

UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE VETERINÁRIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA

Vanessa Amorim Teixeira

**ESTRATÉGIAS DE PREDIÇÃO E DETECÇÃO DE ANAPLASMOSE BOVINA COM
TECNOLOGIAS DE PRECISÃO**

Belo Horizonte
2022

Vanessa Amorim Teixeira

**ESTRATÉGIAS DE PREDIÇÃO E DETECÇÃO DE ANAPLASMOSE BOVINA
COM TECNOLOGIAS DE PRECISÃO**

Versão final

Tese apresentada ao Programa de Pós-Graduação em Zootecnia da Escola de Veterinária da Universidade Federal de Minas Gerais, como requisito parcial para obtenção do grau de Doutora em Zootecnia.

Área de concentração: Produção Animal

Orientadora: Profa. Dra. Ângela Maria Quintão Lana

Coorientadores: Prof. Dr. Luiz Gustavo Ribeiro Pereira
Prof. Dr. Lúcio Carlos Gonçalves

**Belo Horizonte
2022**

T266e

Teixeira, Vanessa Amorim, 1989-

Estratégias de predição de anaplasrose bovina com tecnologias de precisão / Vanessa Amorim
Teixeira . – 2022.

120 f. il

Orientadora: Ângela Quintão Lana

Coorientadores: Lúcio Carlos Gonçalves

Luiz Gustavo Ribeiro Pereira.

Bibliografias: f. 40 – 54

Tese (Doutorado) apresentada à Escola de Veterinária da Universidade Federal de Minas Gerais para obtenção do título de Doutora.

1. Bovino – Doenças - Teses - 2. Anaplasrose - Teses – 3. Veterinária - Teses - I. Lana, Ângela Quintão – II. Gonçalves, Lúcio Carlos – III. Pereira, Luiz Gustavo Ribeiro - IV. Universidade Federal de Minas Gerais, Escola de Veterinária – V. Título.

CDD – 636.089

Bibliotecária responsável Cristiane Patrícia Gomes – CRB2569

Biblioteca da Escola de Veterinária, Universidade Federal de Minas Gerais.



UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE VETERINÁRIA
COLEGIADO DO CURSO DE PÓS-GRADUAÇÃO EM ZOOTECNIA

FOLHA DE APROVAÇÃO

ESTRATÉGIAS DE PREDIÇÃO DE ANAPLASMOSE BOVINA COM TECNOLOGIAS DE PRECISÃO

Vanessa Amorim Teixeira

Tese de Doutorado defendida e aprovada, no dia **18 de fevereiro de 2022**, pela Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Zootecnia da Universidade Federal de Minas Gerais, constituída pelos seguintes professores:

DRA. ÂNGELA MARIA QUINTÃO LANA - Orientadora
Universidade Federal de Minas Gerais

DR. JOÃO PAULO PACHECO RODRIGUES
Universidade Federal do Sul e Sudeste do Pará

DRA. FERNANDA CAROLINA FERREIRA
University of California, Davis

DRA. CAMILA DE VALGAS E BASTO CASTRO
Escola de veterinária da UFMG/ Ciência Animal/ Parasitologia

DRA. MARIANA MAGALHÃES CAMPOS
Embrapa Gado de Leite

DR. LUIZ GUSTAVO RIBEIRO PEREIRA
Embrapa Gado de Leite

Belo Horizonte, 18 de fevereiro de 2022.

*A Deus, pela presença constante em minha vida,
aos meus familiares e amigos que me apoiaram e
incentivaram em todos os momentos.*

Dedico

AGRADECIMENTOS

À Deus, que me iluminou e me deu forças nos momentos em que mais precisei para vencer os obstáculos surgidos durante essa caminhada.

Aos meus pais Luciano e Marlene, que são meu porto seguro e minha vida, tudo que sou e que conquistei devo a eles, e faço por eles, muito obrigada por me ensinarem diariamente o significado da palavra resiliência e por não terem me deixado desistir nos momentos de fragilidade.

À toda minha família, principalmente minha vó Olga, pelo amor, presença e apoio incondicional em todos os momentos de minha vida.

Aos meus avós Elvira e José Amorim que já estão ao lado de Deus, sempre cuidando de mim dos céus.

À Cybele por não ter me deixado jogar pedra em avião e ter me mantido com um mínimo de sanidade mental para suportar os desafios do doutorado.

À Ane Cacique e a Jaqueline Satyro por estarem comigo nos momentos difíceis e se tornarem amigas, conselheiras e ancoras nas tempestades.

À minha orientadora professora Ângela Lana, pela oportunidade, confiança, atenção e orientações fundamentais. Obrigada pela paciência, amizade e disponibilidade.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes) pelo suporte financeiro para realização desta pesquisa e concessão da bolsa de doutorado.

À Embrapa Gado de Leite - CNPGL, pelo suporte financeiro e pela estrutura para a execução experimental e análises.

Aos Funcionários do Campo Experimental José Henrique Bruschi pelo acolhimento, ajuda e amizade, a todos, que se tornaram minha segunda família.

Aos pesquisadores da Embrapa Gado de leite em especial a Luiz Gustavo Ribeiro Pereira e Thierry Ribeiro Tomich pela amizade, oportunidade, paciência e principalmente pela confiança, foram os primeiros a acreditar que eu seria capaz, mesmo quando nem eu acreditava em mim, muito obrigada.

Ao João Paulo Pacheco Rodrigues por ter me abraçado nessa jornada acadêmica desde o mestrado, ter me adotado e ter se tornado um amigo, um confidente um orientador de verdade e por saber tirar o melhor de mim, muito obrigada.

Ao querido e amado professor John Furlong que me ensinou tanto e muito além disso me mostrou que sou capaz de romper barreiras que nem eu imaginava que era capaz, ele me ensinou a vencer o medo a ter confiança e me mostrou o poder de um apoio e trabalho em equipe, sem dúvidas se venci foi porque Deus te colocou no meu caminho.

À minha amiga e parceira Gleicinha que foi meu grande apoio durante a fase mais difícil de execução experimental, obrigada por vestir a camisa da responsabilidade junto comigo e ser minha força em todos os momentos, Deus sabe o que passamos juntas e sabe que um dia vamos colher frutos de tudo que plantamos.

A todos os estagiários que passaram por minhas mãos e que ajudaram muito nos momentos difíceis tornando os dias mais leves, depois se tornaram uma família em especial Janaína, Gabriela, Romani, Leo, Wuiley, Lavinea, Luanda, Karol, José, Bianca, Barbara, Alisson, Ana keren, Carol, Roni, Rafael e tantos outros meu muito obrigada

Aos Mestres e hoje amigos José Avelino, Rogério Carvalho de Souza, Rafahel Carvalho de Souza, Alex Matos Teixeira, Diogo Jaime, Ronaldo Braga Reis, Lúcio Carlos Gonçalves, Lívio Molina, Bolivar Nóbrega de Faria, Joana Ferrez e Sandra Gesteira Coelho pela amizade, experiência, paciência e todos os conselhos em todos os momentos da minha caminhada.

Aos grandes amigos da vida, pelo convívio, amizade e descontração durante esta caminhada. Em especial aos amigos Mila, Rozi, Edmeia, Alírio, Thiago, Joelma, Tânia, Amana, Marina, Day, Filipe, Beta, Aline, Isabela, Diego, Bela, Flávia, Isadora, Fred, Tadeu, Lili, Giovanna, Luiz, Leandro Luiz, Pedro e Rô.

Ao professor João Doréa e a Universidade de Winsconsin pela confiança e oportunidade.

Ao colegiado da Pós-graduação em Zootecnia e á Escola de Veterinária da UFMG, por todo apoio, acolhida e disponibilidade.

À banca examinadora pela valiosa contribuição e disponibilidade.

Finalmente, a todos que direta ou indiretamente colaboraram para a realização desse trabalho os meus sinceros agradecimentos. Muito obrigada e que Deus retribua e abençoe a todos.

*Ando devagar porque já tive pressa
Levo esse sorriso porque já chorei demais
Hoje me sinto mais forte, mais feliz, quem sabe
Só levo a certeza de que muito pouco eu sei
Eu nada sei.
Conhecer as manhãs e as manhãs,
O sabor das massas e das maçãs,
É preciso amor pra poder pulsar,
É preciso paz pra poder sorrir,
É preciso a chuva para florir
Penso que cumprir a vida seja simplesmente
Compreender a marcha e ir tocando em frente
Como um velho boiadeiro levando a boiada
Eu vou tocando os dias pela longa estrada eu vou
Estrada eu sou.
Todo mundo ama um dia todo mundo chora,
Um dia a gente chega, no outro vai embora
Cada um de nós compõe a sua história
Cada ser em si carrega o dom de ser capaz
De ser feliz.*

(Renato Teixeira, Tocando em frente).

APRESENTAÇÃO

Esta tese foi estruturada em um tópico de introdução geral, três capítulos e um tópico de considerações finais.

No capítulo 1 foi elaborada uma revisão bibliográfica que apresenta o estado da arte sobre anaplasmoses e tecnologias de precisão e métodos de inteligência artificial aplicado a ciência animal. Neste texto, o objetivo principal foi preparar o leitor para compreender os temas abordados nos capítulos 2 e 3.

No capítulo 2 é apresentado o estudo de aplicação de sensores de atividade e ruminação para detecção precoce de anaplasmoses em bezerras leiteiras.

No capítulo 3 é apresentado estudo focado na comparação de dispositivos (brinco ou colar) para o desenvolvimento de modelos preditivos para detecção precoce de anaplasmoses em bezerras leiteiras.

Os capítulos 2 e 3 foram apresentados no formato de artigos científicos, estruturados de acordo com as normas da revista *Journal of Dairy Science* (Capítulo 2) e *Journal of Dairy Science Communications* (Capítulo 3).

Estratégias de predição e detecção de anaplasnose bovina com tecnologias de precisão

RESUMO

A anaplasnose bovina é uma doença endêmica que causa prejuízos diretos nos sistemas de produção animal. A detecção da anaplasnose é realizada por análises clínicas e laboratoriais. Essas metodologias tradicionais são trabalhosas, caras e difíceis de implementar sistematicamente em operações de grande escala. *Trabalho 1:* Os objetivos deste estudo foram avaliar: i) os efeitos da anaplasnose na ruminação (RUM) e atividade (ACT) obtidos pelo colar Hr-Tag em bezerras leiteiras; e ii) a capacidade preditiva das redes neurais recorrentes (RNN) na identificação precoce da anaplasnose. Adicionalmente foi investigado: ii.a) o efeito da duração da série temporal anterior ao diagnóstico da doença (5, 7, 10 ou 12 dias consecutivos) no desempenho preditivo do RNN; e ii.b) o quão precoce a anaplasnose pode ser detectada em bezerros leiteiros (5, 3 e 1 dia de antecedência). Vinte e três bezerras com idade média de 119 dias e pesando 148 kg foram desafiadas com 2×10^7 eritrócitos infectados com a cepa UFMG1 (GenBank nº EU676176) isolada de *Anaplasma marginale*. Após a inoculação, os animais foram monitorados diariamente pela avaliação volume globular (VG). O menor valor de VG ($14 \pm 1,8\%$) e o achado de riquetsias em esfregaços sanguíneos foram utilizados como critérios para classificar um animal como doente (d0). Os dados de ruminação e atividade foram coletados de forma contínua e automática em intervalos de 2 h, usando colares SCR Heattime Hr. Duas séries temporais (TS) foram construídas incluindo a última sequência de -5, -7, -10 ou -12d precedendo d0 ou compreendendo uma sequência de 5, 7, 10 ou 12d selecionada aleatoriamente em uma janela de -50 a -15d antes do d0 para garantir uma sequência de dias em que a VG foi considerada normal ($32 \pm 2,4\%$). Foi adotada a validação cruzada Leave-One-Animal-Out. A doença da anaplasnose reduziu 34% e 11% do RUM e ACT, respectivamente. A acurácia (ACC), sensibilidade (SEN) e especificidade (SPE) do LSTM na detecção de anaplasnose variou de 87 a 98%, 83 a 100% e 83 a 100%, respectivamente, usando dados da ruminação. Para os dados do ACT, a ACC, SEN e SPE variaram de 70 a 98%, 61 a 100% e 74 a 100%, respectivamente. A combinação de RUM e ACT, bem como o uso de séries temporais mais longas não melhoraram o desempenho preditivo dos modelos. A acurácia e a sensibilidade na

predição da anaplasnose em até 3 dias antes do diagnóstico clínico (d0) foram superiores a 80%, confirmando a possibilidade de identificação precoce da doença. Em um segundo estudo, Trabalho 2: foi avaliada a capacidade preditiva da RNN com base em dados de RUM e ACT recuperados de dois dispositivos: colar (Heatime HR) e brinco (eSense Flex®). Quatorze bezerros leiteiros (119 dias de idade e 148 kg) foram equipados com ambos os dispositivos e desafiados na mesma metodologia do primeiro estudo. A ACC, SEN e SPE para previsões em 0d foram semelhantes para colar e brinco (100%) usando dados de ACT. As previsões baseadas no ACT para -3d no avanço diminuem 21% (etiqueta auricular) e 29% (colar) o ACC em relação aos modelos 0d. Quando os dados do RUM foram usados, os valores de ACC, SEN e SPE foram menores em comparação com os dados de ACT. Os modelos desenvolvidos com dados de ambos os dispositivos alcançaram alta qualidade preditiva e foram capazes de detectar anaplasnose com 3 dias de antecedência. Comprovando o potencial dos dispositivos para a identificação precoce da anaplasnose. Podendo impactar positivamente a lucratividade dos produtores de leite e o bem-estar animal.

Palavras-chave: Inteligência artificial. Aprendizado de máquina. Sensores. *Anaplasma marginale*.

Strategies for predicting and detection of bovine anaplasmosis with precision technologies

ABSTRACT

Bovine anaplasmosis is a widely distributed disease and the severity of clinical signs can cause direct damage to production systems worldwide. The detection of anaplasmosis is performed by clinical and laboratory analysis. These traditional methodologies are cumbersome, expensive, and difficult to implement systematically in large-scale operations. The objectives of this study were to evaluate: i) rumination (RUM) and activity (ACT) data collected by Hr-Tag in calves exposed to anaplasmosis; and ii) the predictive capacity of recurrent neural networks (RNN) in the early identification of anaplasmosis. Additionally, we investigated: ii.a) the effect of the duration of the time series prior to the diagnosis of the disease (5, 7, 10 or 12 consecutive days) on the predictive performance of the RNN; and ii.b) how early anaplasmosis disease can be detected in dairy calves (5, 3 and 1 day in advance). Twenty-three heifers with a mean age of 119 days and weighing 148 kg were challenged with 2×10^7 erythrocytes infected with the UFMG1 strain (GenBank n° EU676176) isolated from *Anaplasma marginale*. After inoculation, the animals were monitored daily by assessing packed cell volume (VG). The lowest VG value ($14 \pm 1.8\%$) and the finding of rickettsiae on blood smears were used as criteria to classify an animal as sick (d0). Rumination and activity data were collected continuously and automatically at 2 h intervals, using SCR Heattime Hr collars. Two time series (TS) were constructed including the last sequence of -5, -7, -10 or -12d preceding d0 or comprising a sequence of 5, 7, 10 or 12d selected randomly in a window of -50 to -15d before of d0 to ensure a sequence of days in which VG was considered normal ($32 \pm 2.4\%$). The quality of prediction was evaluated by the Long Short-Term Memory (LSTM) method and by Leave-One-Animal-Out cross-validation. Anaplasmosis disease reduced 34% and 11% of RUM and ACT, respectively. The precision (ACC), sensitivity (SEN) and specificity (SPE) of the LSTM in detecting anaplasmosis ranged from 87 to 98%, 83 to 100% and 83 to 100%, respectively, using rumination data. For ACT, ACC, SEN and SPE data, they ranged from 70 to 98%, 61 to 100% and 74 to 100%, respectively. The combination of RUM and ACT, as well as the use of longer time series, did not improve the predictive performance of the models. The accuracy and sensitivity in predicting anaplasmosis up to 3 days before the clinical diagnosis (d0) were greater

than 80%, confirming the possibility of early identification of the disease. In a second study, the predictive capacity of the RNN was evaluated based on RUM and ACT data retrieved from two devices: necklace (Heatime HR) and earring (eSense Flex®). Fourteen dairy calves (119 days old and 148 kg) were equipped with both devices and challenged in the same methodology as in the first study. ACC, SEN and SPE for predictions at 0d were similar for necklace and earring (100%) using ACT data. ACT-based predictions for -3d on advancement decrease the ACC by 21% (ear tag) and 29% (paste) over 0d models. When the RUM data were used, the ACC, SEN and SPE were lower compared to the ACT data. The specific RNN models developed to detect anaplasmosis for both devices achieved high predictive quality and were able to detect anaplasmosis 3 days in advance. Such achievements indicate the great potential of wearable sensors in the early identification of anaplasmosis diseases. This could positively impact dairy farmers' profitability and animal welfare.

Keywords: Artificial intelligence. Machine learning. Sensors. *Anaplasma marginale*.

LISTA DE ILUSTRAÇÕES

3.1 Artigo 1 - Using activity and rumination data for early detection of anaplasmosis disease in dairy heifer calves	55
Figure 1 - Strategy used for hyperparameter search and model training and testing.....	84
Figure 2 - Effects of <i>Anaplasma marginale</i> inoculation on packed cell volume, rickettsemia and rectal temperature in dairy heifer calves according to days relative to sickness.....	85
Figure 3 - Effects of <i>Anaplasma marginale</i> inoculation on rumination time and activity index measured by SCR Heat time Hr® collars in dairy heifer calves according to days relative to sickness.....	86
Figure 4 - Rumination time and activity index measured by SCR Heat time Hr® collars in periods of 12 random days of healthy time (green) and 12 days before sickness (red) in dairy heifer calves.....	87
3.2 Artigo 2 - Developing predictive models for early detection of anaplasmosis based on data from collar or ear tag accelerometers in dairy heifer calves.....	103
Figure 1 - Scatter plots and histograms for contrasting rumination time and activity measured by Collars (Hr-Tag system) and Ear tags (eSense Flex system) in calves facing anaplasmosis.....	115
Figure 2 - Description of clinical characteristics (A, globular volume; B, rickettsemia; C, rectal temperature) and Collar or Ear tag data (D, rumination time; E, activity; F, health alerts) observed in calves as a function of days relative to clinical diagnosis (pink dotted line) of anaplasmosis.....	116
Figure 3 - Accuracy, specificity, and sensitivity of different recurrent neural networks on detecting anaplasmosis in calves based on rumination time or activity data collected from Collars or Ear tags in different days relative to clinical diagnosis.....	117

LISTA DE TABELAS

3.1 Artigo 1 - Using activity and rumination data for early detection of anaplasmosis disease in dairy heifer calves55

Table 1 - Performance of different recurrent neural network models based on rumination time data to detect anaplasmosis using different time series length at different days relative to sickness (DRS) in dairy heifer calves.....88

Table 2 - Performance of different recurrent neural network models based on activity index data to detect anaplasmosis using different time series length at different days relative to sickness (DRS) in dairy heifer calves.....89

Table 3 - Performance of different recurrent neural network models based on rumination time and activity index data to detect anaplasmosis using different time series length at different days relative to sickness (DRS) in dairy heifer calves.....90

Supplementary material – Artigo 1.....91

Table 1 - Models performance on the test set using activity, rumination, and activity + rumination behavior for five, seven, ten- and twelve-days time series length in dairy calves on the day of the event.....91

Table 2 - Models performance to predict health status for Anaplasmosis one day before the event using activity, rumination, and activity + rumination behavior considering five, seven, ten and twelve days time series length in dairy calves.....93

Table 3 - Models performance to predict health status for Anaplasmosis two days before the event using activity, rumination, and activity + rumination behavior considering five, seven, ten and twelve days time series length in dairy calves.....95

Table 4 - Models performance to predict health status for Anaplasmosis three days before the event using activity, rumination, and activity + rumination behavior considering five, seven, ten and twelve days time series length in dairy calves.....97

Table 5 - Models performance to predict health status for Anaplasmosis four days before the event using activity, rumination, and activity + rumination behavior considering five, seven, ten and twelve days time series length in dairy calves.....99

Table 6. Models performance to predict health status for Anaplasmosis five days before the event using activity, rumination, and activity + rumination behavior considering five, seven, ten and twelve days time series length in dairy calves.....101

LISTA DE SIGLAS E ABREVIATURAS

%	Porcentagem
μg	Micrograma
$^{\circ}\text{C}$	Grau centígrado
CEUA	Comitê de Ética em Experimentação Animal
CV	Coefficiente de variação
DMSO	Dimetilsulfóxido
DNA	Ácido desoxirribonucleico
EDTA	Ácido etilenodiamino tetra-acético
ELISA	Ensaio imunossorventes ligados a enzimas
h	horas
IFN- γ	Interferon gama
IgG	Imunoglobulina da classe G
IL2/IL12	Interleucina do tipo 2/ tipo 12
Kg	Kilograma
mg	Miligrama
PCR	Polimerase Chain Reaction (Reação em cadeia da polimerase)
RIFI	Reação de imunofluorescência indireta
Riq.	Riquetsemia
TR	Temperatura retal
UFMG	Universidade Federal de Minas Gerais
VG	Volume globular, hematócrito
PIB	Produto Interno Bruto
TPB	Tristeza Parasitária Bovina
SPP	Espécies
EX	Exemplo
PPP	Período Pré-Patente
PP	Período de Patência
mL	Mililitro
CF	Método de fixação de complemento
CAT	Teste de aglutinação do cartão
GPS	Sistema global de navegação por satélite
EUA	Estados Unidos da América
RFID	Radiofrequência

Vs	Versus
Min	Minutos
IA	Inteligência Artificial
ML	Machine Learning
RNA	Rede Neural Artificial
MLP	Camada Múltipla <i>Perceptron</i>
PCV	Packed cell volume
RUM	Rumination
ACT	Activity
RNN	Recurrent neural networks
TS	Time-series
LSTM	Long Short-Term Memory
LOAOCV	Leave-One-Animal-Out Cross-Validation
ACC	Accuracy
SEN	Sensitivity
SPE	Specificity
CP	Proteína Total
NDF	Nutrientes digestíveis totais
TMR	Total mixed ration
D	Dias
CHTC	UW-Madison Center for High Throughput Computing
PPV	Positive predicted value
NPV	Negative predicted value
PFT	Precision farming technologies

SUMÁRIO

1 INTRODUÇÃO GERAL	20
2 REVISÃO BIBLIOGRÁFICA	21
2.1 Pecuária no Brasil e no mundo	21
2.2 Anaplasmosse bovina	21
2.2.1 Patógeno e vetor	21
2.2.2 Transmissão	22
2.2.3 O ciclo da anaplasmosse	23
2.2.4 Manifestações clínicas da anaplasmosse.....	24
2.2.5 Métodos de diagnóstico da anaplasmosse.....	26
2.2.6 Impactos econômicos da anaplasmosse	27
2.3 Adoção de tecnologias na atividade pecuária	28
2.3.1 Pecuária de precisão	28
2.3.2 Classificação de sensores	28
2.3.3 Fatores que influenciam no uso de sensores.....	29
2.3.4 Perfil de utilização dos sensores	30
2.3.5 Sensores para o monitoramento de alterações na saúde animal	31
2.3.6 Cria e recria	33
2.4 Processamento e análise dos dados	34
2.4.1 Inteligência artificial.....	35
2.4.2 Aprendizado de máquina (<i>Machine Learning</i>).....	36
2.4.3 Rede neural artificial	38
2.5 Referências bibliográficas	40
3 ARTIGOS	55
3.1 Artigo 1 - Using activity and rumination data for early detection of anaplasmosis disease in dairy heifer calves	55

3.2 Artigo 2 - Developing predictive models for early detection of anaplasmosis based on data from collar or ear tag accelerometers in dairy heifer calves	103
4 CONSIDERAÇÕES FINAIS.....	118
ANEXO A – Ciclo biológico da anaplasnose	119
ANEXO B – Artigos e resumos apresentados em eventos.....	120

1 INTRODUÇÃO GERAL

A agricultura e a pecuária são as principais atividades econômicas de diversos países (SPARE *et al.*, 2020). Entretanto, a pecuária tem a produtividade desafiada constantemente por doenças como a anaplasmose, a pneumonia e a diarreia em animais jovens. A anaplasmose bovina é uma doença de grande relevância e de impacto na saúde dos animais de produção. A incidência e a gravidade dos sinais clínicos podem acarretar prejuízos diretos na produção devido ao aumento nas taxas de morbidade e mortalidade (OIE, 2017; ZABEL; AUGUSTO, 2018).

