelos de aprendizado de máquina podem ser uma ferramenta para fazer previsões com elevado nível de acerto (BI et al., 2019).

Na pecuária leiteira, inúmeros estudos vêm sendo realizados para a detecção precoce de mastite e afecções podais, porém o diagnóstico de doenças uterinas, através de aprendizado de máquina, ainda é pouco investigado (DE VRIES et al., 2023; PRIM et al., 2024). Assim, objetivo do presente estudo foi desenvolver modelos de predição através de algoritmos de aprendizado de máquina, com dados relacionados ao manejo e ambiência, para detecção precoce de casos de metrite em bovinos leiteiros.

2. METODOLOGIA

Os dados utilizados neste estudo foram coletados em 46 propriedades leiteiras durante um estudo epidemiológico conduzido na mesorregião Noroeste do estado do Rio Grande do Sul, entre agosto de 2021 e agosto de 2022. As propriedades incluídas no estudo possuíam até 4 módulos fiscais (1 módulo fiscal

= 20 hectares) e contavam preponderantemente com mão de obra familiar. O diagnóstico de metrite era realizado durante o exame ginecológico, a partir da presença de descarga vaginal aquosa, vermelho amarronzada, mucopurulenta ou sanguinolenta e com odor pútrido. Foram incluídos 1436 animais, sendo que destes 141 apresentaram episódios de metrite, chegando a uma incidência de 9,8%.

Ao todo foram selecionadas 22 variáveis preditoras, as quais estavam relacionadas ao manejo, ambiência nas instalações e desempenho das propriedades. As variáveis categóricas foram o fornecimento de dieta pré-parto em canzil (sim x não), fornecimento de dieta pré-parto em local coberto (sim x não), avaliação de sobras no cocho (sim x não), avaliação de pH da urina no pré-parto (sim x não), presença de baia maternidade (sim x não), fornecimento de drench imediatamente após o parto (sim x não), fornecimento de água (antes da ordenha; após a ordenha; antes e após a ordenha; sem oferta de água antes e depois da ordenha), método de resfriamento da sala de espera (sombra; sombra e ventilação; sombra, ventilação e aspersão) e raça (Holandesa, Jersey e Gir).

Já as variáveis numéricas foram todas relacionados ao rebanho, sendo o escore de condição corporal médio pré e pós-parto (escala de 1 a 5), produção de leite média diária, contagem de células somáticas média, teor médio de gordura e proteína do leite, período de espera voluntário, período seco, período de pré-parto, intervalo entre partos médio e número de tratamentos ofertados diariamente. A variável predita foi uma variável categórica dicotômica relacionada ao diagnóstico de metrite (sim x não).

As etapas de pré-processamento, modelagem e avaliação dos modelos foram realizadas no Python (Python Software Foundation), em conformidade com as instruções TRIPOD+IA. O conjunto de dados foi dividido em conjunto de treino e conjunto de teste, utilizando a função *train_test_split* do SkitLearn. Posteriormente, foi realizada uma subamostragem para balanceamento das classes da variável predita, a partir da função *randomundersampler*, totalizando 282 instâncias (141 de cada classe). As variáveis preditoras categóricas foram transformadas com a função *OneHotEncoder* e as variáveis preditoras numéricas foram standardizadas com a função *StandardScaler*.

Foram utilizados quatro modelos de aprendizado de máquina: Regressão Logística, Floresta Aleatória, Gradient Boosting e XGBoost. Após o treinamento e teste dos modelos, uma matriz de confusão foi construída e foram calculadas as métricas para a avaliação do desempenho dos modelos de predição sobre o conjunto de teste, conforme Tabela 1. Além disso, foram construídas as curvas ROC para o cálculo da área sob a curva (AUC).

Tabela 1. Métricas para a avaliação do desempenho dos modelos de predição.