Os produtores têm utilizado as avaliações visuais e o exame clínico como forma de diagnóstico das principais enfermidades que acometem os bovinos. Entretanto, esses métodos quando aplicados em grandes rebanhos demandam recursos econômico, além de tempo e de mão-de-obra (URTON *et al.*, 2005). A pecuária de precisão surge como alternativa e oferece tecnologias automatizadas para diagnóstico e predição precoce das doenças, evitando ou reduzindo as taxas de descarte dos animais, a interferência na produção e no custo do tratamento (DENG *et al.*, 2020). Os dados coletados pelos sensores das tecnologias podem ser utilizados para identificar modificações nos comportamentos do animal, e essas podem estar associadas a quadros de doenças.

O volume de dados gerados pelos sensores é grande, o que pode dificultar a interpretação para a tomada de decisão (KITCHIN *et al.*, 2017; MANOGARAN *et al.*, 2017; CABRERA *et al.*, 2020). Nessa perspectiva, a inteligência artificial vem sendo utilizada e, com o auxílio de redes neurais é possível desenvolver modelos de predição de doenças (DE MAURO *et al.*, 2018). Assim, é possível antecipar o tratamento evitando que o animal não atinja quadro de debilidade acentuado e tenha um prognóstico favorável com mínima perda econômica (DE MAURO *et al.*, 2018; PAWAR; PANCHAL, 2020).

Estudo focados na utilização de sensores vestíveis para diagnosticar a anaplasmose bovina em bezerros ainda não foram reportados. O objetivo do presente trabalho foi avaliar, a viabilidade da utilização de modelos preditivos de *machine learning* para predição de anaplasmose com base em dados obtidos por sensores de atividade e ruminação de dispositivos comerciais.

2 REVISÃO BIBLIOGRÁFICA

2.1 Pecuária no Brasil e no mundo

Em alguns países, a agricultura e a pecuária são as principais responsáveis por manter ou aumentar o Produto Interno Bruto (PIB). Em 2021, o PIB do agronegócio brasileiro cresceu 10,79%, mostrando desempenho superior à média das outras atividades econômicas. Dessa forma, o agronegócio passou a representar 28% (R\$ 2,05 trilhão) (Cepea/Esalq/USP, 2021).

Em todo o mundo aproximadamente 800 milhões de pessoas sofrem de fome, e estima-se que em 10 anos haverá 650 milhões de pessoas subnutridos. Para suprir essa demanda de alimentos para a população espera-se que em 2050, a humanidade terá que aumentar em 70% a produção de alimentos, em relação ao que é produzido atualmente. Nessa perspectiva, para resolver o problema da escassez, os métodos tradicionais agrícolas e pecuários devem evoluir e se desenvolver apoiados em novas tecnologias (UNOLD *et al.*, 2020).

Em síntese, os produtores que consideram expandir os negócios precisam garantir melhores práticas de manejo, saúde, nutrição, melhoramento e bem-estar do rebanho. Além de serem altamente eficientes na gestão dos recursos socioeconômicos, humanos e ambientais que envolvam, por exemplo, a produção de leite (STONE, 2020; ZACHUT *et al.*, 2020).

2.2 Anaplasmosse bovina

A anaplasmosse e a babesiose formam um complexo de doenças hemolíticas, denominado Tristeza Parasitária Bovina (TPB), sendo essa responsável por perdas significativas na pecuária (SACCO *et al.*, 2001).

2.2.1 Patógeno e vetor

A anaplasmosse é causada por uma bactéria intraeritrocitária da ordem das Rickettsiales, da família Anaplasmataceae e do gênero *Anaplasma* (DUMLER *et al.*, 2001; SPARE *et al.*, 2020). As principais espécies são *Anaplasma marginale* (THEILER, 1910), a mais patogênica (LOSOS, 1986), e *Anaplasma centrale* (THEILER, 1911), descrita na literatura com menor poder de virulência (KOCAN *et al.*, 2003). A *A. marginale* pode ser identificada por meio da visualização de pontos ou corpúsculos de inclusão na fronteira das hemácias. Esses pontos

marginais e a ausência de citoplasma deram origem ao nome da espécie. Da mesma forma, quando os corpúsculos são observados no centro dos eritrócitos caracterizam a espécie *A. centrale* (KOCAN *et al.*, 2003).

Do ponto de vista estrutural há duas formas de *A. marginale*, uma apresenta os corpúsculos de inclusão com presença de apêndice (KOCAN *et al.*, 1984) e outra caracterizada pela ausência de apêndice (SMITH *et al.*, 1986). Tal característica morfológica é descrita como filamento, cauda e/ou proeminência e tem função de alça e configurações de cometas formados por lâminas interconectadas de constituição proteica (KOCAN *et al.*, 1984). Essa estrutura proporciona grande diversidade antigênica devido à capacidade de gerar proteção. A distinção dessas manifestações pode ser realizada com base nas propriedades de transmissão por carrapatos (WICKWIRE *et al.*, 1987), na morfologia (KOCAN *et al.*, 1984), na análise de fragmentos de DNA (DE LA FUENTE *et al.*, 2003) e na capacidade de reação a anticorpos monoclonais (WAGHELA *et al.*, 2000). A inoculação da cepa com apêndice provocou o aparecimento de sinais clínicos moderados e permitiu a inferência de que a forma com apêndice possui menor patogenicidade do que a amostra sem apêndice (COELHO, 2007).

A *A. marginale* tem distribuição cosmopolita, com maior prevalência em regiões de países tropicais e subtropicais como o Brasil, e em alguns países de clima temperado (OIE, 2017). A África, a Ásia, a América Central, a América do Sul, a Europa e os países do Mediterrâneo são consideradas áreas endêmicas (KOCAN *et al.*, 2010). A maioria dos países da América Latina com exceção de áreas de deserto ou montanhas como os Andes são considerados enzoóticos (GUGLIELMONE, 1995).

No mundo mais de 20 espécies de carrapatos são exemplificadas como vetores biológicos de *A. marginale* (MELO, 2018). Os principais gêneros descritos são o *Rhipicephalus* spp., o *Dermacentor* spp. e o *Ixodes ricinus*, sendo o primeiro considerado o principal vetor no Brasil (RIBEIRO; LIMA, 1996). Esse gênero é representado pelo carrapato dos bovinos (*Rhipicephalus (Boophilus) microplus*). A anaplasmosose ainda pode ser transmitida mecanicamente por dípteros hematófagos (KOCAN *et al.*, 2010).

2.2.2 Transmissão

A infecção de bovinos por *A. marginale* pode ocorrer pelas vias: mecânica, vertical e biológica. A transmissão mecânica acontece a partir da picada de insetos hematófagos ou pelo contato com fômites contaminados com sangue, como por exemplo, agulhas, brincos de

identificação individual, tatuadores, argolas nasais e utensílios cirúrgicos (KOCAN *et al.*, 2003; AUBRY; GEALE, 2011). Essa é a principal via de transmissão da anaplasmose e, nesse caso, as hemácias infectadas passam para os bovinos susceptíveis sem que ocorra a fase de multiplicação no vetor. Em regiões da África, América Central e América do Sul não existe população efetiva de carrapatos (ex.: *Rhipicephalus microplus*) transmissores da anaplasmose. Assim, a picada de dípteros hematófagos dos gêneros *Tabanus* e *Stomoxys* e dos mosquitos dos gêneros *Culex* e *Aedes* (FOIL, 1989) são responsáveis pela disseminação da rickéttsia (CORONADO, 2001).

A transmissão vertical (transplacentária) ocorre quando animal gestante e infectado com *A. marginale* contamina o feto durante a gestação (AUBRY; GEALE, 2011). O período de transição (três semanas pré e pós-parto), caracterizado por modificações fisiológicas e hormonais, é o considerado crítico e envolve alterações ligadas ao consumo, ao equilíbrio hormonal, à imunossupressão e à adaptação da microbiota ruminal (DIVERS; PEEK, 2008). A imunossupressão transitória é uma das causas prováveis que favorecem a via transplacentária (SILVA; FONSECA, 2014). No estudo de Meneses (2013), com bezerros neonatos, foi demonstrada frequência de até 10% de transmissão vertical.

A transmissão biológica é caracterizada pela participação dos carrapatos em uma relação de parasitismo com os bovinos, que acabam contaminados pela ingestão de eritrócitos infectados pela rickéttsia (MELO, 2018). Esse tipo de transmissão pode ocorrer de três maneiras distintas: transestadial, intraestadial e transovariana. A primeira é observada entre a fase de desenvolvimento de ninfa ou a fase adulta do carrapato. Na segunda, a transmissão do *A. marginale* se dá no desenvolvimento atual do artrópode, sendo uma das principais formas de transmissão. As espécies de carrapatos *R. microplus* e *Dermacentor albipictus* são as mais relevantes como transmissores dos agentes causadores da doença e possuem um único hospedeiro (monóxenos). Os machos adultos têm participação significativa, pois transitam entre os hospedeiros sem mudar de fase (KOCAN *et al.*, 2003). A terceira maneira de transmissão (transovariana) é pouco representativa e marcada pela passagem do *A. marginale* da teleógina para sua prole (RIBEIRO *et al.*, 1996).

2.2.3 O ciclo da anaplasmose

O desenvolvimento da anaplasmose envolve o vetor invertebrado (carrapatos) e o hospedeiro vertebrado (bovinos). O ciclo biológico começa quando o hospedeiro é infectado

com *A. marginale* por meio da transmissão mecânica e torna-se a via de contaminação do vetor como pode ser observado no Anexo A (página 119). Nesse estágio, os eritrócitos infectados são ingeridos pelo carrapato, alcançam o lúmen intestinal e a rickettsia se multiplica e atinge diversos tecidos, incluindo as glândulas salivares. Em seguida, o vetor contamina o próximo hospedeiro sadio a partir da inoculação da saliva como preparação do local para alimentação. Após esse processo, o ciclo pode ser reiniciado (MELO, 2018)

Comumente, no vetor é comum a forma reticulada (vegetativa) de *A. marginale*, que se divide por fissão binária e forma grandes colônias. Sequencialmente, evolui para a forma densa (infectante), a qual pode sobreviver no meio extracelular no hospedeiro (KOCAN *et al.*, 2003).

As formas infectantes de *A. marginale* ao entrarem na corrente sanguínea dos bovinos faz com que eritrócitos comecem a rofeocitose. Nesse processo ocorre a invaginação da membrana plasmática das hemácias formando um vacúolo parasitóforo. No interior dos vacúolos, os corpúsculos iniciais se multiplicam e abandonam o glóbulo vermelho, sem provocar ruptura da membrana celular. Isso caracteriza a rofeocitose reversa. A migração de uma hemácia para outra pode ocorrer por pontes intercelulares recomeçando o ciclo de multiplicação (RIBEIRO; PASSOS, 2002).

Os animais que sobrevivem à fase aguda da doença desenvolvem infecções persistentes, caracterizadas por rickettsiemias baixas e cíclicas a cada 10-14 dias (KOCAN *et al.*, 2003) ou até cinco semanas (KIESER *et al.*, 1990). Ao final, tornam-se reservatórios de *A. marginale* para transmissão mecânica e biológica (BRITO *et al.*, 2010).

A doença clínica é mais elucidada em bovinos, porém outros ruminantes como búfalos, bisões, antílopes e cervos podem se infectar persistentemente com *A. marginale* (KOCAN *et al.*, 2003; BROWN, 2012).

2.2.4 Manifestações clínicas da anapalmsose

A evolução da doença pode ser decomposta didaticamente em quatro estágios: período de incubação ou pré-patente, fase de desenvolvimento ou de patência, período convalescente e fase de portador (RICHEY, 1993).

O primeiro estágio é o Período Pré-Patente (PPP), que representa o tempo entre a infecção com rickettsia na hemácia até a primeira visualização do eritrócito parasitado nos esfregaços sanguíneos. Essa fase tem duração média de sete a 60 dias (média 28 dias) e pode

apresentar alteração conforme a população de organismos na dose infectante (KOCAN *et al.*, 2003) e a virulência do isolado (ANDRADE *et al.*, 2001).

A segunda fase também chamada de Período de Patência (PP) tem duração média de 15 dias e inicia com a observação das primeiras hemácias infectadas e prossegue até a obtenção dos menores valores de hematócrito do animal parasitado (VIDOTTO; MARANA, 2001). Os ciclos de invasão, replicação e multiplicação exponencial da rickettsia nos eritrócitos ocorrem sucessivamente. Em seguida, eritrócitos infectados e não infectados são fagocitados pelas células retículoendoteliais esplênicas. Esses processos caracterizam um quadro de anemia branda a grave e icterícia sem hemoglobinemia e hemoglobinúria (KOCAN *et al.*, 2003). A anemia é acompanhada de apatia, anorexia, mucosas pálidas ou ictéricas, hipertermia, dispneia, taquicardia, perda de peso, fadiga, sialorreia, diarreia e poliúria. Esse conjunto de sintomas pode ocasionar o óbito do animal. A manifestação clínica da doença causada por *A. marginale* pode ser: aguda, subaguda ou crônica. A fase de patência é caracterizada por valores de parasitemia elevados, mas que reduzem após o desenvolvimento da imunidade (MARANA *et al.*, 2009).

No período convalescente é observado a recuperação clínica e fisiológica do animal, podendo perdurar por até dois meses. O animal restabelece o Volume Globular (VG) e apresenta melhora na sintomatologia clínica geral (KOCAN *et al.*, 2003). Após esse período, o hospedeiro se torna persistentemente infectado e passa a ser caracterizado como portador. Nessa fase, os níveis de rickettsemia são baixos, variando de 10^2 a 10^7 eritrócitos infectados/mL sanguíneo, permanecem por meses ou anos e conferem resistência a novas doenças clínicas quando submetidos a algum desafio (BROWN, 2012).

As manifestações clínicas superagudas são raras e culminam com a morte rápida do animal. A forma branda da patologia acomete animais jovens de até um ano de idade, e quanto maior o tempo decorrido, mais rigorosa a doença se torna. Nesse cenário os animais adultos (com mais de três anos de vida), que não foram submetidos ao desafio com o agente infeccioso anteriormente, em sua maioria, apresentam quadros superagudos a fatais (RISTIC, 1968).

A resistência observada em animais jovens está relacionada à presença de anticorpos colostrais, hemoglobina fetal nos eritrócitos, maior eritropoiese da medula óssea e resposta celular rápida (RIBEIRO; PASSOS, 2002). O curso da doença está diretamente ligado com a duração da infecção, com a taxa de multiplicação do microrganismo e com a habilidade do hospedeiro (bovino) em debelar a infecção por meio da ativação e reposta do sistema imunológico (WANER *et al.*, 2010). Os bezerros esplenectomizados são totalmente

susceptíveis à infecção. Nesses casos, a doença se instala de forma mais severa do que a observada em animais com idade superior (KOCAN *et al.*, 2003).

Na forma aguda, a rickéttsemia cresce progressivamente podendo atingir 109 hemácias infectadas/mL (PCR quantitativo) e o VG reduz de 30 a 50% em relação ao valor normal (BROWN, 2012). Os principais sinais clínicos dessa síndrome são o desenvolvimento de anemia discreta a intensa. Nos episódios de maior intensidade pode ocorrer hipóxia, taquipneia e taquicardia (COELHO, 2007; LASMAR, 2012), mucosas hipocoradas, icterícia sem hemoglobinemia (devido à hemocaterese originada da saída das hemácias infectadas, tornando a bile espessa, grumosa, de cor amarelada e os tecidos ictéricos) e sem hemoglobinúria. Febre, depressão, anorexia, desidratação, fraqueza, aborto e diminuição da produção de leite são quadros que também podem ser observados (COELHO, 2007; WANER *et al.*, 2010).

No começo da anaplasnose, a sintomatologia clínica da doença é discreta, aumentando proporcionalmente com a intensidade da anemia. A temperatura retal demonstrou ser indicador promissor de acompanhamento dos animais, pois permite antecipar o diagnóstico. Isso facilita a indicação do momento crucial para o tratamento, que antecede a queda do VG (COELHO, 2007).

Na progressão da infecção por *A. marginale* não há associação direta entre a rickéttsemia e a intensidade da anemia. Dessa forma, existe a possibilidade de outros aspectos estarem relacionados à fagocitose das hemácias (GIARDINA *et al.*, 1993). No decorrer do ciclo de *A. marginale* ocorrem alterações morfológicas e bioquímicas na membrana celular das hemácias infectadas. Essas modificações induzem uma resposta imune humoral, na qual os anticorpos se fixam às células infectadas e não infectadas e fazem com que sejam reconhecidas pelo sistema monocítico fagocitário e eliminadas da circulação. Isso ocorre a uma taxa de oito a dez vezes superior à normalidade (RODRÍGUEZ *et al.*, 2000), e, por consequência, provoca anemia. Durante a fase aguda da anaplasnose, os menores valores de VG são observados de um a seis dias após o pico de parasitemia (GIARDINA *et al.*, 1993), reforçando o envolvimento dos anticorpos na patogenia.

2.2.5 Métodos de diagnóstico da anaplasnose

O diagnóstico direto ou laboratorial da infecção por *A. marginale* da forma aguda geralmente é realizado por microscopia, com base na detecção de corpúsculos intraeritrocitários marginais de inclusões de *A. marginale* em esfregaços sanguíneos corados com Giemsa

(VIDOTTO; MARANA, 2001; AUBRY; GEALE, 2011) ou pelo método de Romanowsky. Entretanto, esses métodos só detectam quantidades superiores a 10^6 de hemácias infectadas por mL de sangue (GALE *et al.*, 1996). Dessa forma, esse limiar de sensibilidade impede a avaliação de bovinos com baixa rickettsemia (MELO, 2018).

Os métodos indiretos são também chamados de sorológicos, pois mensuram anticorpos específicos contra *Anaplasma* spp. (AUBRY; GEALE, 2011). Dentre eles estão: os ensaios imunoabsorventes ligados a enzimas (ELISA), a reação de imunofluorescência indireta (RIFI) (AUBRY; GEALE, 2011; OIE, 2012), o método de fixação de complemento (CF), o teste de aglutinação do cartão (CAT) e o de citometria de fluxo.

Outras técnicas de diagnóstico são bastante utilizadas na rotina laboratorial de diagnóstico de *Anaplasma* spp. como a de reação de polimerase em cadeia (PCR). Essa reação é bastante sensível e empregada para diferenciar os animais naturalmente infectados com *A. marginale* dos animais vacinados com *A. centrale* (MOLAD *et al.*, 2006). A técnica Multiplex PCR é utilizada para detectar *A. marginale*, *Babesia bovis* e *B. bigemina* (FIGUEROA *et al.*, 1993).

No campo, o diagnóstico de anaplasmoses, geralmente, ocorre por meio da identificação dos sinais clínicos da patologia. O problema é que esses sinais só aparecem alguns dias após o pico da rickettsemia, quando o quadro de anemia é intenso (COELHO *et al.* 2007).

2.2.6 Impactos econômicos da anaplasmoses

As hemoparasitoses são fatores de risco aos animais susceptíveis e causam grandes danos econômicos nos sistemas de produção (MELO, 2018). A anaplasmoses bovina causa impactos prejudiciais à estabilidade financeira das propriedades devido à alta morbidade e mortalidade que causa nos rebanhos (MELO, 2018). Esses prejuízos estão associados à perda de peso, redução na produção de leite, aborto, custos com o tratamento e controle da doença (KOCAN *et al.*, 2003; MENDONÇA *et al.*, 2015; SOUZA *et al.*, 2021).

A anaplasmoses se torna entrave para o melhoramento genético e, conseqüentemente, para a reposição de animais jovens dos rebanhos em países tropicais. Os bovinos (*Bos taurus*) importados de regiões temperadas são susceptíveis às doenças transmitidas por parasitos como carrapatos e, frequentemente, ficam vulneráveis à infecção (MELÉNDEZ, 2005).

No Brasil é uma das principais causas de mortalidade de bezerros (RIBEIRO *et al.*, 1983) e os prejuízos determinados por *A. marginale*, juntamente à *Babesia bovis* e *B. bigemina*

são da ordem de US\$ 500 milhões por ano (GRISI *et al.*, 2002). Nos Estados Unidos, as perdas são avaliadas em torno de US\$ 300 milhões e, na América Latina, entre US\$ 800 a 875 milhões (KOCAN *et al.* 2003).

Os custos de um caso clínico de anaplasnose nos Estados Unidos, em média, são estimados em mais de US\$ 400 por animal (KOCAN *et al.* 2003) e no Brasil em torno de US\$ 5,27 (SOUZA *et al.*, 2021). Os efeitos das infecções por anaplasnose em um rebanho previamente não infectado podem levar a uma redução de 3,6% na safra de bezerros e ao aumento de 30% de mortalidade do gado adulto (ZABEL; AUGUSTO, 2018). Em sistemas confinados o risco de incidência de anaplasnose é de 58% e a pasto de 49% (MENDONÇA *et al.*, 2015).

2.3 Adoção de tecnologias na atividade pecuária

2.3.1 Pecuária de precisão

O aumento do número de animais nas propriedades leiteiras faz com que o monitoramento individual e preciso se torne mais complexo e desafiador. Isso exige maior atenção e capacidade de gerenciamento associadas às decisões precisas (BEWLEY, 2016; GARGIULO *et al.*, 2018; LOVARELLI *et al.*, 2020; MALTZ *et al.*, 2020).

Nessa perspectiva, sistemas tecnológicos são criados e adaptados para aumentar a eficiência dos sistemas de produção leiteira, a mensuração de indicadores produtivos, comportamentais e fisiológicos em benefício da saúde dos animais (MALTZ *et al.*, 2020). A partir disso, foi definido o conceito de pecuária de precisão, que envolve uma variedade de ferramentas tecnológicas de informação e comunicação para melhor controle da variabilidade animal e de recursos físicos em escala reduzida (STEENEVELD; HOGVEEN, 2015; LOVARELLI *et al.*, 2020). Dentre essas estão: sensores para detecção precoce de doenças, dispositivos de monitoramento do ambiente e do animal associados a tecnologias de processamento e análise de dados (UNOLD *et al.*, 2020).

2.3.2 Classificação de sensores

O uso de sensores na atividade pecuária vem sendo incentivado desde a década de 90. O consenso é de que esses dispositivos, quando empregados para monitorar o comportamento

animal, são capazes de reduzir a necessidade de observação visual e, assim, aumentam a capacidade de gerenciamento (FROST *et al.*, 1997). Esses sensores podem ser classificados em duas categorias: estacionária e vestíveis (RUUSKA *et al.*, 2016).

Os sensores estacionários são unidades fixas que são colocadas no ambiente para registrar a dinâmica do animal. As câmeras remotas e os leitores de identificação por radiofrequência são utilizados para avaliar o consumo de alimento e de água do rebanho em sistemas intensivos de produção (WILLIAMS *et al.*, 2020), além de poderem fornecer dados individuais dos animais, como tempo e duração da visita, consumo e frequência de alimentação (ALLWARDT *et al.*, 2017).

Os sensores vestíveis ou de rastreamento são pequenos dispositivos colocados em contato direto com os animais e podem monitorar continuamente o comportamento individual. O posicionamento do sistema global de navegação por satélite (GPS), acelerômetros, monitores acústicos e de proximidade são exemplos de sensores utilizados no registro de atividades diárias (TALUKDER *et al.*, 2015; PATISON *et al.*, 2017; BAILEY, 2018). De forma mais específica, identificam-se a postura (em pé ou deitado), a atividade comportamental (caminhar, descansar, pastar ou ruminar) e a geolocalização (WILLIAMS *et al.*, 2019).

Outra forma de classificação seria separar os sensores em três grandes grupos: vestíveis (At cow), perto da vaca (Near Cow) e de vaca (From Cow). O primeiro grupo são dispositivos encontrados presos na vaca e incluem os alojados no sistema digestivo ou no trato reprodutivo do animal. O segundo grupo inclui todos os sensores remotos que podem assistir, ouvir, rastrear, pesar, registrar a vaca ou seu ambiente imediato. Isso é realizado a partir de elementos geograficamente remotos (GPS e nuvem) e permite a análise em tempo real. O terceiro “From Cow” é representado por sensores que podem coletar e analisar dados relacionados a produtos provenientes dos animais, sendo a análise do leite o principal exemplo. Entretanto, a análise de biomarcadores de tecidos / fluidos corporais (cabelo, saliva, suor, secreção nasal, respiração e fezes) também está sendo utilizada na prática (KNIGHT, 2020).

2.3.3 Fatores que influenciam no uso de sensores

A decisão de comprar e de implementar uma tecnologia de precisão representa um investimento significativo para um produtor, que muitas vezes, enfrenta o desafio de escolher uma tecnologia que atenda às suas necessidades por vários anos. Para isso devem levar em

conta muitos fatores distintos, como escala financeira, demográfica e outras considerações (BROCHERS; BEWLEY, 2015).

O desenvolvimento de sistemas de sensores pode ser subdividido em quatro etapas: (i) tecnologia ou sensor que mede algum parâmetro do animal individualmente (por exemplo, tempo de ruminção); (ii) interpretações que resumem as mudanças nos dados do sensor para produzir informações sobre o *status* do animal (por exemplo, queda da ruminção gera alerta sugestivo de deslocamento de abomaso); (iii) integração de informações complementares a outros conhecimentos para gerar sugestões (valor econômico); e (iv) o produtor toma uma decisão ou o sistema de sensores toma a decisão de forma autônoma (operar ou descartar o animal) (RUTTEN *et al.*, 2013).

Os aspectos que influenciam a decisão do produtor em aderir às tecnologias de precisão podem ser resumidos na compatibilidade com o gerenciamento da fazenda, custo-benefício da tecnologia/vantagem relativa, complexidade, possibilidade de período de teste na propriedade e observação (YULE; EASTWOOD, 2012).

Outra expectativa que motiva o produtor a investir em tecnologia é a de redução do trabalho e, por consequência, menor custo de mão de obra e maior facilidade no manejo diário do rebanho. As fazendas que adotaram algum tipo de tecnologia de precisão obtiveram uma redução de até 23% das horas trabalhadas por vaca/semana, comparadas àquelas que não faziam uso de sistemas de monitoramento por sensores (STEENEVELD; HOGEVEEN, 2015).

Por outro lado, no Brasil, as principais tecnologias utilizadas são importadas de países desenvolvidos e, por isso, esses dispositivos ainda apresentam valores elevados e, às vezes, não podem ser adaptados às condições de produção dos diversos sistemas presentes no país devido às peculiaridades das raças, dietas e manejos de alimentação diferentes (CAVALCANTI *et al.*, 2017; SILVI *et al.*, 2021).

2.3.4 Perfil de utilização dos sensores

A produtividade na pecuária leiteira sofre influência negativa por consequência de fatores como mastite, claudicação, anaplasmose, desnutrição, doenças metabólicas, problemas reprodutivos, ineficiência na recria, no desempenho, na gestão de pastagens e na habitação. Dessa forma, esses problemas são prioridades para o desenvolvimento das tecnologias aplicáveis aos sistemas de produção (BROCHERS; BEWLEY, 2015).

A tecnologia de precisão tem potencial de uso, mas são necessários mais trabalhos para melhorar os alertas de detecção de doenças. Embora os produtores tenham indicado que a maioria dos alertas representava uma mudança comportamental real, os produtores acompanharam visualmente apenas 21% dos alertas que são gerados (ECKELKAMP; BEWLEY, 2020). Os alertas comportamentais de doenças devem ser aprimorados para embasar a tomada de decisão por parte dos produtores.

Os produtores que detém rebanhos maiores adotam mais tecnologias de precisão quando comparados aos produtores que gerenciam rebanhos menores (GARGIULO *et al.*, 2018). Esses dados mostram que a adoção das tecnologias de precisão vem sendo utilizadas em larga escala melhorando a eficiência dos sistemas de produção e gerando oportunidade para a fazenda enfrentar futuros desafios (STONE, 2020).

No Brasil, os parâmetros mais comumente mensurados por tecnologias de precisão foram: sistemas de medidores de leite (31,7%), portão inteligente da sala de ordenha (14,5%), sistemas de sensores para detecção de mastite (8,4%), medidor de atividade da vaca (7,1%) e temperatura corporal (7,9%) (SILVI *et al.*, 2021). Nos EUA, as medidas em destaque foram representadas pela produção diária de leite (52,3%), atividade da vaca (41,3%), mastite (25,7%) e composição do leite (24,8%) (BORCHERS; BEWLEY, 2015).

Outros dispositivos com potencial de adoção são os sistemas eletrônicos de identificação de vacas, alimentação automática na sala de ordenha ou em cabines de alimentação e *software* de gerenciamento de rebanhos. No âmbito de desenvolvimento, estão as tecnologias para avaliação baseada em imagem do comportamento alimentar individual (BLOCH *et al.*, 2019), função ruminal (SONG *et al.*, 2019), frequência cardíaca e respiratória (BEIDERMAN *et al.*, 2014), composição corporal (HUANG *et al.*, 2018), micro-Doppler para frequência cardíaca e respiratória (MICHIE *et al.*, 2020), biomarcadores de reprodução (BRUINJÉ *et al.*, 2019), função metabólica (DE ALMEIDA *et al.*, 2019) e outros relacionados à saúde e ao bem-estar do animal (ZACHUT *et al.*, 2020).

2.3.5 Sensores para o monitoramento de alterações na saúde animal

A observação direta do rebanho, ao vivo ou por meio de gravação de vídeo, tem sido utilizada como método tradicional para avaliar o comportamento dos animais em fazendas leiteiras. Isso porque mudanças no comportamento de repouso podem indicar fatores de perturbação do conforto e do bem-estar animal (LEDGERWOOD *et al.*, 2010). No entanto,

devido às restrições de tempo e à falta de força de trabalho, especialmente em fazendas de grande porte, houve progresso no monitoramento de vacas com dispositivos eletrônicos e biossensores (BENAISSA *et al.*, 2016a, BENAISSA *et al.*, 2016b). Além desses, os pesquisadores propuseram o uso de várias ferramentas de aprendizado de máquina para classificar os dados com maior precisão (RESHEFF *et al.*, 2014).

Para vacas leiteiras, diferentes abordagens foram sugeridas para classificar automaticamente o comportamento, isto é, deitar, levantar e alimentar. Essa classificação é realizada com base em algoritmos de aprendizado de máquina, comparando acelerômetros montados nas pernas e no pescoço do animal. Para o acelerômetro montado na perna, o comportamento de repouso foi classificado com alta precisão (99%) e sensibilidade (98%). A alimentação foi classificada com mais precisão pelo acelerômetro alocado no pescoço comparado ao colocado na perna (precisão 92% versus 80%; sensibilidade 97% versus 88%). Ficar em pé foi o comportamento mais difícil de classificar quando apenas um acelerômetro foi empregado (BENAISSA *et al.*, 2019).

Jaeger *et al.* (2019) avaliaram dados do sensor auricular, características de bem-estar (escore de condição corporal, escore de locomoção, escore de úbere / higiene das pernas), características de temperamento (ordem de classificação intra-rebanho, agressividade e temperamento geral durante a ordenha) e produção. A temperatura auricular do sensor foi correlacionada negativamente com o comportamento alimentar. Em relação ao bem-estar, houve correlações positivas entre o nível de agressividade em relação a outros companheiros de rebanho e a ordem de classificação intra-rebanho, indicando que as vacas com classificação intra-rebanho mais alta apresentaram comportamento agressivo aumentado.

A análise revelou que as vacas que passam mais tempo deitadas (> 7 h / d) reduziram a produção diária de leite e gordura. Por outro lado, vacas de alta produtividade apresentaram comportamento intensivo de alimentação e ruminação. Observaram também uma menor ruminação e tempo de alimentação de vacas com células somáticas elevadas (> 700.000 células / mL). Isso sugere a possibilidade de utilização do comportamento obtido com base em sensores, como indicador de saúde do úbere.

Dispositivos intra-ruminais foram desenvolvidos para medir o pH e outras características do fluido ruminal (MOTTRAM *et al.*, 2008; BISHOP-HURLEY *et al.*, 2016). Como também a ruminação, mensurada por acelerômetros (ZEHNER *et al.*, 2017), podem

ajudar a estimar a produção de saliva, ou seja, a capacidade de tamponamento e de saúde ruminal.

No geral, nos trabalhos apresentados, foi exemplificada a variação do padrão de comportamento individual em virtude de alterações fisiológicas. Isso foi possível através da tecnologia de sensores como alternativa adequada para diagnóstico precoce de doenças e bem-estar do rebanho.

2.3.6 Cria e recria

Em todo o mundo, há uma tendência de aumento no tamanho dos rebanhos e a proporção de animais está aumentando, assim, o tempo disponível para monitorar animais individuais está reduzindo. Sabe-se que o comportamento dos bezerros muda quando esses estão sujeitos a alguma patologia, por exemplo, apresentam menos tempo ruminando e alimentando e diminuição do nível de atividade. Esses comportamentos podem ser monitorados de forma não invasiva usando sensores. Assim, os traços comportamentais podem ser variáveis interessantes para a predição de desempenho na recria (MILLER *et al.*, 2020).

O uso de tecnologias de precisão com confiabilidade requer validação de dados de animais individuais para garantir medições confiáveis de variáveis comportamentais e fisiológicas. Para isso, avalia-se a precisão, a exatidão e a tendência da tecnologia operando no ambiente de produção. Os estudos de validação comparam os dados de comportamento registrados pela tecnologia com uma medida conhecida de comportamento, como observação visual, ou com outra tecnologia validada conhecida como padrão ouro (COSTA *et al.*, 2021).

Os acelerômetros podem ser tecnologias úteis para identificar mudanças na atividade dos passos e no comportamento de bezerros antes de adoecer. Esses são dispositivos triaxiais que permitem medir o ângulo de inclinação em relação à Terra e a quantidade de aceleração dinâmica. Os dados fornecidos pelos acelerômetros podem ser usados para determinar a posição em relação ao solo (ou seja, vertical, horizontal) e a velocidade e a direção do movimento. Os acelerômetros tridimensionais fornecem uma medida objetiva e não invasiva de padrões de comportamento normais usando algoritmos para processar dados brutos de posição, velocidade e direção (ROBERT *et al.*, 2009; COSTA *et al.*, 2021).

Devido ao pequeno tamanho e peso, baixo custo e capacidade potencial de registrar dados comportamentais de alta resolução por um longo período, esses dispositivos, são cada vez mais usados para monitorar o comportamento dos animais. Por exemplo, novilhos

experimentalmente induzidos com complexo de doença respiratória bovina (BRD) aumentaram o tempo total de repouso em até 11%, além de apresentar sessões de repouso mais longas no decorrer dos dias da doença até 87% mais alto em comparação com bezerros do grupo controle (TOAFF-ROSENSTEIN *et al.*, 2016).

Bezerros avaliados com sensor triaxial e infectados com *Mannheimia haemolytica* demonstraram que o tempo de repouso foi igualmente sujeito aos efeitos do tratamento por dia, e os bezerros doentes também passaram mais tempo deitados sobre o lado esquerdo em comparação com o direito (604 vs. 471 min / h; erro padrão = 32), enquanto os bezerros controle não expressaram posições de lateralidade. A duração do repouso social não diferiu, mas a frequência diminuiu em bezerros doentes após a inoculação (0,44 vs. 0,75 sessões / h; erro padrão = 0,04) (HIXSON *et al.*, 2018).

Os acelerômetros também têm sido usados para detectar mudanças no comportamento durante o desenvolvimento de inflamação do umbigo e diarreia. Por exemplo, bezerros usando acelerômetros tiveram menos tempo de repouso do que bezerros saudáveis ao apresentarem inflamação no umbigo (STUDDS *et al.*, 2018). Em casos de diarreia grave devido à *Salmonella*, foi observado aumento da duração do período de repouso nos 3 dias antes do diagnóstico clínico (LOWE *et al.*, 2019). Belaid *et al.* (2020) observaram 15% menos episódios de repouso na predição de casos de diarreia comparando-se animais doentes e sadios, corroborando os dados de Sutherland *et al.* (2018) que obtiveram redução do tempo de repouso em bezerros dois dias antes da diarreia e aumento no dia do diagnóstico de diarreia.

O comportamento de ruminação apresenta potencial para detectar doenças em bezerros. No entanto, o monitoramento automatizado da ruminação em bezerros teve aplicação limitada. Isso provavelmente está relacionado às idades variáveis nas quais os acelerômetros são capazes de medir a ruminação (RODRIGUES *et al.*, 2019). Como exemplo, a ruminação foi detectada usando acelerômetros de gerenciamento de rebanho de seis semanas (HILL *et al.*, 2017), oito semanas de idade (REYNOLDS *et al.*, 2019) a 12 semanas de idade (RODRIGUES *et al.*, 2019), mas há um debate sobre em que idade ocorre a verdadeira ruminação em bezerros, conforme Khan *et al.* (2016).

2.4 Processamento e análise dos dados

As fazendas leiteiras estão adotando inovações tecnológicas para incrementar a produtividade, em concomitância, houve um aumento considerável na quantidade de dados

disponíveis (CABRERA *et al.*, 2020). Devido à complexidade do conjunto, integrar e interpretar esses dados mostrou ser um desafio para melhorar o gerenciamento e o suporte a decisões (FERRIS *et al.*, 2020).

Os resultados de uma pesquisa no meio-oeste dos EUA mostraram que 64% dos produtores utilizam pelo menos um tipo de tecnologia digital; cerca de 47% aderiram a aplicativos de *smartphones* para obter informações ou tomar decisões; 20 a 25% aplicam a agricultura de precisão e 11% usam sensores em animais ou drones (SHUTSKE *et al.*, 2018).

Em 1997, surgiu o termo *Big Data* e foi aplicado para nomear essa elevada, crescente e não estruturada quantidade de dados, que está sendo gerada a cada segundo em diferentes setores (COX; ELLSWORTH, 1997). Inicialmente, os elementos fundamentais de caracterização foram: volume, variedade, velocidade, veracidade e valor. Ao longo do tempo outros atributos foram adicionados ao termo *Big Data*. Dentre eles, validade (representando o processamento correto dos dados), variabilidade (contexto dos dados), viscosidade (transmissão de dados de latência entre a fonte e o destino), vitalidade (velocidade dos dados enviados e recebidos de várias fontes) e visualização (interpretação dos dados e identificação das informações mais relevantes para os usuários) (MANOGARAN *et al.*, 2017).

O processamento das informações acontece de forma distinta das análises convencionais. Nessa perspectiva, surge a ciência de dados (*Data Science*), que reúne habilidades para explorar o armazenamento, a transformação, a geração e a posterior análise desses megadados (DE MAURO *et al.*, 2018; SEN *et al.*, 2020).

2.4.1 Inteligência artificial

A palavra inteligência por definição quer dizer juntar ou conectar. É a ciência ou capacidade de ligar internamente o que é captado (DE HOLLANDA-FERREIRA, 1988). Inteligência artificial (IA) é uma subárea da ciência da computação que utiliza mecanismos e dispositivos tecnológicos “capazes” de simular o raciocínio humano. Um dos primeiros relatos do conceito de inteligência artificial foi de Aristóteles, que aspirava substituir a mão-de-obra escrava por objetos autônomos. Essa ideia foi evoluindo ao longo do tempo pelo desenvolvimento da ciência da computação (TURING, 2009).

O desenvolvimento da IA teve início em 1943 com vários trabalhos de pesquisadores como: Herbert Simon, Allen Newell, John McCarthy, Warren McCulloch, Walter Pitts e Marvin Minsky, entre outros. Suas pesquisas envolviam modelos de “neurônios” artificiais com

estímulos conectivos satisfatórios, e formação de redes artificiais com capacidade de aprendizado (COPPIN; LEGRAS, 2012).

A maioria dos aspectos construídos sobre IA concentraram em criar algoritmos para aprimorar a precisão da modelagem, ou a velocidade de sua construção (CHOU *et al.*, 2015). Outros pesquisadores propõem que a IA se refere a programas, algoritmos, sistemas e máquinas que demonstram inteligência (SHANKAR, 2018),

A IA engloba métodos de aprendizado de máquina, processamento de linguagem natural, sistemas especialistas baseados em regras, redes neurais, aprendizado profundo, robôs físicos e automação de processos robóticos (DAVENPORT, 2018). Ao empregar essas ferramentas, a IA fornece um meio de interpretar dados externos corretamente, aprender com esses dados e exibir uma informação, que possa resolver questões de áreas como as ciências biológicas, exatas e humanas (KAPLAN; HAENLEIN, 2020).

2.4.2 Aprendizado de máquina (*Machine Learning*)

O estudo envolvendo as ciências da engenharia e da computação que evolue o aprendizado computacional e a inteligência artificial é conhecido como *Machine Learning* (ML) ou aprendizagem de máquina (SAMUEL, 1959).