Métrica	Fórmula
Acurácia	$(VP + VN) / (VP + VN + FP + FN)$
Recall	$VP / (VP + FN)$
Precisão	$VP / (VP + FP)$
F1 Score	$(2 * Precisão * Recall) / (Precisão + Recall)$

VP = verdadeiro positivo; VN = verdadeiro negativo; FP = falso positivo; FN = falso negativo

3. RESULTADOS E DISCUSSÃO

Os resultados das métricas de avaliação dos modelos de aprendizado de máquina referentes às predições realizadas sobre o conjunto de teste estão

apresentados na Tabela 2. O modelo de Regressão Logística apresentou os melhores resultados de Acurácia, Recall, F1 Score e AUC, enquanto o modelo de Gradient Boosting apresentou a melhor Precisão.

Tabela 2. Métricas de avaliação de desempenho de diferentes modelos de aprendizado de máquina para a predição de metrite em bovinos leiteiros.

Modelo	Acuária	Precisão	Recall	F1 Score	AUC
Regressão Logística	61,9%	58,5%	70,5%	64,0%	67,1%
Floresta Aleatória	56,3%	60,0%	55,2%	57,3%	64,2%
Gradient Boosting	57,7%	62,8%	56,4%	59,4%	60,6%
XGBoost	59,1%	55,5%	73,5%	63,2%	62,6%

AUC = área sobre a curva

Em um levantamento realizado por SLOB et al. (2021) sobre as diferentes aplicações da Inteligência Artificial na pecuária leiteira, os autores verificaram que os modelos de aprendizado de máquina mais utilizados são algoritmos baseados em regressão, árvores de decisão e redes neurais artificiais. Os modelos de Regressão Logística são largamente utilizados em estudos epidemiológicos para identificar relação de causalidade entre uma ou mais variáveis independentes com uma variável desfecho categórica dicotômica. Estes modelos também são utilizados em uma abordagem de aprendizado de máquina com o intuito de realizar classificações (BI et al., 2019). Ainda que seja considerado um modelo mais simples em relação aos demais utilizados no presente estudo, foi o que apresentou o melhor desempenho na predição de metrite, obtendo uma AUC igual a 67,1%.

As variáveis preditoras utilizadas para a construção dos modelos eram relacionadas ao ambiente, manejos das propriedades, principalmente aqueles relacionados aos períodos de pré e pós-parto, e ao desempenho produtivo e reprodutivo. Estudos realizados previamente para a detecção de metrite utilizaram dados de comportamento, provenientes de acelerômetros alocados junto aos animais. MERENDA et al. (2021) desenvolveram um modelo de Regressão Logística com uma AUC igual a 82% para a predição de animais sob risco de metrite, a partir de dados relacionados aos animais e de comportamento. Já VIDAL et al. (2023), comparando três modelos de aprendizado de máquina para a detecção de metrite, atingiram um F1 Score acima de 90%, utilizando um algoritmo de Floresta Aleatória, a partir de dados de comportamento. A combinação de dados de manejo e ambiência e dados relacionados aos animais tem o potencial para o desenvolvimento de modelos com elevada acurácia, podendo ser aplicados aos sistemas utilizados nas propriedades.

O diagnóstico de metrite é normalmente realizado pelos profissionais das propriedades, através da análise do aspecto do corrimento vaginal e outros sinais clínicos. Dessa forma, podem ocorrer diagnósticos incorretos ou a não identificação de episódios de metrite, acarretando efeitos negativos sobre a saúde e desempenho dos animais ou o uso desnecessário de antimicrobianos. Algoritmos de aprendizado de máquina podem auxiliar na identificação de animais sob risco de metrite, possibilitando ações preventivas, como destinar maior atenção aos animais identificados, separando-os dos demais, realizar exames ginecológicos com maior frequência durante o período de espera voluntário e fornecer suplementos e aditivos nutricionais, a fim de estimular o sistema imune. Neste contexto, a Inteligência Artificial está inserida na chamada Pecuária de Precisão, a qual tem potencial de aumentar a eficiência produtiva das propriedades leiteiras,

além de propiciar o uso racional de antibióticos e promover a saúde e o bem-estar animal (GEHLOT et al., 2022).