Os estudos matemáticos e estatísticos envolvendo ML são realizados em padrões que assumem variações em torno do tempo. O ML tem como base o estudo e a construção estatística de algoritmos, que podem aprender ou treinar por meio de seus erros e fazer previsões sobre os dados analisados. Os algoritmos trabalham construindo um modelo por meio de “unidades de entrada amostrais” ou variáveis. Essas unidades podem aprender um padrão ou gerar uma resposta. Essas são consideradas previsões ou decisões ancoradas pelos dados, ao invés de simplesmente seguir programações prévias (HEMPSTALK *et al.*, 2015).

As técnicas de previsões podem ser melhoradas devido a aptidão de modelar relações complexas entre variáveis, tais como, não linearidade e interações (GIANOLA *et al.*, 2011). Os algoritmos e variáveis são adicionados em programas ou softwares comerciais. O analista, por sua vez, deve elaborar conjuntos de treinamento e testes para aplicar no *software* que sejam independentes e apropriados para o uso pretendido, de acordo com a variável estudada. Tais ações, quando bem executadas evitam conclusões irreais sobre a capacidade preditiva do modelo em aplicações futuras (WEIGEL *et al.*, 2017).

A maioria das aplicações de ML podem ser descritas no fluxo de trabalho de aprendizado de máquina canônico, que envolve quatro etapas: limpeza e pré-processamento de dados, extração de recursos, ajuste e avaliação de modelos (ANGERMUELLER *et al.*, 2016; RASCHKA; MIRJALILI, 2017).

Os sistemas de ML possuem características específicas, que facilitam estruturação de acordo com a função da linguagem de descrição, o modo de aprendizado ou de treinamento, o modelo, a forma e a tarefa de aprendizado (GUZELLA; CAMINHAS, 2009).

O aprendizado supervisionado é um dos ramos mais amplos do ML, pois permite que o modelo preveja resultados futuros, depois de treinados com base em dados anteriores (SEN *et al.*, 2020). Assim cada observação do conjunto de dados dispõe de um vetor de medições para variáveis preditoras, o que é chamado de *inputs* ou variáveis independentes. Da mesma maneira ocorre a medição correspondente a resposta de interesse, *output* ou variável dependente. Em seguida, o modelo é relacionado à resposta dos preditores, de modo que, consiga prever essa resposta em observações futuras para as quais estão disponíveis apenas dados referentes aos preditores (RASCHKA; MIRJALILI, 2017).

A variável resposta divide-se em dois grupos: o de variáveis quantitativas que envolve a regressão (saídas são contínuas), e o de variáveis qualitativas que envolve a classificação (saídas são categóricas). Grande parte dos algoritmos são utilizados de forma independente do tipo de variável preditora disponível, contanto que os preditores sejam adequadamente pré-processados antes da análise dos dados (SEN *et al.*, 2020).

No aprendizado não supervisionado, para toda observação há um vetor de medidas (*input*), correspondente aos preditores disponíveis no conjunto de dados. Entretanto, não existe uma variável resposta conhecida. Desta forma, o ajuste de modelos deve dominar as relações entre variáveis ou entre observações, para identificar como estas estão organizadas (RASCHKA; MIRJALILI, 2017).

O ML tem sido utilizado no campo da produção animal, por exemplo, na tentativa de prever resultados de fertilidade (FENLON *et al.*, 2016), genética (GIANOLA *et al.*, 2011; KESHAVARZI *et al.*, 2020), genoma (ABDOLLAHI-ARPANAHI *et al.*, 2020), qualidade do leite (EBRAHIMIE *et al.*, 2018; MUÑIZ *et al.*, 2020), mastite (HYDE *et al.*, 2020), início do parto (FENLON *et al.*, 2017; BORCHERS *et al.*, 2017; KECALI *et al.*, 2020), cetose subclínica (EHRET *et al.*, 2015), estro (DOLECHECK *et al.*, 2015; HIGAKI *et al.*, 2019), prenhez (DELHEZ *et al.*, 2020), consumo de alimentos (DOREA *et al.*, 2018; ABDELLA *et al.*, 2020;

FU *et al.*, 2020; BRESOLIN; DÓREA, 2020), produção de frangos e suínos (ABREU *et al.*, 2020; JENSEN *et al.*, 2020), monitoramento (ALONSO *et al.*, 2020), comportamento (ALVARENGA *et al.*, 2020; GUO *et al.*, 2020; FOGARTY *et al.*, 2020), respostas ao estresse térmico (BENNI *et al.*, 2020; GORCZYCA; GEBREMEDHIN, 2020), produção e análise de medicamentos (BROUGHTON-NEISWANGER *et al.*, 2020; HUR *et al.*, 2020), tomada de decisão e gerenciamento (CABRERA *et al.*, 2020; CATAL *et al.*, 2020), ganho de peso (COMINOTTE *et al.*, 2020), produção de leite (DA ROSA RIGHI *et al.*, 2020; HAZARI *et al.*, 2020), recursos humanos (DE MAURO *et al.* 2018), necessidade de cirurgia (FRAIWAN; ABUTARBUSH, 2020), treinamento veterinário (GATES *et al.*, 2020), identificação individual (HU *et al.*, 2020), dados climáticos (KEDARI *et al.*, 2020), identificação de doenças (SARANYA *et al.*, 2020; SEMENENKO *et al.*, 2020), dentre outros.

2.4.3 Rede neural artificial

Rede neural artificial (RNA) é um exemplo de um modelo de ML supervisionado e um método comumente aplicado para interpretar dados. A RNA baseia-se em modelos computacionais formados por unidades simples de processamento fundamentadas e inspiradas na estrutura funcional do cérebro humano (MCCULOCK; PITTS, 1943; ABREU *et al.*, 2020). O cérebro humano é composto por uma quantidade de elementos interligados, conhecidos como unidades básicas do sistema nervoso, chamados neurônios. Esses elementos do sistema nervoso humano agrupam e transformam as informações, modificando e moldando o arranjo de suas conexões de acordo com os problemas a eles apresentados. A solução de problemas sofre modificações pela quantidade e qualidade das interações entre os neurônios (ELLIS *et al.*, 2020).

A estrutura de uma RNA é, portanto, como uma versão simplificada de uma rede neural biológica, através da qual vários nós são organizados em diferentes camadas interconectadas. Cada nó é capaz de integrar a entrada fornecida, a partir, de uma soma ponderada sobre a qual uma função de ativação (normalmente logística) é aplicada. Exceder o limite desta função de ativação fornece uma saída, que emula o disparo de um neurônio no cérebro (ELLIS *et al.*, 2020). A RNA permite que o sistema artificial simule comportamentos, como aprendizado, cognição, tomada de decisão, capacidade de associação, generalização e abstração. Isso ocorre com base na lógica dos parâmetros associações entre esses componentes artificiais, também chamados de neurônios, que compõem a rede neural (ABDOLLAHI-ARPANAHI *et al.*, 2020).

As RNAs podem ser arquitetadas com esqueletos estruturais, essa estruturação é dependente do tipo de problema que será aplicado à rede neural. Um dos tipos mais populares de RNA é a Camada Múltipla *Perceptron* (MLP) (ROSENBLATT, 1958; AITKIN; FOXALL, 2003). Seu modelo é baseado no neurônio biológico, como descrito no trabalho de McCulloch e Pitts (1943).

A maioria dos tipos de RNAs recebem várias entradas, que são transformadas por meio de “neurônios artificiais” a partir de uma única ou múltiplas camadas ocultas, convertendo o resultado usando uma camada de saída. Esse processo de estimativa de resultados é conhecido como “propagação direta”. A RNA funciona comparando o resultado com uma saída real, avalia o nível de erro ou perda (*Loss function*) (w) e que peso que o neurônio contribui para o erro total. Posteriormente ajusta os pesos para minimizar esse erro. Essa etapa é conhecida como “propagação para trás”. O funcionamento desse algoritmo consiste em: (1) apresentar o padrão à camada de entrada (*inputs*) da rede; (2) processar camada por camada até obter o resultado ou resposta processada na camada de saída (*outputs*); (3) se o resultado diferir do esperado o algoritmo devolve o erro para adaptação nos valores dos pesos nas camadas intermediárias, e se reinicia a função (ELLIS *et al.*, 2020).

Um MLP contém vários nós de “camada oculta” entre as camadas de entrada (*inputs*) e saída (*outputs*) da RNA. Nesse tipo de modelo, todas as camadas estão totalmente conectadas, todos os nós em uma camada estão conectados a todos os nós na camada anterior e na camada seguinte (exceto as camadas de entrada e saída). Modelos com multicamadas de processamento oculto são chamadas RNAs profundas ou modelos de “*deep learning*” (DL). Esses modelos podem, como qualquer RNA, ser supervisionados, parcialmente supervisionados ou não supervisionado (ELLIS *et al.*, 2020; ABREU *et al.*, 2020).

A RNA é capacitada para todos os diversos parâmetros como o número de neurônios, número de camadas intermediárias (*hidden layers*), a taxa de aprendizado e o otimizador (*Stochastic Gradient Descent*) que precisam ser definidos e trabalhados pelo analista para que a estrutura da RNA seja bem definida. A aplicabilidade das RNAs está associada a situações nas quais as informações de entrada e saída são interconectadas por um relacionamento não linear de variáveis dependentes e independentes. Assim, as RNAs podem ser usadas para prever e representar parâmetros não quantificados a partir de dados avaliados por padrões de comportamento, permitindo o desenvolvimento de técnicas para resolver problemas complexos (ABREU *et al.*, 2020).

2.5 Referências bibliográficas

ABDELLA, G. M.; KUCUKVAR, M.; ONAT, N. C.; AL-YAFAY. H. M. Sustainability assessment and modeling based on supervised machine learning techniques: The case for food consumption. **Journal of Cleaner Production**, v. 251, s. n., p. 119661-19677, 2020.

ABDOLLAHI-ARPAHAHI, R.; GIANOLA, D.; PEÑAGARICANO, F. Deep learning versus parametric and ensemble methods for genomic prediction of complex phenotypes. **Genetics Selection Evolution**, v. 52, s. n., p. 1-15, 2020.

ABREU, L. H.; YANAGI JUNIOR, T.; BAHUTI, M.; HERNÁNDEZ-JULIO. Y. F.; FERRAZ. P. F. P. Artificial neural networks for prediction of physiological and productive variables of broilers. **Engenharia Agrícola**, v. 40, s. n., p. 1-9, 2020.

AITKIN, M.; FOXALL, R.; Statistical modelling of artificial neural networks using the multi-layer perceptron. **Statistics and Computing**, v. 13, n. 3, p. 227-239, 2003.

ALLWARDT, K.; AHLBERG, C.; BROOCKS, A.; BRUNO. K.; TAYLOR. A.; PLACE. S.; RICHARDS. C.; KREHBIEL. C.; CALVO-LORENZO. M.; DESILVA. U.; VANOVERBEKE. D.; MATEESCU. R.; GOAD. C.; ROLF. M. M. Validation of an automated system for monitoring and restricting water intake in group-housed beef steers. **Journal of Animal Science**, v. 95, s. n., p. 4213-4219, 2017.

ALONSO, R. S.; SITTÓN-CANDANEDO, I.; GARCÍA, Ó.; PRIETO. J.; RODRÍGUEZ-GONZÁLEZ. S. An intelligent Edge-IoT platform for monitoring livestock and crops in a dairy farming scenario. **Ad Hoc Networks**, v. 98, s. n., p. 102047, 2020.

ALVARENGA, F. A. P.; BORGES, I.; ODDY, V. H.; DOBOS, R. C. Discrimination of biting and chewing behaviour in sheep using a tri-axial accelerometer. **Computers and Electronics in Agriculture**, v. 168, s. n., p. 105051, 2020.

ANDRADE, G.M.; VIDOTTO, O.; VIDOTTO, M.C.; YOSHIHARA. E.; KANO. F. S.; AMARAL. C. H. S. Seroprevalence of *Anaplasma marginale* in dairy cattle and studies on the dynamics of natural infection of Holstein calves in Southern Brazil. **Semina: Ciências Agrárias**, v. 22, s. n., p.155-159, 2001.

ANGERMUELLER, C.; PÄRNAMAA. T.; PARTS. L.; STEGLE. O. Deep learning for computational biology. **Molecular Systems Biology**, v. 12, n. 7, p. 878, 2016.

AUBRY, P.; GEALE, D.W. A review of bovine anaplasmosis. **Transboundary and Emerging Diseases**, v. 58, s. n., p.1-30, 2011

BAILEY, D. W.; TROTTER, M. G.; KNIGHT, C. W.; THOMAS, M. G. Use of GPS tracking collars and accelerometers for rangeland livestock production research. **Translational Animal Science**, v. 2, s. n., p. 81-88, 2018.

BEIDERMAN, Y.; HALACHMI, I.; ZALEVSKY, Z. A novel approach for remote monitoring of heart beat rate, respiratory rate and chewing activity in cows. **In Proceedings of the First DairyCare Conference**, Copenhagen, 2014.

BELAID, M. A.; RODRÍGUEZ-PRADO, M.; RODRÍGUEZ-PRADO, D. V.; CHEVAUX, E.; CALSAMIGLIA, S. Using behavior as an early predictor of sickness in veal calves. **Journal of Dairy Science**, v. 103, s. n., p. 1874-1883, 2020.

BENAISSA, S.; PLETS, D.; TANGHE, E.; LEEN VERLOOCK L. MARTENS.; HOEBEKE, J.; SONCK, B.; TUYTTENS, F.; VANDAELE, L.; STEVENS, N.; JOSEPH, W. Experimental characterisation of the off-body wireless channel at 2.4 GHz for dairy cows in barns and pastures. **Computers and Electronics in Agriculture**, v. 127, s. n., p. 593-605, 2016a.

BENAISSA, S.; PLETS, D.; TANGHE, E.; VERMEEREN, G.; MARTENS, L.; SONCK, B.; TUYTTENS, F.; VANDAELE, L.; HOEBEKE, J.; STEVENS, N.; JOSEPH, W. Characterization of the on-body path loss at 2.45 GHz and energy efficient WBAN design for dairy cows. **IEEE Transactions on Antennas and Propagation**, v.64, s. n., p. 4848-4858, 2016b.

BENAISSA, S.; TUYTTENS, F. A.; PLETS, D.; PESSEMIER, T.; TROGH, J.; TANGHE, E.; MARTENS, L.; VANDAELE, L.; VAN NUFFEL, A.; JOSEPH, W.; SONCK, B. On the use of on-cow accelerometers for the classification of behaviours in dairy barns. **Research in Veterinary Science**, v. 125, s. n., p. 425-433, 2019.

BENNI, S.; PASTELL, M.; BONORA, F.; TASSINARI, P. A generalised additive model to characterise dairy cows' responses to heat stress. **Animal**, v. 14, s. n., p.418-424, 2020.

BEWLEY, J. M. Opportunities for monitoring and improving animal welfare using precision dairy monitoring technologies. **Journal of Animal Science**, v. 94, s. n., p.11-11, 2016.

BISHOP-HURLEY, G. J.; PAULL, D.; VALENCIA, P.; OVERS, L. Intra-ruminal gas-sensing in real time: a proof-of-concept. **Animal Production Science**, v. 56, s. n., p.204-212, 2016.

BLOCH, V.; LEVIT, H.; HALACHMI, I. Assessing the potential of photogrammetry to monitor feed intake of dairy cows. **Journal of Dairy Research**, v. 86, s. n., p.34-39, 2019.

BORCHERS, M. R.; BEWLEY, J. M. An assessment of producer precision dairy farming technology use, prepurchase considerations, and usefulness. **Journal of Dairy Science**, v. 98, s. n., p. 4198-4205, 2015.

BORCHERS, M. R.; CHANG, Y. M.; PROUDFOOT, K. L.; JONES, B. W. Machine-learning-based calving prediction from activity, lying, and ruminating behaviors in dairy cattle. **Journal of Dairy Science**, v. 100, s. n., p.5664-5674, 2017.

BRESOLIN, T.; DOREA, J. Infrared Spectrometry as a High-Throughput Phenotyping Technology to Predict Complex Traits in Livestock Systems. **Frontiers in Genetics**, v. 11, s. n., p. 923-943, 2020.

BRITO, L.G.; OLIVEIRA, M.C.S.; ROCHA, R.B.; SILVA NETTO, F. G.; MARIM, A. D.; DE SOUZA, G. C. R.; VENDRAME, F. B.; MOURA, M. M. F. *Anaplasma marginale* infection in cattle from south-western Amazonia. **Pesquisa Veterinária Brasileira**, v. 30, s. n., p.249-254, 2010.

BROUGHTON-NEISWANGER, L. E.; RIVERA-VELEZ, S. M.; SUAREZ, M. A.; SLOVAK, J. E.; PIÑEYRO, P. E.; HWANG, J. K.; VILLARINO, N. F. Urinary chemical fingerprint left behind by repeated NSAID administration: Discovery of putative biomarkers using artificial intelligence. **PloS one**, v. 15, s. n., p. e0228989, 2020.

BROWN, W.C. Adaptive immunity to *Anaplasma* pathogens and immune dysregulation: implications for bacterial persistence. **Comparative Immunology, Microbiology & Infectious Diseases**, v. 35, s. n., p. 241-252, 2012.

BRUINJÉ, T.C.; COLAZO, M.G.; RIBEIRO, E.S.; GOBIKRUSHANTHA, M.; AMBROSEAB, D. J. Using in-line milk progesterone data to characterize parameters of luteal activity and their association with fertility in Holstein cows. **Journal of Dairy Science**, v. 102, s. n., p. 780–798, 2019.

CABRERA, V. E.; BARRIENTOS-BLANCO, J. A.; DELGADO, H.; FADUL-PACHECO, L. Symposium review: Real-time continuous decision making using big data on dairy farms. **Journal of Dairy Science**, v. 103, s. n., p. 3856-3866, 2020.

CATAL, C.; KASSAHUN, A.; HOVING, H. J. Improving Farm Management Information Systems with Data Mining. **Balkan Journal of Electrical and Computer Engineering**, v. 8, s. n., p. 21-30, 2020.

CAVALCANTI, L. F. L.; MACHADO, F. S.; PAIVA, C. A. V.; PEREIRA, L. G. R. Pecuária de Precisão: Uso de tecnologias para apoio à tomada de decisão. Zootec 2017, Santos, São Paulo, *Anais... researchgate*, 2017.

CEPEA – Centro de Estudos Avançados em Economia Aplicada – ESALQ/USP. PIB do agronegócio brasileiro. Piracicaba: CEPEA/ESALQ/USP, 2020. Disponível em: Acesso em: 22/01/2021.

CHOU, J. S.; LIN, C. W.; PHAM, A. D.; SHAO, J. Y. Optimized artificial intelligence models for predicting project award price. **Automation in Construction**, v. 54, s. n., p. 106-115, 2015.

COELHO, L.C.T. **Anaplasmosse bovina: parâmetros clínicos e de patologia clínica em bezerros infectados experimentalmente**. 2007. 65f. Dissertação (Mestrado em Medicina Veterinária) – Universidade Federal de Minas Gerais, Belo Horizonte, 2007.

COMINOTTE, A.; FERNANDES, A. F. A.; DOREA, J. R. R.; ROSA, G. J. M. Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases. **Livestock Science**, v. 232, s. n., p. 103904-103914, 2020.

COPPIN, G.; LEGRAS, F. Controlling swarms of unmanned vehicles through user-centered commands. In: **2012 AAAI Fall Symposium Series**, 2012.

CORONADO, A. Is *Boophilus microplus* the main vector of *Anaplasma marginale*? Technical note. **Revista Científica de la Facultad de Ciencias Veterinarias**, v. 11, n. 5, p. 408-411, 2001.

COSTA, J. H.; CANTOR, M. C.; NEAVE, H. W. Symposium review: Precision technologies for dairy calves and management applications. **Journal of Dairy Science**, v. 104, s. n., p. 1203-1219, 2021.

COX, M.; ELLSWORTH, D. Managing big data for scientific visualization. In: **ACM siggraph**, v.97, p. 21-38, 1997.

DA ROSA RIGHI, R.; GOLDSCHMIDT, G.; KUNST, R.; DEON, C.; DA COSTA, C. A. Towards combining data prediction and internet of things to manage milk production on dairy cows. **Computers and Electronics in Agriculture**, v. 169, s. n., p. 105156-105169, 2020.

DAVENPORT, T. H.; RONANKI, R. Artificial intelligence for the real world. **Harvard Business Review**, v. 96, n. 1, p. 108-116, 2018.

DE ALMEIDA, A. M.; ZACHUT, M.; HERNÁNDEZ-CASTELLANO, L. E.; ŠPERANDA, M.; GABAI, G.; MOBASHERI, A. Biomarkers of fitness and welfare in dairy animals: healthy living. **Journal of Dairy Research**, v. 86, n. 4, p. 379-387, 2019.

DE HOLLANDA FERREIRA, A. B., & DOS ANJOS, M. (1988). *Dicionário Aurélio básico da língua portuguesa*. Editora Nova Fronteira.

DE LA FUENTE, J.; GARCIA-GARCIA, J.C.; BLOUIN, E.F.; KOCAN, K.M. Characterization of the functional domain of major surface protein 1a involved in adhesion of the rickettsia *Anaplasma marginale* to host cells. **Microbiologia Veterinária**, v. 91, n. 2-3, p. 265-283, 2003.

DE MAURO, A.; GRECO, M.; GRIMALDI, M.; RITALA, P. Human resources for Big Data professions: A systematic classification of job roles and required skill sets. **Information Processing & Management**, v. 54, n. 5, p. 807-817, 2018.

DELHEZ, P.; HO, P. N.; GENGLER, N.; SOYEURT, H.; PRYCE, J. E. Diagnosing the pregnancy status of dairy cows: How useful is milk mid-infrared spectroscopy. **Journal of Dairy Science**, v. 103, n. 4, p. 3264-3274, 2020.

DENG, Z., LAM, T. J. G. M., HOGEVEEN, H., SPANINKS, M., HEIJ, N., POSTEMA, M.; KOOP, G. Antimicrobial use and farmers' attitude toward mastitis treatment on dairy farms with automatic or conventional milking systems. **Journal of Dairy Science**, v. 103, n. 8, p. 7302-7314, 2020.

DIVERS, T.J.; PEEK, S.F. “Metabolic diseases” *Rebhun's Diseases of Dairy Cattle*, 2. Ed, United States: Saunders Elsevier, p.590-596, 2008.

DOLECHECK, K. A.; W. J. SILVIA.; G. HEERSCHE JR.; CHANG. Y. M.; RAY. D. L.; STONE. A. E.; WADSWORTH. B. A.; BEWLEY. J. M. Behavioral and physiological changes around estrus events identified using multiple automated monitoring technologies. **Journal of Dairy Science**, v. 98, n. 12, p. 8723-8731, 2015.

DÓREA, J. R. R.; G. J. M. ROSA.; WELD. K. A.; ARMENTANO. L. E. Mining data from milk infrared spectroscopy to improve feed intake predictions in lactating dairy cows. **Journal of Dairy Science**, v. 101, n. 7, p. 5878-5889, 2018.

DUMLER, J.S.A.F.; BARBET, C.P.J.; BEKKER, G.A. Reorganization of the genera in the families Rickettsiaceae and Anaplasmataceae in the order Rickettsiales: unification of some species of Ehrlichia with Anaplasma, Cowdria with Ehrlichia and Ehrlichia with Neorickettsia, descriptions of six new species combinations and designation of Ehrlichia equi and “HGE agent” as subjective synonyms of *Ehrlichia phagocytophila*. **International Journal of Systematic and Evolutionary Microbiology**, v. 51, n. 6, p. 2145-2165, 2001.

EBRAHIMIE, E.; EBRAHIMI. F.; EBRAHIMI. M.; TOMLINSON. S. Hierarchical pattern recognition in milking parameters predicts mastitis prevalence. **Computers and Electronics in Agriculture**, v. 147, s. n., p. 6-11, 2018.

ECKELKAMP, E. A.; BEWLEY, J. M. On-farm use of disease alerts generated by precision dairy technology. **Journal of Dairy Science**, v. 103, n. 2, p. 1566-1582, 2020.

EHRET, A.; HOCHSTUHL, D.; KRATTENMACHER, N.; TETENS. J.; KLEIN.; W. GRONWALD. M. S.; THALLER. G. Use of genomic and metabolic information as well as milk performance records for prediction of subclinical ketosis risk via artificial neural networks. **Journal of Dairy Science**, v. 98, n.1, p. 322-329, 2015.

ELLIS, J. L.; JACOBS, M.; DIJKSTRA, J.; VAN LAAR. H.; CANT. J. P.; TULPAN. D.; FERGUSON. N. Synergy between mechanistic modelling and data-driven models for modern animal production systems in the era of big data. **Animal**, v. 14, n. S2, p. 1-15, 2020.

FENLON, C.; O'GRADY. L.; MEE. J. F.; BUTLER. S. T.; DOHERTY. M. L.; DUNNION. J. A comparison of 4 predictive models of calving assistance and difficulty in dairy heifers and cows. **Journal of Dairy Science**, v. 100, n. 12, p. 9746-9758, 2017.

FENLON, C.; O'GRADY. L.; DUNNION. J.; SHALLOO. L.; BUTLER. S.; DOHERTY. M. A comparison of machine learning techniques for predicting insemination outcome in Irish dairy cows. 2016.

FERRIS, M. C.; CHRISTENSEN, A.; WANGEN, S. R. Symposium review: Dairy Brain—Informing decisions on dairy farms using data analytics. **Journal of Dairy Science**, v. 103, n. 4, p. 3874-3881, 2020.

FIGUEROA, J.V.; CHIEVES, L.P.; JOHNSON, G.S.; BUENING, G. M. Multiplex polymerase chain reaction based assay for the detection of *Babesia bigemina*, *Babesia bovis* and *Anaplasma marginale* DNA in bovine blood. **Veterinary Parasitology**, v. 50, n. 1-2, p. 69-81, 1993.

FOGARTY, E. S.; SWAIN, D. L.; CRONIN, G. M.; MORAES, L. E.; TROTTER, M. Behaviour classification of extensively grazed sheep using machine learning. **Computers and Electronics in Agriculture**, v. 169, s. n., p.105175, 2020.

FOIL, L. D. Tabanids as vectors of disease agents. **Parasitology Today**, v. 5, n. 3, p. 88-96, 1989.

FRAIWAN, M.; ABUTARBUSH, S. M. Using Artificial Intelligence to Predict Survivability Likelihood and Need for Surgery in Horses Presented with Acute Abdomen (Colic). **Journal of Equine Veterinary Science**, v. 90, s. n., p. 102973, 2020.

FROST, A. R.; SCHOFIELD, C. P.; BEAULAH, S. A.; MOTTRAM, T. T; LINES, J. A; WATHES, C. M A review of livestock monitoring and the need for integrated systems. **Computers and Electronics in Agriculture**, v. 17, n. 2, p. 139-159, 1997.

FU, Q.; SHEN, W.; WEI, X.; ZHANG, Y. Prediction of the diet energy digestion using kernel extreme learning machine: A case study with Holstein dry cows. **Computers and Electronics in Agriculture**, v. 169, s. n., p. 105231, 2020.

GALE, K.R.; DIMMOCK, C.M.; GARTSIDE, M.; LEATCH, G. *Anaplasma marginale*: detection of carrier cattle by PCR-ELISA. **International Journal for Parasitology**, v. 26, n. 10, p. 1103-1109, 1996.

GARGIULO, J. I.; EASTWOOD, C. R.; GARCIA, S. C.; LYONS, N. A. Dairy farmers with larger herd sizes adopt more precision dairy technologies. **Journal of Dairy Science**, v. 101, n. 6, p. 5466-5473, 2018.

GATES, M. C.; LITTLEWOOD, K. E.; KONGARA, K.; ODOM, T. F.; SAWICKI, R. K. Guidelines for implementing a low-cost volunteer desexing skills training program for veterinary and veterinary technology students. **Journal of Veterinary Medical Education**, v. 47, n. 1, p. 27-38, 2020.

GIANOLA, D.; OKUT, H.; WEIGEL, K. A.; ROSA, G. J. M. Predicting complex quantitative traits with Bayesian neural networks: a case study with Jersey cows and wheat. **BMC Genetics**, v. 12, n. 1, p. 1-14, 2011.

GIARDINA, S.; ASO, P. M.; BRETaña, A. Antigen recognition on *Anaplasma marginale* and bovine erythrocytes: an electron microscopy study. **Veterinary Immunology and Immunopathology**, v. 38, n. 1-2, p. 183-191, 1993.

GORCZYCA, M. T.; GEBREMEDHIN, K. G. Ranking of environmental heat stressors for dairy cows using machine learning algorithms. **Computers and Electronics in Agriculture**, v. 168, s. n., p. 105124-105132, 2020.

GRISI, L.; MASSARD, C. L.; BORJA, G.E.M. Impacto econômico das principais ectoparasitoses em bovinos no Brasil. **A Hora Veterinária**, v. 21, n. 125, p. 8-10, 2002.

GUGLIELMONE, A.A. Epidemiology of babesiosis and anaplasmosis in south and Central America. **Veterinary Parasitology**, v. 57, n. 1-3, p.109-119, 1995.

GUO, Y.; HE, D.; CHAI, L. A Machine Vision-Based Method for Monitoring Scene-Interactive Behaviors of Dairy Calf. **Animals**, v. 10, n. 2, p. 190-204, 2020.

GUZELLA, T. S.; CAMINHAS, W. M. A review of machine learning approaches to spam filtering. **Expert Systems with Applications**, v. 36, n. 7, p. 10206-10222, 2009.

HAZARI, P. K.; KUMAR, P.; JHA, A.; BHATIA, N. Analysis of Factors of Milk Production and Use of ICT in Diary: India Versus Jharkhand. In: **Smart Intelligent Computing and Applications**, p. 77-91, 2020.

HEMPSTALK, K.; MCPARLAND, S.; BERRY, D. P. Machine learning algorithms for the prediction of conception success to a given insemination in lactating dairy cows. **Journal of Dairy Science**, v. 98, n. 8, p. 5262-5273, 2015.

HIGAKI, S.; MIURA, R.; SUDA, T. T.; ANDERSSON, L. M.; OKADA, H.; ZHANG, Y.; ITOH, T.; MIWAKEICHI, F.; YOSHIOKA, K. Estrous detection by continuous measurements of vaginal temperature and conductivity with supervised machine learning in cattle. **Theriogenology**, v. 123, s. n., p. 90-99, 2019.

HILL, T. M.; SUAREZ-MENA, F. X.; HU, W.; DENNIS PAS, T.S.; SCHLOTTERBECK, R. L.; TIMMS, L. L.; HULBERT, L. E. Evaluation of an ear-attached movement sensor to record rumination, eating, and activity behaviors in 1-month-old calves. **The Professional Animal Scientist**, v. 33, n. 6, p. 743-747, 2017.

HIXSON, C. L.; KRAWCZEL, P. D.; CALDWELL, J. M.; MILLER-CUSHON, E. K. Behavioral changes in group-housed dairy calves infected with *Mannheimia haemolytica*. **Journal of Dairy Science**, v. 101, n. 11, p. 10351-10360, 2018.

HU, H.; DAI, B.; SHEN, W.; WEI, X. Cow identification based on fusion of deep parts features. **Biosystems Engineering**, v. 192, s. n., p. 245-256, 2020.

HUANG, L.; LI, S.; ZHU, A.; FAN, X.; ZHANG, C.; WANG, H. Non-contact body measurement for Qinchuan cattle with LiDAR sensor. **Sensors**, v. 18, N. 9, p. E3014, 2018.

HUR, B. A.; HARDEFELDT, L. Y.; VERSPOOR, K. M.; BALDWIN, T.; GILKERSON, J. R. Describing the antimicrobial usage patterns of companion animal veterinary practices; free text analysis of more than 4.4 million consultation records. **PloS one**, v. 15, n. 3, p. e0230049, 2020.

HYDE, R. M.; DOWN, P. M.; BRADLEY, A. J.; BREEN, J. E.; HUDSON, C.; LEACH, K. A.; GREEN, M. J. Automated prediction of mastitis infection patterns in dairy herds using machine learning. **Scientific Reports**, v. 10, n. 1, p. 1-8, 2020.

JAEGER, M.; BRÜGEMANN, K.; BRANDT, H.; KÖNIG, S. Associations between precision sensor data with productivity, health and welfare indicator traits in native black and white dual-purpose cattle under grazing conditions. **Applied Animal Behaviour Science**, v. 212, s. n., p. 9-18, 2019.

JENSEN, D. B.; LARSEN, M. L. V.; PEDERSEN, L. J. Predicting pen fouling in fattening pigs from pig position. **Livestock Science**, v. 231, s. n., p. 103852, 2020.

KAPLAN, A.; HAENLEIN, M. Rulers of the world, unite! The challenges and opportunities of artificial intelligence. **Business Horizons**, v. 63, n. 1, p. 37-50, 2020.

KECELI, A. S.; CATAL, C.; KAYA, A.; B. TEKINERDOGAN. Development of a recurrent neural networks-based calving prediction model using activity and behavioral data. **Computers and Electronics in Agriculture**, v. 170, s. n, p. 105285, 2020.

KEDARI, S.; VUPPALAPATI, J. S.; ILAPAKURTI, A.; KEDARI. S.; VUPPALAPATI. R.; VUPPALAPATI. C. The Role of Supervised Climate Data Models and Dairy IoT Edge Devices in Democratizing Artificial Intelligence to Small Scale Dairy Farmers Worldwide. In: **Fourth International Congress on Information and Communication Technology**, (pp. 383-404). Springer, Singapore, 2020.

KESHAVARZI, H.; SADEGHI-SEFIDMAZGI, A.; MIRZAEI, A.; RAVANIFARD. R. Machine learning algorithms, bull genetic information, and imbalanced datasets used in abortion incidence prediction models for Iranian Holstein dairy cattle. **Preventive Veterinary Medicine**, v. 175, s. n., p. 104869, 2020.

KHAN, M. A.; BACH, A.; WEARY, D. M.; VON KEYSERLINGK. M. A. G. Invited review: Transitioning from milk to solid feed in dairy heifers. **Journal of Dairy Science**, v. 99, s. n., p. 885-902, 2016.

KIESER, S.T.; ERIKS, I.S.; PALMER, G.H. Cyclic rickettsemia during persistent *Anaplasma marginale* infection of cattle. **Infection and Immunity**, v. 58, n. 4, p. 1117-1119, 1990.

KITCHIN, R. Big Data—hype or revolution. **The SAGE handbook of social media research methods**, p.27, 2017.

KNIGHT, C. H. Sensor techniques in ruminants: more than fitness trackers. **Animal**, v. 14, n. S1, p. 187-195, 2020.

KOCAN, K.M.; EWING, S.A.; HAIR, J.A.; BARRON. S. J. Demonstration of the inclusion appendage of *Anaplasma marginale* in nymphal *Dermacentor andersoni*. **American Journal of Veterinary Research**, v. 45, n. 9, p. 1800-1807, 1984.

KOCAN, K.M.; DE LA FUENTE, F.J.; BLOUIN, E. F.; COETZEE. J. F. The natural history of *Anaplasma marginale*. **Veterinary Parasitology**, v. 167, n. 2-4, p. 95-107, 2010.

KOCAN, K. M.; DE LA FUENTE, J.; GUGLIELMONE, A. A. Antigens and alternatives for control of *Anaplasma marginale* infection in cattle. **Clinical Microbiology Reviews**, v. 16, n. 4, p.698-712, 2003.

LASMAR, P. V. F.; CARVALHO, A.U.; FACURY FILHO, E. J.; BASTOS. C. V.; RIBEIRO. M. F. B. Evaluating the effectiveness of an inactivated vaccine from *Anaplasma marginale* derived from tick cell culture. **Revista Brasileira de Parasitologia Veterinária**, v. 21, n. 2, p. 112-117, 2012.

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. **Journal of Dairy Science**, v. 93, n. 11, p. 5129-5139, 2010.

LOSOS, G.J. Rickettsial Diseases – Anaplasmosis. In: **Infectious tropical diseases of domestic animals**. 1. Ed., New York: Churchill Livingstone Inc., p. 742-795, 1986.

LOVARELLI, D.; BACENETTI, J.; GUARINO, M. A review on dairy cattle farming: Is precision livestock farming the compromise for an environmental, economic and social sustainable production? **Journal of Cleaner Production**, v. 262, s. n., p. 121409, 2020.

LOWE, G.L.; SUTHERLAND, M.A.; WAAS, J.R.; SCHAEFER. A. L.; COX. N. R.; STEWART. M. Physiological and behavioral responses as indicators for early disease detection in dairy calves. **Journal of Dairy Science**, v. 102, n. 6, p. 5389–5402, 2019.

MALTZ, E. Individual dairy cow management: achievements, obstacles and prospects. **Journal of Dairy Research**, v. 87, n. 2, p. 145-157, 2020.

MANOGARAN, G.; THOTA, C.; LOPEZ, D.; ABBAS. K. M.; SUNDARSEKAR. R. Big data knowledge system in healthcare. In: **Internet of things and big data technologies for next generation healthcare**, Springer, Cham, p. 133-157, 2017.

MARANA, E. R. M.; DIAS, J. A.; FREIRE, R. L.; VICENTINI. J. C.; VIDOTTO. M. C.; VIDOTTO. O. Soroprevalência de *Anaplasma marginale* em bovinos da região Centro-Sul do estado do Paraná, Brasil, por um teste imunoenzimático competitivo utilizando proteína recombinante MSP5-PR1. **Revista Brasileira de Parasitologia Veterinária**, v. 18, s. n., p. 20-26, 2009.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115-133, 1943.

MELÉNDEZ, R. D. Phagocytosis of *Anaplasma marginale* infected and uninfected erythrocytes by bovine peripheral blood leucocytes. **Revista Científica**, v. 15, n. 4, p. 305-309, 2005.

MELO, I. O. **Balanço ácido-base, hidroeletrólítico e hemograma de bezerros inoculados com *Anaplasma marginale***. 2018. 77p. Dissertação (Mestrado em Ciência Animal) – Escola de Veterinária, Universidade Federal de Minas Gerais, Belo Horizonte. 2018.

MENDONCA, F. L. **Utilização de isolados de *Anaplasma marginale* de baixa virulência em protocolos de imunização de bezerros: análise dos efeitos pós-vacinais e proteção contra o desafio natural.** 2015. 69p. Dissertação (Mestrado em Ciência Animal) – Escola de Veterinária, Universidade Federal de Minas Gerais, Belo Horizonte. 2015.

MENESES, R. M. **Isolamento e caracterização molecular de *Anaplasma marginale* de origem congênita e avaliação da virulência em bezerros experimentalmente infectados.** 2013. 76f. Dissertação (Mestrado em Ciência Animal) – Escola de Veterinária, Universidade Federal de Minas Gerais, Belo Horizonte, 2013.

MICHIE, C.; ANDONOVIC, I.; DAVISON, C.; HAMILTON, A.; TACHTATZIS, C.; JONSSON, N.; DUTHIE, C-A.; JENNA BOWEN.; GILROY, M. The Internet-of-things enhancing animal welfare and farm operational efficiency. **Journal of Dairy Research**, v. 87, n. S1, p. 20-27, 2020.

MILLER, G. A.; MITCHELL, M.; BARKER, Z. E.; GIEBEL, K.; CODLING, E. A.; AMORY, J. R.; MICHIE, C.; DAVISON, C.; TACHTATZIS, C.; ANDONOVIC, I.; DUTHIE, C. A. Using animal-mounted sensor technology and machine learning to predict time-to-calving in beef and dairy cows. **Animal**, v. 14, n. 6, p. 1304-1312, 2020.

MOLAD, T.; MAZUZ, M.L.; FLEIDEROVITZ, L.; FISH, L.; SAVITSKY, I.; KRIGEL, Y.; LEIBOVITZ, B.; MOLLOY, J.; JONGEJAN, F.; SHKAP, V. Molecular and serological detection of *A. centrale* and *A. marginale*-infected cattle grazing within an endemic area. **Veterinary Microbiology**, v. 113, n. 1-2, p. 55-62, 2006.

MOTTRAM, T.; LOWE, J.; MCGOWAN, M.; PHILLIPS, N. Technical note: a wireless telemetric method of monitoring clinical acidosis in dairy cows. **Computers and Electronics in Agriculture**, v. 64, n. 1, p. 45–48, 2008.

MUÑIZ, R.; CUEVAS-VALDÉS, M.; DE LA ROZA-DELGADO, B. Milk quality control requirement evaluation using a handheld near infrared reflectance spectrophotometer and a bespoke mobile application. **Journal of Food Composition and Analysis**, v. 86, s. n., p. 103388-103396, 2020.

OIE. Bovine anaplasmosis. OIE Terrestrial manual. [S.l: s.n.], 2017. v.13. p. 1-15. OIE. TERRESTRIAL ANIMAL HEALTH CODE. 46. ed. [S.l.]: Publications, World Organisation for Animal Health (OIE), 2017. v. I. Disponível em: <<https://www.oie.int/doc/ged/D10905.PDF>>. Acessado em: 02 jan 2021.

PATISON, K.; TROTTER, M.; SWAIN, D.; CORBET, N.; BAILEY, D.; KINDER, J. Applying proximity sensors to monitor beef cattle social behaviour as an indicator of animal welfare. In: **1st Asian-Australasian Conference on Precision Pastures and Livestock Farming**, Hamilton, New Zealand, 2017.

PAWAR, K.; PANCHAL, I. Artificial Intelligence in Dairy Farming: A Way Forward for Improving the Health of Dairy-Cows. Research & Reviews: **Journal of Dairy Science and Technology**, v. 8, s. n., p.13-16, 2020.

RASCHKA, S.; MIRJALILI, V. Python Machine Learning: Machine Learning and Deep Learning with Python. **Scikit-Learn, and Tensor Flow**. 2. Ed, 2017.

RESHEFF, Y. S.; ROTICS, S.; HAREL, R.; SPIEGEL, O.; NATHAN, R. AcceleRater: a web application for supervised learning of behavioral modes from acceleration measurements. **Movement Ecology**, v. 2, n. 1, p. 1-7, 2014.

REYNOLDS, M. A.; BORCHERS, M. R.; DAVIDSON, J. A.; BRADLEY, C. M.; BEWLEY, J. M. An evaluation of technology-recorded rumination and feeding behaviors in dairy heifers. **Journal of Dairy Science**, v. 102, n. 7, p. 6555-6558, 2019.

RIBEIRO, M.F.B.; LIMA, J.D. Morphology and development of *Anaplasma marginale* in midgut of engorged female ticks of *Boophilus microplus*. **Veterinary parasitology**, v. 61, n. 1-2, p.v31-39, 1996.

RIBEIRO, M.F.B.; LIMA, J.D.; SALCEDO, J.H.P. Attempted transmission of *Anaplasma marginale* by infected *Boophilus microplus*. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, v. 48, s. n., p. 397-402, 1996.

RIBEIRO, M.F.B.; PASSOS L.M.F. Tristeza Parasitária Bovina. **Cadernos Técnicos de Veterinária e Zootecnia**, v.39, s. n., p. 36-52, 2002.

RIBEIRO, M.F.B.; SALCEDO, J.H.P.; SANTOS, J.L. Inquérito de opinião com criadores da Zona da Mata do estado de Minas Gerais: I. Alguns fatores associados com a mortalidade de bezerras. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, v. 35, s. n., p. 547-556, 1983.

RICHEY, E.J. Bovine Anaplasmosis In: **Howard - Current Veterinary Therapy: Food Animal Practice**. 3. Ed. Philadelphia:W.B. Saunders Company, p. 767-772, 1993.