4. CONCLUSÕES

No presente estudo, foi possível criar modelos de aprendizado de máquina para predição de metrite, utilizando dados relacionados ao ambiente e manejo de propriedades leiteiras. Apesar do desempenho dos modelos não ter sido suficiente para empregá-los na rotina clínica, foi possível comprovar seu potencial para auxiliar na detecção precoce de metrite. Novos estudos devem ser realizados testando diferentes algoritmos, maiores conjuntos de dados, diferentes variáveis preditoras, hiperparâmetros e técnicas de treinamento e validação para gerar modelos com potencial para a implementação na rotina de propriedades leiteiras.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- BI, Q.; GOODMAN, K. E.; KAMINSKY, J.; LESSLER, J. What is machine learning? A primer for the epidemiologist. **American Journal of Epidemiology**, v.188, n.12, p.2222–2239, 2019.
- DELPINO, F. M.; COSTA, K.; FARIAS, S. R., CHIAVEGATTO FILHO, A. D. P.; ARCÊNCIO, R. A.; NUNES, B. P. Machine learning for predicting chronic diseases: a systematic review. **Public Health**, v.205, p.14–25, 2022.
- DE VRIES, A.; BLIZNYUK, N.; PINEDO, P. Invited Review: Examples and opportunities for artificial intelligence (AI) in dairy farms. **Applied Animal Science**, v.39, n.1, p.14–22, 2023.
- GEHLOT, A.; MALIK, P. K.; SINGH, R.; AKRAM, S. V.; ALSUWIAN, T. Dairy 4.0: Intelligent Communication Ecosystem for the Cattle Animal Welfare with Blockchain and IoT Enabled Technologies. **Applied Sciences (Switzerland)**, v.12, n.14, 2022.
- MERENDA, V. R.; RUIZ-MUNOZ, J.; ZARE, A.; CHEBEL, R. C. Predictive models to identify Holstein cows at risk of metritis and clinical cure and reproductive/productive failure following antimicrobial treatment. **Preventive Veterinary Medicine**, 194, 2021.
- SHELDON, I. M.; LEWIS, G. S.; LEBLANC, S.; & GILBERT, R. O. Defining postpartum uterine disease in cattle. **Theriogenology**, v.65, n.8, p.1516–1530, 2006.
- SLOB, N.; CATAL, C.; KASSAHUN, A. Application of machine learning to improve dairy farm management: A systematic literature review. **Preventive Veterinary Medicine**, v.187, 2021.
- VÁRHIDI, Z.; CSIKÓ, G.; BAJCSY, Á. C.; JURKOVICH, V. Uterine Disease in Dairy Cows: A Comprehensive Review Highlighting New Research Areas. **Veterinary Sciences**, v.11, n.2, 2024.
- VIDAL, G.; SHARPBACK, J.; PINEDO, P.; TSAI, I. C.; LEE, A. R.; MARTÍNEZ-LÓPEZ, B. Comparative performance analysis of three machine learning algorithms applied to sensor data registered by a leg-attached accelerometer to predict metritis events in dairy cattle. **Frontiers in Animal Science**, v.4, 2023.
- PRIM, J. G.; CASARO, S.; MIRZAEI, A.; GONZALEZ, T. D.; de OLIVEIRA, E. B.; VERONESE, A.; CHEBEL, R. C.; SANTOS, J. E. P.; JEONG, K. C.; LIMA, F. S.; MENTA, P. R.; MACHADO, V. S.; GALVÃO, K. N. Application of behavior data to predictive exploratory models of metritis self-cure and treatment failure in dairy cows. **Journal of Dairy Science**, v.107, n.7, p.4881–4894, 2024.