RISTIC, M.; SIBINOVIC, S.; WELTER, J.C. An attenuated *Anaplasma marginale* vaccine. *Proc. 72nd Ann. Meet. U. S. Livest. Sanit. Assoc.*, v.72, p.56-69, 1968.

ROBERT, B.; WHITE, B. J.; RENTER, D. G.; LARSON, R. L. Evaluation of three-dimensional accelerometers to monitor and classify behavior patterns in cattle. **Computers and Electronics in Agriculture**, v. 67, n. 1-2, p. 80-84, 2009.

RODRIGUES, J. P. P.; PEREIRA, L. G. R.; NETO, H. D. C. D.; LOMBARDI, M. C.; LAGE, C. F. A.; COELHO, S. G.; SACRAMENTO, J. P.; MACHADO F. S.; TOMICH, T. R.; MAURÍCIO, R. M.; CAMPOS, M. M. Evaluation of an automatic system for monitoring rumination time in weaning calves. **Livestock Science**, v. 219, s. n., p. 86-90, 2019.

RODRÍGUEZ, S. D., ORTIZ, M. G., SALGADO, G. H., CERDA, N. S., TORRES, R. A., & ALARCÓN, G. C. *Anaplasma marginale* inactivated vaccine: dose titration against a homologous challenge. **Comparative immunology, microbiology and infectious diseases**, v. 23, n. 4, p. 239-252, 2000.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386, 1958.

RUTTEN, C.J.; VELTHUIS, A.G.J.; STEENEVELD, W.; HOGEVEEN, H. Invited review: sensors to support health management on dairy farms. **Journal of Dairy Science**, v. 96, n. 4, p. 1928–1952, 2013.

RUUSKA, S.; KAJAVA, S.; MUGHAL, M.; ZEHNER, N.; MONONEN, J. Validation of a pressure sensor-based system for measuring eating, rumination and drinking behaviour of dairy cattle. **Applied Animal Behaviour Science**, v. 174, s. n., p. 19-23, 2016.

SACCO, A.M.S.; KESSLER, R.H.; MADRUGA, C.R. Cepas atenuadas de *Babesia bovis* e *Babesia bigemina* e de *Anaplasma marginale* como imunógenos no controle da tristeza parasitária bovina. **Ciência Rural**, v. 31, s. n., p. 849-855, 2001.

SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of Research and Development**, v. 3, n. 3, p. 210-229, 1959.

SARANYA, P.; KRISHNESWARI, K.; KAVIPRIYA, K. Identification of Diseases in Dairy Cow Based on Image Texture Feature and Suggestion of Therapeutical Measures, 2020.

SEMENENKO, M. P.; KUZMINOVA, E. V.; SEMENENKO, K. A.; KUZMINOV, N. D. Methodology of development and diagnostic efficiency of expert systems in animal hepatopathies. In: **IOP Conference Series: Earth and Environmental Science**, v. 421, IOP Publishing, p. 052038, 2020.

SEN, P. C.; HAJRA, M.; GHOSH, M. Supervised classification algorithms in machine learning: A survey and review. In: **Emerging technology in modelling and graphics**. Springer, Singapore, p. 99-111, 2020.

SHANKAR, V. How artificial intelligence (AI) is reshaping retailing. **Journal of Retailing**, v. 94, n. 4, p. 6-11, 2018.

SHUTSKE, J. M.; TRECHTER, D.; LUCK, B. D. Assessment of Digital Capacity, Needs and Access Barriers Among Crop, Dairy and Livestock Producers. In **2018 ASABE Annual International Meeting**. American Society of Agricultural and Biological Engineers, 2018. p. 1.

SILVA, J.B.; FONSECA, A.H. Risk factors for anaplasmosis in dairy cows during the peripartum. **Tropical Animal Health and Production**, v. 46, n. 2, p. 461-465, 2014.

SILVI, R.; PEREIRA, L. G. R.; PAIVA, C. A. V.; TOMICH, T. R.; TEIXEIRA, V. A.; SACRAMENTO, J. P.; FERREIRA, R. A. P.; COELHO, S. G.; MACHADO, F. S.; CAMPOS, M. M.; DÓREA, J. R. R. Adoption of Precision Technologies by Brazilian Dairy Farms: The Farmer's Perception. **Animals**, v. 11, p. 3488, 2021.

SMITH, R.; LEVY, M.G.; KUHLENSCHMIDT, M.S.; ADAMS J. H.; RZECHULA, D. L.; HARDT, T. A.; KOCAN, K. M. Isolate of *Anaplasma marginale* not transmitted by ticks. **American Journal of Veterinary Research**, v. 47, n. 1, p. 127-129, 1986.

SONG, X.; VAN DER TOL. P.P.J.; GROOT KOERKAMP. P. W.G.; BOKKERS. E. A. M. Hot topic: automated assessment of reticulo-ruminal motility in dairy cows using 3-dimensional vision. **Journal of Dairy Science**, v. 102, n. 10, p. 9076–9081, 2019.

SOUZA, R.S., M.F.S. RESENDE, L.C.A. FERREIRA, R.S. FERRAZ, M.V.V. ARAÚJO, C. V. BASTOS, J.A.G. SILVEIRA, T.F. MOREIRA, R.M. MENESES, A.U. CARVALHO, F.O.P. LEME, E.J. FACURY FILHO. 2021. Monitoring bovine tick fever on a dairy farm: An economic proposal for rational use of medications. **Journal of Dairy Science**. v.104, p.5643-5651, 2021.

SPARE, M. R.; HANZLICEK, G. A.; WOOTTEN, K. L.; ANDERSON. G, A.; THOMSON. D. U.; SANDERSON. M, W.; GANTA. R, R.; REIF. K, E.; RAGHAVAN. R, K. Bovine anaplasmosis herd prevalence and management practices as risk-factors associated with herd disease status. **Veterinary Parasitology**, v. 3, s. n., p. 100021-100027, 2020.

STEENEVELD, W.; HOGEVEEN, H. Characterization of Dutch dairy farms using sensor systems for cow management. **Journal of Dairy Science**, v. 98, n. 1, p.709-717, 2015.

STONE, A. E. Symposium review: The most important factors affecting adoption of precision dairy monitoring technologies. **Journal of Dairy Science**, v. 103, n. 6, p. 5740-5745, 2020.

STUDDS, M. J.; DEIKUN, L. L.; SORTER, D. E. The effect of diarrhea and navel inflammation on the lying behavior of veal calves. **Journal of Dairy Science**, v. 101, n. 12, p. 11251-11255, 2018.

SUTHERLAND, M. A.; LOWE, G. L.; HUDDART, F. J.; WAAS. J, R.; STEWART. M. Measurement of dairy calf behavior prior to onset of clinical disease and in response to disbudding using automated calf feeders and accelerometers. **Journal of Dairy Science**, v. 101, n. 9, p. 8208-8216, 2018.

TALUKDER, S.; THOMSON, P. C.; KERRISK, K. L.; CLARK. C, E. F.; CELI. P, Evaluation of infrared thermography body temperature and collar-mounted accelerometer and acoustic technology for predicting time of ovulation of cows in a pasture-based system. **Theriogenology**, v. 83, n. 4, p. 739-748, 2015.

THEILER, A. *Anaplasma marginale*: The marginal points in the blood of cattle suffering from a specific disease. In: THEILER, A. **Report of the Government Veterinary Bacteriologist 1908 – 1909**. Transvaal, South Africa: Transvaal Department of Agriculture, p. 6-64, 1910.

THEILER, A. Further investigations into anaplasmosis of South African cattle. In: **1st Report of the Director of Veterinary Research**, Department of Agriculture of the Union of South Africa, p.7-46, 1911.

TOAFF-ROSENSTEIN, R. L.; GERSHWIN, L. J.; ZANELLA, A. J.; TUCKER, C. B. The sickness response in steers with induced bovine respiratory disease before and after treatment with a non-steroidal anti-inflammatory drug. **Applied Animal Behaviour Science**, v. 181, s. n., p. 49-62, 2016.

TURING, A. M. Computing machinery and intelligence. In: **Parsing the turing test**. Springer, Dordrecht, 2009. p. 23-65.

UNOLD, O.; NIKODEM, M.; PIASECKI, M.; SZYC, K.; MACIEJEWSKI, H.; BAWIEC, M.; DOBROWOLSKI, P.; ZDUNEK, M. IoT-Based Cow Health Monitoring System. In **International Conference on Computational Science**, Springer, Cham, 2020. p. 344-356.

URTON, G. M. A. G.; VON KEYSERLINGK, M. A. G.; WEARY, D. M. Feeding behavior identifies dairy cows at risk for metritis. **Journal of Dairy Science**, v. 88, n. 8, p. 2843-2849, 2005.

VIDOTTO, O.; MARANA, E.R.M. Diagnóstico em anaplasrose bovina. **Ciência Rural**, v. 31, s. n., p. 361-368, 2001.

WAGHELA, S.D.; MELENDY, D.; CRUZ, D.; WAGNER, G. G. Antigenic analysis of *Anaplasma marginale* grown in bovine erythrocytes co-cultured with bovine endothelial cells. **Veterinary Parasitology**. v. 94, n. 1-2, p. 133-139, 2000.

WANER, T.; MAHAN, S.; KELLY, P. Rickettsiales. In: GYLES, C.L.; PRESCOTT, J.F.; SONGER, J. G. *et al.* **Pathogenesis of Bacterial Infections in Animals**. 4.ed. Wiley-blackwell, p.589-621, 2010.

WEIGEL, K. A.; P, M. VANRADEN.; H, D. NORMAN.; H, GROSU. A 100-Year Review: Methods and impact of genetic selection in dairy cattle—From daughter–dam comparisons to deep learning algorithms. **Journal of Dairy Science**, v. 100, n. 12, p. 10234-10250, 2017.

WICKWIRE, K.B.; KOCAN, K.M.; BARRON, S.T.; EWING, S, A.; SMITH, R, DHAIR, J, A.; Infectivity of three *Anaplasma marginale* isolates for *Demarcentor andersoni*. **American Journal of Veterinary Research**, v. 48, n. 1, p. 96-99, 1987.

WILLIAMS, L. R.; BISHOP-HURLEY, G. J.; ANDERSON, A. E.; SWAIN, D, L. Application of accelerometers to record drinking behaviour of beef cattle. **Animal Production Science**, v. 59, n. 1, p. 122-132, 2019.

WILLIAMS, L. R.; MOORE, S. T.; BISHOP-HURLEY, G. J.; SWAIN, D, L. A sensor-based solution to monitor grazing cattle drinking behaviour and water intake. **Computers and Electronics in Agriculture**, v. 168, s. n., p. 105141, 2020.

YULE, I.; EASTWOOD, C. Challenges and opportunities for precision dairy farming in New Zealand. In: **Proceedings of the 11th international conference on precision Agriculture**, Indianapolis, Indiana, USA, p. 15-18, 2012.

ZABEL, T. A.; AGUSTO, F. B. Transmission dynamics of bovine anaplasmosis in a cattle herd. **Interdisciplinary Perspectives on Infectious Diseases**, v. 2018, s. n., p. 1-17, 2018.

ZACHUT, M.; ŠPERANDA, M.; DE ALMEIDA, A. M.; GABAI, G.; MOBASHERI, A.; HERNÁNDEZ-CASTELLANO, L. E. Biomarkers of fitness and welfare in dairy cattle: healthy productivity. **Journal of Dairy Research**, v. 87, n. 1, p. 4-13, 2020.

ZEHNER, N.; UMSTATTER, C.; NIEDERHAUSER, J.J.; SCHICK, M. 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**, v. 136, s. n., p. 31–41, 2017.

3 ARTIGOS

3.1 Artigo 1 - Using activity and rumination data for early detection of anaplasmosis disease in dairy heifer calves

Este artigo foi **aceito** na revista Journal Dairy Science.

INTERPRETATIVE SUMMARY

Using activity and rumination data for early detection of anaplasmosis disease in dairy heifer calves. *Teixeira et al.* Bovine anaplasmosis can cause significant economic losses in dairy cattle production systems worldwide. The procedures used for anaplasmosis diagnosis are usually laborious, costly, and difficult to apply in large-scale operations. Thus, the use of wearable sensing technologies to automatically identify health problems in dairy cattle is an innovative and promising strategy. We investigated whether data from activity and rumination collars can be used for early detection of anaplasmosis disease in dairy calves. Activity and rumination accurately identify sick animals five days prior to clinical disease diagnosis.

RUNNING HEAD: USING SENSORS FOR EARLY DETECTION OF ANAPLASMOSIS

**Using activity and rumination data for early detection of anaplasmosis disease in dairy
heifer calves**

V. A. Teixeira,¹ A. M. Q. Lana,¹ T. Bresolin,² T. R. Tomich,³ G. M. Souza,⁴ J. Furlong,³ J. P. P. Rodrigues⁵, S. G. Coelho,¹ L. C. Gonçalves,¹ J. A. G. Silveira⁶, L. D. Ferreira,¹ E. J. Facury Filho,¹ M. M. Campos,³ J. R. R. Dorea,^{2*} L. G. R. Pereira³

¹Department of Animal Science, School of Veterinary Medicine, Federal University of Minas Gerais, Minas Gerais, 30161-970, Brazil

²Department of Animal and Dairy Science, University of Wisconsin-Madison, Wisconsin, USA

⁴Department of Animal Science, Federal University of Lavras, Minas Gerais, 37200-000, Brazil

³Brazilian Agricultural Research Corporation - Embrapa, Embrapa Dairy Cattle, Minas Gerais, 36038-330, Brazil

⁵Faculty of Animal Science, Federal University of Southern and Southeastern Pará, Xinguara, Pará, 68557-335, Brazil

⁶Department of Parasitology, Institute of Biological Sciences, Federal University of Minas Gerais, Minas Gerais, 31270-901, Brazil,

*Corresponding author: joao.dorea@wisc.edu

1675 Observatory Drive, 266 Animal Sciences Building, Madison, WI 53706-1205

ABSTRACT

Bovine anaplasmosis causes considerable economic losses in dairy cattle production systems worldwide, ranging from US\$ 300 to US\$ 900 million annually. It is commonly detected through rectal temperature, blood smears microscopy, and packed cell volume (PCV). Such methodologies are laborious, costly, and difficult to systematically implement in large-scale operations. The objectives of this study were to evaluate: *i*) rumination (RUM) and activity (ACT) data collected by the Hr-Tag in heifer calves exposed to anaplasmosis; and *ii*) the predictive ability of recurrent neural networks (RNN) in early identification of anaplasmosis. Additionally, we aimed to investigate: *ii.a*) the effect of time series length prior to disease diagnosis (5, 7, 10 or 12 consecutive days) on the predictive performance of RNN; and *ii.b*) how early anaplasmosis disease can be detected in dairy calves (5, 3, and 1 day in advance). Twenty-three heifer calves aged 119 ± 15 (mean \pm SD) days and weighing 148 ± 20 kg of BW were challenged with 2×10^7 erythrocytes infected with UFMG1 strain (GenBank no. EU676176) isolated from *Anaplasma marginale*. After inoculation, animals were monitored daily by assessing PCV. The lowest PCV value ($14 \pm 1.8\%$) and the finding of rickettsia on blood smears were used as a criteria to classify an animal as sick (d0). Rumination and activity data were collected continuously and automatically at 2h intervals, using SCR Heatime Hr collars. Two time-series (TS) were built including last sequence of -5, -7, -10, or -12d preceding d0 or comprising a sequence of 5, 7, 10 or 12d randomly selected in a window from -50 to -15d before d0 to ensure a sequence of days in which PCV was considered normal ($32 \pm 2.4\%$). Long Short-Term Memory (LSTM) was used as a predictive approach, and a Leave-One-Animal-Out Cross-Validation (LOAOCV) was used to assess prediction quality. The anaplasmosis disease reduced 34% and 11% of RUM and ACT, respectively. The accuracy (ACC), sensitivity (SEN) and specificity (SPE) of LSTM in detecting anaplasmosis ranged

from 87 to 98%, 83 to 100%, and 83 to 100% respectively, using RUM data. For ACT data, the ACC, SEN and SPE varied from 70 to 98%, 61 to 100%, and 74 to 100%, respectively. Predictive performance did not improve when combining RUM and ACT. The use of longer time-series did not improve the performance of models to predict anaplasmosis. The accuracy and sensitivity in predicting anaplasmosis up to 3 days prior to clinical diagnosis (d0) were greater than 80%, confirming the possibility for early identification of anaplasmosis disease. Such accomplishments indicate the great potential of wearable sensors in early identification of anaplasmosis diseases. This could positively impact the profitability of dairy farmers and animal welfare.

Keywords: artificial intelligence, machine learning, sensors, *Anaplasma marginale*

INTRODUCTION

Bovine anaplasmosis caused by *Anaplasma marginale* is endemic in some countries, causing considerable economic losses due to mortality, especially in young animals, reducing animal performance, and increasing costs related to medicines and veterinary services (Kocan et al., 2003; Aubry and Geale, 2011; Ueti et al., 2012). Bovine anaplasmosis is listed as an important disease by World Organization for Animal Health report (OIE, 2019). The mortality caused by anaplasmosis can reduce the number of weaned calf by 3.6% and increase the mortality rate in adult cattle by up to 30% (Zabel and Agosto, 2018). Anaplasmosis is one of the most common post-weaning diseases in tropical countries, and it is responsible for generating annual economic losses of US\$ 300 million in the United States and US\$ 900 million in Latin America, including Dairy and Beef industry (Kocan et al., 2003).

Current procedures used for diagnosis of anaplasmosis are based on laboratory analyses of blood smears using a binocular microscope (Vidotto and Marana, 2001; Aubry and Geale, 2011), and packed cell volume (PCV) (Radostits et al., 2007). Another way to diagnose anaplasmosis is through clinical symptomatology, which includes: fever, mild to severe anemia, jaundice without hemoglobinemia and hemoglobinuria, loss of appetite and weight, dehydration, abortion, anorexia, and lethargy (Souza et al., 2001; Kocan et al., 2003, 2010; Oliveira Júnior et al., 2018). The serological and molecular methods to measure *Anaplasma* spp. antibodies (Aubry and Geale, 2011), include ELISA (Araújo et al., 2005), the Indirect Immunofluorescence Reaction (RIFI) (Visser et al., 1992), and PCR (Molad et al., 2006). Such methods present high specificity (SPE) and sensitivity (SEN); however, they are expensive and difficult to perform routinely on commercial farms. Additionally, systematic monitoring of individual animals for anaplasmosis detection requires time, training and specialized labor,

which become a limiting factor in large-scale livestock operations (Kocan et al., 2003; Silvestre et al., 2016; Oliveira Júnior et al., 2018).

Although the on-farm diagnosis of anaplasmosis disease is based on clinical signs, the peak of anemia occurs only 2 days after the peak of parasitemia, and 1 day after the peak in rectal temperature (Coelho, 2007). Consequently, on-farm anaplasmosis diagnosis usually occurs when the disease has already caused damage to health and economic losses. Therefore, strategies for its early detection would improve disease prognosis and efficiency of the diagnosis, maximizing the sustainable use of antimicrobials.

Precision farming technologies appear as an option for early disease detection. Continuous sensor-based monitoring of rumination and activity has the potential to be used for herd health management decisions (Reiter et al., 2018) and to evaluate animal welfare (Jaeger et al., 2019) through early diagnosis of diseases such as ketosis (Sturm et al., 2020), hypocalcemia (Goff et al., 2020), lameness (Alsaad et al., 2019), diarrhea (Belaid et al., 2020) and respiratory disease (Timsit et al., 2011; Swartz et al., 2017; Hixson et al., 2018). However, the use of such sensor devices to create predictive models for disease detection has not been extensively explored in dairy heifer calves. Souza et al. (2021) recommended a protocol based on blood smears associated with rectal temperature for bovine tick fever monitoring. Such protocol avoided unnecessary treatments, drove the correct treatment, and decreased the unnecessary use of medicines. Continuous sensor-based monitoring can automate animal screening for application of the Souza et al. (2021) protocol.

We hypothesized that anaplasmosis causes changes in rumination time and activity index in dairy heifer calves and that bovine anaplasmosis can be predicted based on either or both RUM and ACT data obtained from wearable sensors. The objectives of this study were to evaluate: *i*) rumination and activity data collected from dairy heifers exposed to anaplasmosis;

and *ii*) Long Short-Term Memory (LSTM) for detection of anaplasmosis using RUM, ACT or both combined. Additionally, we aimed: *ii.a*) to investigate the effect of time series length on predictive performance of LSTM; and *ii.b*) to study how early anaplasmosis diseases can be accurately detected in dairy heifers using sensor data.

MATERIAL AND METHODS

This study was approved by the Embrapa Dairy Cattle Animal Care and Use Committee, Juiz de Fora, Minas Gerais, Brazil (number: 4498240316). The experiment was conducted from February to December 2019 at the Embrapa Dairy Cattle Experimental Farm located in Coronel Pacheco, Minas Gerais, Brazil. Data analysis was conducted at the University of Wisconsin-Madison.

1. Pre-weaning period

Calves, housing, and management

Fifty-five Holstein calves with birth weight of 34.42 ± 6.25 kg (mean \pm SD) were randomly selected from the Embrapa Dairy Cattle experimental farm. Calves were individually placed in pens (1.25 x 1.75 m) located in a shed protected by nylon screen and a double-screened door to prevent contact with flies and ticks, and exposure to anaplasmosis and other tick fever agents. Once a week, the shed was sprayed with Imidacloprid (Rotam do Brazil Agrochemicals and Agricultural Products Ltda., Campinas, São Paulo, Brazil) to keep away flies and mosquitoes. In addition to replacing Thiamethoxan and Z-9-tricosene mosquito baits (Agita 10 Wg - Elanco®) every 3 weeks, a spray containing Cypermethrin 15% + Chlorpyrifos 25% + Piperonyl Butoxide 15% (Ciperclor Plus®, Ceva Saúde Animal Ltda, Paulínia, São Paulo, Brazil) was administered to the animals weekly to prevent tick infestation. This drug

was selected for use based on a sensitivity test performed using ticks found on the experimental farm, as described by Drummond et al. (1973). In addition, the calves received a Diazinon mosquito ring (Top Tag 180 - Zoetis®).

To ensure proper adaptation, one day after birth, each calf received an SCR Hr-Tag Heatime collar (SCR Engineers LTD., Netanya, Israel) according to Rodrigues et al. (2019). The collars were adjusted routinely as the calves grew. Colostrum ($\geq 25\%$ Brix) was administered at a minimum of 10% of BW up to 6 hours after birth (Lombard et al., 2020). To verify the quality of the transfer of passive immunity, plasma blood protein was measured 48 hours after birth (Serum protein REF-301, Biocotek, Beilun, Ningbo, China), and all animals presented adequate values (greater than 5.5 g/dL) as recommended by McGuirk (2003). Calves received transition milk until 3 days of age, and from 4 to 75 days of age, they were fed whole milk ($4.4 \pm 1.0\%$ fat and $3.1 \pm 0.1\%$ CP) using nipple buckets (Milk Bar®, Waipu, New Zealand). The volume of milk supplied was: 8, 6, and 3 L/day from 0 to 30, 31 to 60, and 61 to 75 days of age, respectively. From 0 to 60 days of age, calves were fed twice daily (at 08:00 and 15:00) and from 61 to 75 days of age calves were fed a single meal (at 08:00). A mixture of 95% starter (22% CP and 80% NDF) and 5% Tifton hay (8.5% CP and 69.9% NDF) was fed *ad libitum* from 0 to 60 days of age. After age 61 days, corn silage (6.8% CP and 42% NDF) was fed *ad libitum* in an individual bucket. Between 75 to 90 days of age, the calves were maintained in the same facilities, receiving only solid diet and water.

A clinical examination was performed daily at 08:00 to assess: rectal temperature, nasal discharge, cough, eye discharge, ear positioning, and fecal score according to Larson et al. (1977) and McGuirk (2008). Animals presenting injuries or illness were treated in accordance with routine farm management practices. At 15 and 120 days of age, all animals received coccidiostat (Isocox®, Ouro fino, São Paulo, Brazil) at a dose of 3 mL/10 kg, equivalent to 15

mg/kg of Toltrazuril. Two days after birth, individual blood samples were collected, via puncture of the jugular vein, and placed in vacuum tubes (EDTA, Vacutainer; Becton, Dickinson and Company) to determine the absence of *A. marginale*, *Babesia bovis* and *B. bigemina* using PCR (Silveira et al., 2014) and RIFI (Santos et al., 2017). Twenty-two calves tested positive and were excluded from the experiment to avoid interference from the antibodies that resulted from the responses to vertical transmission in the induced anaplasmosis challenge process. The remaining 23 calves were monitored by collar sensor and challenged with approximately 2×10^7 erythrocytes infected with *A. marginale* UFMG1-EU676176 isolated from a naturally-infected splenectomised calf and cryopreserved in liquid nitrogen using dimethyl sulfoxide (Bastos et al., 2010).

2. Post-weaning period

2.1. Heifer calves, housing, and management

After the pre-weaning period, the remaining 23 dairy heifer calves averaging 119 ± 15 days of age and 148.4 ± 20.3 kg of BW were randomly grouped (8, 8 and 7/group) and moved to three paddocks with a concrete floor (280 m^2) mechanically cleaned daily. The first 15 days of the experimental trial were used for socialization and adaptation of the animals.

In the post-weaning period, calves were fed total mixed ration (TMR; 18% CP and 80% NDF) composed of whole corn silage, ground corn, soybean meal, monensin, and mineral-vitamin (Bovigold Prima®, DSM / Tortuga, Mairinque - SP, Brazil). TMR was provided twice a day (at 08:00 and 15:00) in four electronic feed bins per paddock (AF-1000 Junior; Intergado® Ltda, Minas Gerais, Brazil). The refused feed was removed from the feed bins daily before the morning meals at 09:00. The amount of feed offered was adjusted daily to

reach approximately 10% refusal. Water was offered *ad libitum* by an electronic water bin available in each paddock (WD-1000 Junior, Intergado Ltda.).

The same clinical examination procedure adopted during the pre-weaning period was performed daily at 08:00 to assess rectal temperature, nasal discharge, cough, eye discharge, ear positioning, and fecal score.

2.2. *Anaplasmosis inoculation procedure*

Fifteen days before *A. marginale* inoculation, blood samples were collected to determine the absence of *A. marginale*, *Babesia bovis*, and *B. bigemina* using nPCR and RIFI techniques. Based on nPCR and RIFI results, all 23 animals averaging 119 ± 15 days of age and 148.4 ± 20.3 kg of BW tested negative and were challenged with a low virulence inoculum dosage (2×10^7 erythrocytes infected) of *A. marginale* UFMG1-EU676176 (Bastos et al., 2010).

2.3. *Laboratory and hematological evaluation*

PCV was performed using the microhematocrit method (Weiss, J.D., Wardrop, 2010) using heparinized blood in a capillary tube, which was then centrifuged (SPIN 1000, MICRO SPIN™, São Paulo, Brazil) at 800xg for 5 minutes (Schalm et al., 1975). Subsequently, the PCV value was obtained using a Hematocrit Reader Card (SPIN™, São Paulo, Brazil). Blood smears were stained by the *Romanowsky* method (Panótico Rápido Laborclin® Produtos para Laboratórios Ltda, Santa Bárbara, Minas Gerais, Brazil). Rickettsemia was determined by observing 40 homogeneous fields in a binocular microscope (Nikon Instruments® Inc., New York, USA), at a 100-fold increase, to determine the percentage of hematocrit cells infected with *A. marginale* (IICA, 1987).

The PCV and rickettsemia values were used to monitor anaplasmosis progression. The average of PCV values performed once a week before inoculation were used to calculate the

reference value for a healthy animal. After *A. marginale* inoculation, PCV procedures continued to be performed once a week, but after the first identification of parasitized erythrocyte by *A. marginale* in a blood smear, PCV and blood smears were performed every 48 hours. Sequentially, as PCV decreased further, both procedures were performed every 24 hours to establish the exact time to begin treatment. When PCV reached 50% of the healthy value, the animal was intramuscularly administered a single dose of 7.5 mg/kg of BW enrofloxacin (Kinetomax®, Bayer, Ribeirão Pires – SP, Brazil) according to Facury-Filho et al. (2012).

3. Data processing and analysis

The animals were considered sick when PCV value dropped and achieved 50% or less of average (n=23) healthy value ($32 \pm 1.49\%$), and the presence of anaplasma was confirmed in the blood smears. The animals were classified as healthy when they had no parasitized red blood cells and the PCR/RIFI test was negative for anaplasmosis. To standardize the days relative to sickness, day zero (d0) was considered the day that the minimum PCV value was reached. The time from inoculation to clinical disease (d0) averaged 35 ± 3 d.

Rumination (min/2h) and activity (index ranging from 0 to 255 bits/2h) data were generated through 3-axis accelerometers and collected directly from the SCR® software (Rodrigues et al., 2019), using the Hr-Tag recording standards of 2h periods for activity and rumination data. Activity measurement was based on the signal analysis of the head movements (proportional to the number, intensity, and direction of the neck movements) expressed by an index ranging from 0 to 255 bits for a 2-h interval (Van Hertem et al., 2014).

Data from two time-series of 5, 7, 10 or 12 days were collected from each animal. The first consisted of data from 5, 7, 10 or 12 days prior to sickness (d0), which was considered the

sick pattern. The other comprised a sequence of consecutive 5, 7, 10 or 12 days randomly selected in a time window from -50 to -15d prior to d0, which was considered the healthy pattern. All calves included in the dataset had both time series (healthy and sick).

An RNN called Long Short-Term Memory (LSTM) was used as a predictive approach to detect sick events (50% of healthy PCV value) at day 0, and 1, 3, and 5 days in advance. LSTM was adopted due to its capacity of extracting patterns and learning temporal dependences of longitudinal data in sequence prediction problems (Hochreiter and Schmidhuber, 1997) Data analysis was implemented in Python 3.6 using the computational resources provided by UW-Madison Center for High Throughput Computing (CHTC).

A random search was performed to find the best combination of hyperparameters. The random grid search was based on a single LSTM layer with 20, 40, 80, 100, or 200 neurons, then as activation function, dropout ranging from 0.001–0.01, and recurrent dropout varying from 0–0.05. All models tested used a batch size of 6, 50 epochs, a binary cross-entropy loss function, and *rmsprop* optimizer.

Model validation was performed using LOAOCV. In each iteration, a pair of samples from each calf was deleted (healthy and sick) and used for test, and the remaining dataset was used to train and tune the model. This approach was repeated n times (n = number of calves) until all calves were excluded once from the training set. For each LOAOCV iteration, hyperparameter tuning was performed using the remaining dataset ($n - 2$), and the grid search was performed to define the best combination of hyperparameters through a second LOAOCV (nested in each iteration), and these combinations were ranked based on accuracy (Supplemental Figure S1). The best combination of hyperparameters was defined as the combination with the greatest frequency after all iterations. This combination was then adopted as the final architecture and used to reanalyze specific iterations. Such tuning approach was

used to avoid overfitting, which frequently occurs when machine learning algorithms are applied to small datasets, and particularly when hyperparameters are chosen using the same dataset as that used for model assessment.

To evaluate performance of the models, ACC, SEN, SPE, positive predicted value (PPV), and negative predicted value (NPV) were calculated using the following equations: Accuracy = $(TP + TN)/(TP + TN + FP + FN)$, SEN = $TP/(TP + FN)$, SPE = $TN/(TN + FP)$, PPV = $TP/(TP + FP)$ where TP, FP, FN, and TN are true positive, false positive, false negative and true negative, respectively. A description of the strategy used for hyperparameter search and model training and testing is presented in Figure 1.

RESULTS

Alterations in PCV, rickettsemia, and rectal temperature due to exposure to *A. marginale* can be observed in Figure 2. The PCV value on d0 was $14 \pm 1.8\%$, which means 40% of the normal PCV value between -40 and -16 days ($32 \pm 1.49\%$). The mean rickettsemia value on d0 was $6.12 \pm 3.07\%$. Regarding rectal temperature, values in the normal physiological range (below $39.5\text{ }^{\circ}\text{C}$) were observed three days before (-3d) d0. Rectal temperature was greater than $39.5\text{ }^{\circ}\text{C}$ from -3d to 0d and reached an average value of $40.9 \pm 0.5\text{ }^{\circ}\text{C}$ on d0.

Daily RUM and ACT patterns are described in Figure 4. There was a reduction of RUM from -4d until d0. Rumination time decreased 34% from $566 \pm 78\text{ min/d}$ (between -20d to -15d) to $372 \pm 140\text{ min/day}$ (between -1d to 0d) from healthy and sickness time. Activity index was on average 453 ± 65 (-20 to -15d) and 405 ± 59 (-1 to 0d) and decreased about 11%, respectively. The architectures of LSTM algorithms with best performance for each time series length (5, 7, 10, and 12d), and each day relative to anaplasmosis (0, -1, -3, and -5d), are shown in Tables 1, 2 and 3, respectively. The performance of the remaining tested architectures (total of 345) is

shown in supplementary tables. The ACC of LSTM algorithms for the detection of anaplasmosis ranged from 87–98% when using RUM data (Table 1). The ACC values were 95, 97, 88 and 90% for 0, -1, -3, and -5d, decreasing 5% when the prediction time changed from 0 to -5d. The SEN and SPE decreased 8% and 2% comparing 0 to -5d in early predictions, respectively (Table 1). Changes in time series length did not substantially affect the ACC values of the predictive models (93, 93, 92, and 93% for of 5, 7, 10, and 12d, respectively).

The ACC of predictive models for the detection of anaplasmosis ranged from 70 to 98% using ACT data (Table 2). ACC values were 95, 92, 87, and 80% for 0, -1, -3 and -5d time series length, respectively (Table 2). Regardless of time series length, ACC values were 92, 92, 87, and 85% for 5, 7, 10 and 12d, respectively, decreasing 8% comparing the time series of 5d and 12d.

The ACC of predictive models for the detection of anaplasmosis based both on RUM and ACT data ranged from 85 to 98%. The ACC (95, 97, 89 and 89% for 0, -1, -3 and -5 days before d0) decreased 7% when the prediction was done -5d in advance compared to 0d (Table 3). The length of time series had little influence on ACC values: 92, 92, 93, and 94% for the time series of 5, 7, 10, and 12 days, respectively.

DISCUSSION

The current study was designed to assess the feasibility of using a commercial system (SCR Heatime Hr®) for early detection of anaplasmosis in dairy calves based on challenge model with a low virulence inoculum of *A. marginale* UFMG1-EU676176. Using clinical reference assessments and artificial intelligence, we found that rumination and activity data collected every 2 hours can be used for the early detection of anaplasmosis in calves up to 5 days in advance of clinical signs.

Healthy status, rumination, and activity during the study

The peak of anemia occurs 2 days after the peak in rickettsemia, 1 day after rectal temperature peak, and is concurrent with clinical symptoms. The interrelationship between PCV, rectal temperature, and rickettsemia found in the current study agrees with Coelho (2007) and Oliveira Júnior et al. (2018). The decrease in PCV values is related to the virulence of the *A. marginale* -UFMG1 sample used, which is considered low (Coelho, 2007; Bastos et al., 2010; Silvestre et al., 2016), yet capable of triggering the disease in young calves. These authors, also working with *A. marginale*, found a lower (13.0 and 13.4%, respectively) average PCV value compared to our study (14%). The standard values of PCV normally vary 24 to 46% in cattle (Radostits et al., 2007). In our study, the peak of rickettsemia preceded the peak of lower PCV, which is corroborated by Coelho (2007) and Bastos et al. (2009).

The pyrexia released systemic inflammatory mediators, which can induce behavioral changes (Pecchi et al., 2009; Oliveira Júnior et al., 2018). In the current study, rectal temperature and rickettsemia increased gradually together, as described by Kocan et al. (2003) and Coelho (2007), which reported a positive correlation between rectal temperature and rickettsemia. Thus, the pathogeny and calves' physiological responses seem to be representative of ordinary anaplasmosis cases.

To the best of our knowledge, our study is the first that measures rumination and activity through wearable sensors in Holstein calves challenged with anaplasmosis. The lower RUM and ACT associated with higher rectal temperature, rickettsemia, and decreased PCV on days -1 and 0 relative to sickness can be explained by the effects of anaplasmosis on immune response. Red blood cells parasitized by *A. marginale* induce a humoral immune response that causes antibodies to adhere to infected and uninfected cells. Consequently, these cells are quickly removed by the monocytic phagocytic system, resulting in anemia (Oliveira Júnior et

al., 2018). In addition, changes such as weakness and lethargy can accompany severe anemia, which can mimic respiratory problems, since the animal must breathe faster and more deeply to compensate for the failure in blood oxygenation (Bastos et al., 2009; Silvestre et al., 2016). The increase in infected red blood cells also enhances the immune response, releasing inflammatory mediators that cause fever and lethargy (Coelho 2007).

Rumination, activity, or both as predictors

The reduction of RUM may be associated with reduced intake, which is often an early sign of illness (Johnson, 2002). Previous studies evaluating inoculation of *A. marginale* observed reduction in feed intake and ruminal movements in calves (Andrade et al., 2001; Meneses, 2013). Additionally, altered eating behavior may be a result of fever, which is known to be associated with reduced motivation to eat and drink (Hart, 1988; Feitosa, 2008). Thus, anorexia and fever are common clinical signs of acute anaplasmosis (Rodríguez et al., 2000). Calves affected with tick-borne disease have reduced feed intake, frequency and time spent in feed bins of about 35, 27 and 24% before the clinical symptoms of fever, anemia and parasitemia (Oliveira Junior et al., 2018).

In the present study, the RUM returned to normal values 2 days after d0, probably due to early antimicrobial treatment provided when the PCV reached 50% of the healthy value. Rumination time remained low during the days after anaplasmosis treatment, probably due to the time needed to restore the PCV, acid-base balance, and hydration (Meneses, 2013). Contrastingly, in practical or on-farm conditions, diagnosis of anaplasmosis is usually performed when the disease has already reached an advanced stage, basically by inspecting the animals. Behavioral changes are visible to farm staff when anemia is already more severe and, often, with a PCV well below 50% of the normal value. Therefore, on many dairy farms, the

adverse effects of anaplasmosis on rumination, activity and PCV and rickettsemia may be greater than the values reported in this study.

The RUM data obtained from Hr-Tag sensors were important predictors of anaplasmosis disease in the current study. Based on previous literature, predicted rumination time for heifers and calves may not be highly accurate when compared to human observation (Burfeind et al., 2011; Goldhawk et al., 2013; Lopreiato et al., 2018; Rodrigues et al., 2019). However, our results demonstrate that accuracy bias does not restrict its applicability for detection of diseases.

Visually, anaplasmosis had a more subtle effect on ACT than did on RUM (Figures 3 and 4), but predictive models based on both RUM and ACT data had high predictive quality to detect anaplasmosis. When combining RUM and ACT as predictors, no improvements were observed on models' performance (Table 3). The ACC average for models based on combined RUM and ACT was similar to that of ACT or RUM separately. Therefore, it is possible to use models based only on RUM or ACT, which is interesting since a vast majority of commercial sensors do not have RUM functionality (Stygar et al., 2021). It is important to highlight that accelerometers are becoming less expensive and can be used to develop new commercial devices for early detection of specific diseases like anaplasmosis.

Time series length effects on model's predictive quality

There was no benefit to using a longer time series for anaplasmosis detection. When comparing the 5- and 7-days' time series, ACC, SEN and SPE values were greater compared with time series at 10 and 12 days. Thus, time series between 5 and 7 days seem to be suitable for anaplasmosis detection. Similar results were observed for detecting estrus in dairy cows based on feeding behavior data, with equivalent performance for models using time series of -

24 and -172 hours relative to estrus (Cairo et al., 2020). The use of short time series can reduce the demand for computational resources in future development and deployments.

Perspectives of early detection of anaplasmosis

The differences involving clinical signs, rumination behavior, and activity index observed in this study are consistent with behavioral responses such as depression and lethargy that are part of animals' physiological response to *A. marginale* rickettsemia (Hart, 1988). Thus, the reduced behavioral activity observed between -5 to 0d compared to healthy periods, may be the result of fever, which is associated with the proliferation of parasitized cells and inflammation mediators (Meneses, 2013; Bastos et al., 2009; Bastos et al., 2010).

The use of models that included 0d in time series from sick animals was useful in detecting clinical disease and can be a safe threshold for prescribing treatment, as well as the fact that the health status of all animals in the current study was recovered after treatment with enrofloxacin. However, the great predictive performance of models to detect anaplasmosis 1 and 3 days in advance of clinical signs may allow the diagnosis of anaplasmosis disease at earlier stages of its development (when PCV values range between 50 to 70% of healthy time). This presents a great opportunity for early prescriptive treatments, including those that reduce disease morbidity and mortality. Additionally, after treatment with enrofloxacin, anemia is not eliminated quickly due the slow reduction in rickettsemia (Facury-Filho et al., 2012). Thus, early diagnosis and treatment may promote faster animal recovery. Treatment in the early stages can eliminate the need for supplementary treatment with support medications such as blood transfusions and fluid therapy, which are expensive and laborious. The ACC of models to predict anaplasmosis 5 days in advance was reduced; however, it remained greater than 70%, which may suggest the possibility of the usefulness of tracking of anaplasmosis disease based

on ACT data. Early detection of the anaplasmosis event based on ACT data (-1, -3 and -5 days) reduced the model's accuracy by 2, 8 and 15%, respectively, compared to predictions including 0d.

The satisfactory performance of -5d prediction models can be explained by the ability of machine learning algorithms to grasp complex relationships between input and output information, capturing non-linear relationships (Srivastava et al., 2014), and temporal dependencies with longitudinal data (Hochreiter and Schmidhuber, 1997). Contrastingly, Belaid et al. (2020) used a multivariate logistic regression model based on activity-monitoring device data to predict sickness in veal calves, and reported ACC, SEN, and SPE of 62%, 63%, and 61%, respectively, with -3d in advance.

The ACC values for 1 and 3 days in advance were similar compared to the 0d predictions for all time series based on RUM data. Therefore, -1 and -3d predictions based only on RUM can be used for early treatment prescription. The -5d predictions based on RUM had SEN and SPE of 88% and 92%, respectively, which demonstrate the high potential of machine learning models to recognize the onset of disease, when the PCV represents 80% of normal healthy value. Therefore, the early prescription of treatment can be based both using RUM or ACT and may improve the efficiency of treatment and reduce calves' morbidity and mortality caused by anaplasmosis.

Implications

The impressive performance of machine learning models in predicting anaplasmosis using RUM and ACT data from Hr-tag sensors observed in this study pointed out the possibility for use of such device as an auxiliary tool for precision tick fever therapy (Souza et al., 2021), avoiding the indiscriminate use of antimicrobials and development of antimicrobial resistance

(Aslam et al., 2018; Haley et al., 2020; Lei et al., 2020). At the same time, this approach can improve prognosis due to early detection and can result in better animal welfare (Relić et al., 2020). In addition, the proposed approach can reduce the amount of labor spent on the diagnostic procedures and secondary support treatment (e.g., transfusion and fluid therapy).

Our results were obtained in a fully controlled experiment, where only anaplasmosis affected the evaluated variables. Under farm conditions, there are several distinct pathogens that can cause health problems. Therefore, future studies under farm conditions including a larger number of animals should be performed to check the viability of using commercial devices to identify specific diseases like anaplasmosis as well as the performance of the developed algorithms.

CONCLUSIONS

The presence anaplasmosis changed the daily pattern and reduced rumination time and activity index. Our results suggest that monitoring both rumination time and activity index may be useful for early detection of anaplasmosis in calves. The use of RUM and ACT combined did not improve the capacity of the models to detect anaplasmosis. There was no benefit to using time series longer than 7 days to detect anaplasmosis. The predictive performance of machine learning models including data from the day of disease is greater compared with early detection. However, the anaplasmosis diagnosis prediction up to 5 days before the disease provided satisfactory results and can be useful for early treatment prescription, improving the prognosis and the recovery of animals exposed to anaplasmosis.

ACKNOWLEDGMENTS

The authors declare they have no conflicts of interest. The authors would like to thank the Brazilian Federal Agency for the Support and Evaluation of Graduate Education (CAPES), the National Council for Scientific and Technological Development (CNPq), the Minas Gerais Research Foundation (FAPEMIG), and the Brazilian Agricultural Research Corporation (Embrapa) for financing this study. The mention of commercial names or commercial products in this article is for the sole purpose of providing specific information and does not imply recommendation or endorsement by the authors or their institutions. Specially, we would like to thank John Furlong for all his technical and spiritual support. He is a consummate professional who who dedicated his life to developing science solutions for livestock parasite control. It was a great honor to have you on our team in your last research activity before Embrapa retirement.

REFERENCES

- Alsaod, M., M. Fadul, and A. Steiner. 2019. Automatic lameness detection in cattle. *Vet. J.* 246: 35-44. doi:10.1016/j.tvjl.2019.01.005.
- Andrade, G.M. De, O. Vidotto, M.C. Vidotto, E. Yoshihara, F.S. Kano, and C.H.S. Amaral. 2001. Seroprevalence for *Anaplasma marginale* in dairy cattle and, studies on the dynamics of natural infection of Holstein calves in Southern Brazil. *Semin. Ciências Agrárias*.
- Araújo, F.R., V.S.P. Melo, C.A.N. Ramos, C.R. Madruga, C.O. Soares, R.H. Kessler, N.F. Almeida, G.S. Araújo, L.C. Alves, R.A.A. Torres, S.P. Fragoso, P.R.C. Arauco, G. Bacanelli, M.B. Oliveira, and L.R. Santos. 2005. Development of enzyme-linked immunosorbent assays based on recombinant MSP1a and MSP2 of *Anaplasma*

- marginale*. Mem. Inst. Oswaldo Cruz. 100: 765-769 doi:10.1590/S0074-02762005000700016.
- Aslam, B., W. Wang, M.I. Arshad, M. Khurshid, S. Muzammil, M.H. Rasool, M.A. Nisar, R.F. Alvi, M.A. Aslam, M.U. Qamar, M.K.F. Salamat, and Z. Baloch. 2018. Antibiotic resistance: a rundown of a global crisis. Infect. Drug Resist. 11: 1645 doi:10.2147/IDR.S173867.
- Aubry, P., and D.W. Geale. 2011. A review of Bovine anaplasmosis. Transbound. Emerg. Dis. 58:1-30. doi:10.1111/j.1865-1682.2010.01173.x.
- Bastos, C. V., L.M.F. Passos, E.J. Facury-Filho, E.M. Rabelo, J. de la Fuente, and M.F.B. Ribeiro. 2010. Protection in the absence of exclusion between two Brazilian isolates of *Anaplasma marginale* in experimentally infected calves. Vet. J. 186: 374-378. doi:10.1016/j.tvjl.2009.09.013.
- Bastos, C. V., L.M.F. Passos, M.M.C. Vasconcelos, and M.F.B. Ribeiro. 2009. In vitro establishment and propagation of a Brazilian strain of *Anaplasma marginale* with appendage in IDE8 (*Ixodes scapularis*) cells. Brazilian J. Microbiol. 40: 399-403. doi:10.1590/s1517-83822009000200034.
- Belaid, M.A., M. Rodríguez-Prado, D. V. Rodríguez-Prado, E. Chevaux, and S. Calsamiglia. 2020. Using behavior as an early predictor of sickness in veal calves. J. Dairy Sci. 103: 1874-1883. doi:10.3168/jds.2019-16887.
- Burfeind, O., K. Schirmann, M.A.G. von Keyserlingk, D.M. Veira, D.M. Weary, and W. Heuwieser. 2011. Technical note: Evaluation of a system for monitoring rumination in heifers and calves. J. Dairy Sci. 94:426-430. doi:10.3168/jds.2010-3239.
- Cairo, F.C., L.G.R. Pereira, M.M. Campos, T.R. Tomich, S.G. Coelho, C.F.A. Lage, A.P. Fonseca, A.M. Borges, B.R.C. Alves, and J.R.R. Dorea. 2020. Applying machine

- learning techniques on feeding behavior data for early estrus detection in dairy heifers. *Comput. Electron. Agric.* 179:105855. doi:10.1016/j.compag.2020.105855.
- Coelho, L.C.T. 2007. Anaplasmosse bovina: parâmetros clínicos e de patologia clínica em bezerros infectados experimentalmente.: parâmetros clínicos e de patologia clínica em bezerros infectados experimentalmente. Universidade Federal de Minas Gerais.
- Drummond, R.O., S.E. Ernst, J.L. Trevino, W.J. Gladney, and O.H. Graham. 1973. *Boophilus annulatus* and *B. microplus*: laboratory tests of insecticides.. *J. Econ. Entomol.* 66:130-133. doi:10.1093/jee/66.1.130.
- Facury-Filho, E.J., A.Ú. de Carvalho, P.M. Ferreira, M.F. Moura, B.C. Apolinário, L. de P.H. Santos, and M.F.B. Ribeiro. 2012. Effectiveness of enrofloxacin for the treatment of experimentally-induced bovine anaplasmosis. *Rev. Bras. Parasitol. Vet.* doi:10.1590/s1984-29612012000100007.
- Feitosa, F.L.F. 2008. Exame físico geral ou de rotina. *Semiologia Veterinária A arte do diagnóstico.*
- Goff, J.P., A. Hohman, and L.L. Timms. 2020. Effect of subclinical and clinical hypocalcemia and dietary cation-anion difference on rumination activity in periparturient dairy cows. *J. Dairy Sci.* 103:2591-2601. doi:10.3168/jds.2019-17581.
- Goldhawk, C., K. Schwartzkopf-Genswein, and K.A. Beauchemin. 2013. Technical note: Validation of rumination collars for beef cattle. *J. Anim. Sci.* 91:2858–2862. doi:10.2527/jas.2012-5908.
- Haley, B.J., S.W. Kim, S. Salaheen, E. Hovingh, and J.A.S. Van Kessel. 2020. Differences in the Microbial Community and Resistome Structures of Feces from Preweaned Calves and Lactating Dairy Cows in Commercial Dairy Herds. *Foodborne Pathog. Dis.* 17:494-503. doi:10.1089/fpd.2019.2768.

- Hart, B.L. 1988. Biological basis of the behavior of sick animals. *Neurosci. Biobehav. Rev.* 12:123–137. doi:10.1016/S0149-7634(88)80004-6.
- Hixson, C.L., P.D. Krawczel, J.M. Caldwell, and E.K. Miller-Cushon. 2018. Behavioral changes in group-housed dairy calves infected with *Mannheimia haemolytica*. *J. Dairy Sci.* 101:10351-10360. doi:10.3168/jds.2018-14832.
- Hochreiter, S., and J. Schmidhuber. 1997. Long Short-Term Memory. *Neural Comput.* 9:1735–1780. doi:10.1162/neco.1997.9.8.1735.
- IICA. 1987. Técnicas para el diagnóstico de babesiosis y anaplasmosis bovina. San José.
- Jaeger, M., K. Brügemann, H. Brandt, and S. König. 2019. Associations between precision sensor data with productivity, health and welfare indicator traits in native black and white dual-purpose cattle under grazing conditions. *Appl. Anim. Behav. Sci.* 212:9-18. doi:10.1016/j.applanim.2019.01.008.
- Johnson, R.W. 2002. The concept of sickness behavior: A brief chronological account of four key discoveries. Pages 443–450 in *Veterinary Immunology and Immunopathology*.
- Kocan, K.M., J. de la Fuente, E.F. Blouin, J.F. Coetzee, and S.A. Ewing. 2010. The natural history of *Anaplasma marginale*. *Vet. Parasitol.* 167:95–107. doi:10.1016/j.vetpar.2009.09.012.
- Kocan, K.M., J. De La Fuente, A.A. Guglielmone, and R.D. Meléndez. 2003. Antigens and Alternatives for Control of *Anaplasma marginale* Infection in Cattle. *Clin. Microbiol. Rev.* 16:698–712. doi:10.1128/CMR.16.4.698-712.2003.
- Larson, L.L., F.G. Owen, J.L. Albright, R.D. Appleman, R.C. Lamb, and L.D. Muller. 1977. Guidelines Toward More Uniformity in Measuring and Reporting Calf Experimental Data. *J. Dairy Sci.* 60:989-991. doi:10.3168/jds.S0022-0302(77)83975-1.
- Lei, Y., B. Yang, X. Jiang, F. Jia, N. Li, and A.K. Nandi. 2020. Applications of machine

- learning to machine fault diagnosis: A review and roadmap. *Mech. Syst. Signal Process.* 138:106587. doi:10.1016/j.ymssp.2019.106587.
- Lombard, J., N. Urie, F. Garry, S. Godden, J. Quigley, T. Earleywine, S. McGuirk, D. Moore, M. Branan, M. Chamorro, G. Smith, C. Shivley, D. Catherman, D. Haines, A.J. Heinrichs, R. James, J. Maas, and K. Sterner. 2020. Consensus recommendations on calf- and herd-level passive immunity in dairy calves in the United States. *J. Dairy Sci.* 103:7611-7624. doi:10.3168/jds.2019-17955.
- Lopreiato, V., A. Minuti, F. Piccioli-Cappelli, M. Vailati-Riboni, D. Britti, E. Trevisi, and V.M. Morittu. 2018. Daily rumination pattern recorded by an automatic rumination-monitoring system in pre-weaned calves fed whole bulk milk and ad libitum calf starter. *Livest. Sci.* 212:127-130. doi:10.1016/j.livsci.2018.04.010.
- Mcguirk, S.M. 2003. Solving calf morbidity and mortality problems. *Am. Assoc. Bov. Pract.*
- McGuirk, S.M. 2008. Disease Management of Dairy Calves and Heifers. *Vet. Clin. North Am. - Food Anim. Pract.* 24:139-153. doi:10.1016/j.cvfa.2007.10.003.
- Meneses, R. M. Isolamento e caracterização molecular de *Anaplasma marginale* de origem congênita e avaliação da virulência em bezerros experimentalmente infectados. 2013. 76f. Dissertação (Mestrado em Ciência Animal) – Escola de Veterinária, Universidade Federal de Minas Gerais, Belo Horizonte, 2013.
- Molad, T., M.L. Mazuz, L. Fleiderovitz, L. Fish, I. Savitsky, Y. Krigel, B. Leibovitz, J. Molloy, F. Jongejan, and V. Shkap. 2006. Molecular and serological detection of *A. centrale*- and *A. marginale*-infected cattle grazing within an endemic area. *Vet. Microbiol.* 113:1-2. doi:10.1016/j.vetmic.2005.10.026.
- OIE. 2019. Introduction To the Recommendations for Animal Welfare. *Terr. Anim. Heal. Code.*

- Oliveira Júnior, B.R., B.F. Silper, M.N. Ribas, F.S. Machado, J.A.M. Lima, L.F.L. Cavalcanti, and S.G. Coelho. 2018. Short communication: Tick-borne disease is associated with changes in feeding behavior in automatically fed weaned dairy calves. *J. Dairy Sci.* 101:11256–11261. doi:10.3168/jds.2018-14637.
- Pecchi, E., M. Dallaporta, A. Jean, S. Thirion, and J.D. Troadec. 2009. Prostaglandins and sickness behavior: Old story, new insights. *Physiol. Behav.* 97:279–292. doi:10.1016/j.physbeh.2009.02.040.
- Radostits, O., C. Gay, C. Gay, K. Hinchcliff, and P. Constable. 2007. *A Textbook of the Diseases of Cattle, Horses, Sheep, Pigs and Goats: veterinary medicine.* Vet. Med.
- Reiter, S., G. Sattlecker, L. Lidauer, F. Kickinger, M. Öhlschuster, W. Auer, V. Schweinzer, D. Klein-Jöbstl, M. Drillich, and M. Iwersen. 2018. Evaluation of an ear-tag-based accelerometer for monitoring rumination in dairy cows. *J. Dairy Sci.* 101:3398–3411. doi:10.3168/jds.2017-12686.
- Relić, R., J. Starič, and J. Ježek. 2020. Management practices that influence the welfare of calves on small family farms. *J. Dairy Res.* 87:93-98. doi:10.1017/S0022029920000539.
- Rodrigues, J.P.P., L.G.R. Pereira, H. do C. Diniz Neto, M.C. Lombardi, C.F. de A. Lage, S.G. Coelho, J.P. Sacramento, F.S. Machado, T.R. Tomich, R.M. Maurício, and M.M. Campos. 2019. Technical note: Evaluation of an automatic system for monitoring rumination time in weaning calves. *Livest. Sci.* doi:10.1016/j.livsci.2018.11.017.
- Rodríguez, S.D., M.A. García Ortiz, G. Hernández Salgado, N.A. Santos Cerda, R. Aboytes Torres, and G.J. Cantó Alarcón. 2000. *Anaplasma marginale* inactivated vaccine: Dose titration against a homologous challenge. *Comp. Immunol. Microbiol. Infect. Dis.* 23:239-252. doi:10.1016/S0147-9571(99)00076-4.
- Santos, G.B., I.M.M. Gomes, J.A.G. Silveira, L.C.S.R. Pires, S.S. Azevedo, A.C. Antonelli,

- M.F.B. Ribeiro, and M.C. Horta. 2017. Tristeza parasitária em bovinos do semiárido pernambucano. *Pesqui. Vet. Bras.* 37:1-7. doi:10.1590/S0100-736X2017000100001.
- Schalm, O.W., N.C. Jain, and E.J. Carroll. 1975. Veterinary hematology.. *Vet. Hematol.*
- Silveira, J.A.G. da, É.M.L. Rabelo, P.C.S. Lima, B.N. Chaves, and M.F.B. Ribeiro. 2014. Post-mortem hemoparasite detection in free-living Brazilian brown brocket deer (*Mazama gouazoubira*, Fischer 1814). *Rev. Bras. Parasitol. Veterinária.* 23:206-215. doi:10.1590/s1984-29612014035.
- Silvestre, B.T., J.A.G. Silveira, R.M. Meneses, E.J. Facury-Filho, A.U. Carvalho, and M.F.B. Ribeiro. 2016. Identification of a vertically transmitted strain from *Anaplasma marginale* (UFMG3): Molecular and phylogenetic characterization, and evaluation of virulence. *Ticks Tick. Borne. Dis.* 7:80–84. doi:10.1016/j.ttbdis.2015.09.001.
- Souza, J.C.P. de, C.O. Soares, C.R. Madruga, and C.L. Massard. 2001. PREVALÊNCIA DE ANTICORPOS ANTI *Anaplasma marginale* (RICKETTSIALES: ANAPLASMATACEAE) EM BOVINOS NA MESORREGIÃO DO MÉDIO PARAÍBA. *Ciência Rural.* 31: 309-314. doi:10.1590/s0103-84782001000200019.
- Souza, R.S., M.F.S. Resende, L.C.A. Ferreira, R.S. Ferraz, M.V.V. Araújo, C. V. Bastos, J.A.G. Silveira, T.F. Moreira, R.M. Meneses, A.U. Carvalho, F.O.P. Leme, and E.J. Facury Filho. 2021. Monitoring bovine tick fever on a dairy farm: An economic proposal for rational use of medications. *J. Dairy Sci.* 104:5643-5651. doi:10.3168/jds.2020-19504.
- Srivastava, N., G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov. 2014. Dropout: A simple way to prevent neural networks from overfitting. *J. Mach. Learn. Res.* 15: 1929-1958.
- Sturm, V., D. Efrosinin, M. Öhlschuster, E. Gusterer, M. Drillich, and M. Iwersen. 2020.

- Combination of sensor data and health monitoring for early detection of subclinical Ketosis in dairy cows. *Sensors (Switzerland)* 20:1484. doi:10.3390/s20051484.
- Stygar, A.H., Y. Gómez, G. V. Berteselli, E. Dalla Costa, E. Canali, J.K. Niemi, P. Llonch, and M. Pastell. 2021. A Systematic Review on Commercially Available and Validated Sensor Technologies for Welfare Assessment of Dairy Cattle. *Front. Vet. Sci.* 8:177. doi:10.3389/fvets.2021.634338.
- Swartz, T.H., A.N. Findlay, and C.S. Petersson-Wolfe. 2017. Short communication: Automated detection of behavioral changes from respiratory disease in pre-weaned calves. *J. Dairy Sci.* 100: 9273-9278. doi:10.3168/jds.2016-12280.
- Timsit, E., S. Assié, R. Quiniou, H. Seegers, and N. Bareille. 2011. Early detection of bovine respiratory disease in young bulls using reticulo-rumen temperature boluses. *Vet. J.* 190: 136-142. doi:10.1016/j.tvjl.2010.09.012.
- Ueti, M.W., Y. Tan, S.L. Broschat, E.J.C. Ortiz, M. Camacho-Nuez, J.J. Mosqueda, G.A. Scoles, M. Grimes, K.A. Brayton, and G.H. Palmer. 2012. Expansion of variant diversity associated with a high prevalence of pathogen strain superinfection under conditions of natural transmission. *Infect. Immun.* 80: 2354-2360. doi:10.1128/IAI.00341-12.
- Van Hertem, T., Y. Parment, M. Steensels, E. Maltz, A. Antler, A.A. Schlageter-Tello, C. Lokhorst, C.E.B. Romanini, S. Viazzi, C. Bahr, D. Berckmans, and I. Halachmi. 2014. The effect of routine hoof trimming on locomotion score, ruminating time, activity, and milk yield of dairy cows. *J. Dairy Sci.* 97:4852-4863. doi:10.3168/jds.2013-7576.
- Vidotto, O., and E.R.M. Marana. 2001. DIAGNÓSTICO EM ANAPLASMÓSE BOVINA. *Ciência Rural.* 31: 361-368. doi:10.1590/s0103-84782001000200028.
- Visser, E.S., T.C. McGuire, G.H. Palmer, W.C. Davis, V. Shkap, E. Pipano, and D.P.

Knowles. 1992. The *Anaplasma marginale* msp5 gene encodes a 19-kilodalton protein conserved in all recognized *Anaplasma* species. *Infect. Immun.* 60: 5139-5144.

doi:10.1128/iai.60.12.5139-5144.1992.

Weiss, J.D., Wardrop, K.J. 2010. Schalm's Veterinary Hematology 6th Ed.

Zabel, T.A., and F.B. Agosto. 2018. Transmission Dynamics of Bovine Anaplasmosis in a Cattle Herd. *Interdiscip. Perspect. Infect. Dis.* 2018:1-17. doi:10.1155/2018/4373981.

Figure 1. Strategy used for hyperparameter search and model training and testing.

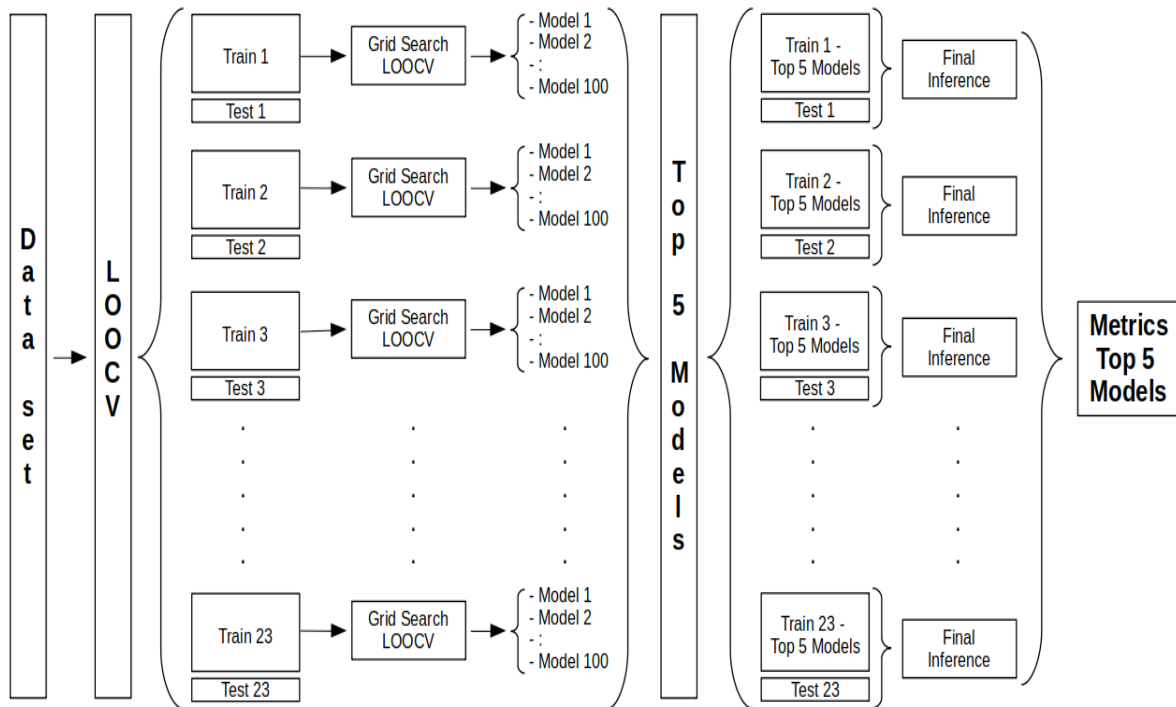


Figure 2. Effects of *Anaplasma marginale* inoculation on packed cell volume, rickettsemia and rectal temperature in dairy heifer calves according to days relative to sickness.

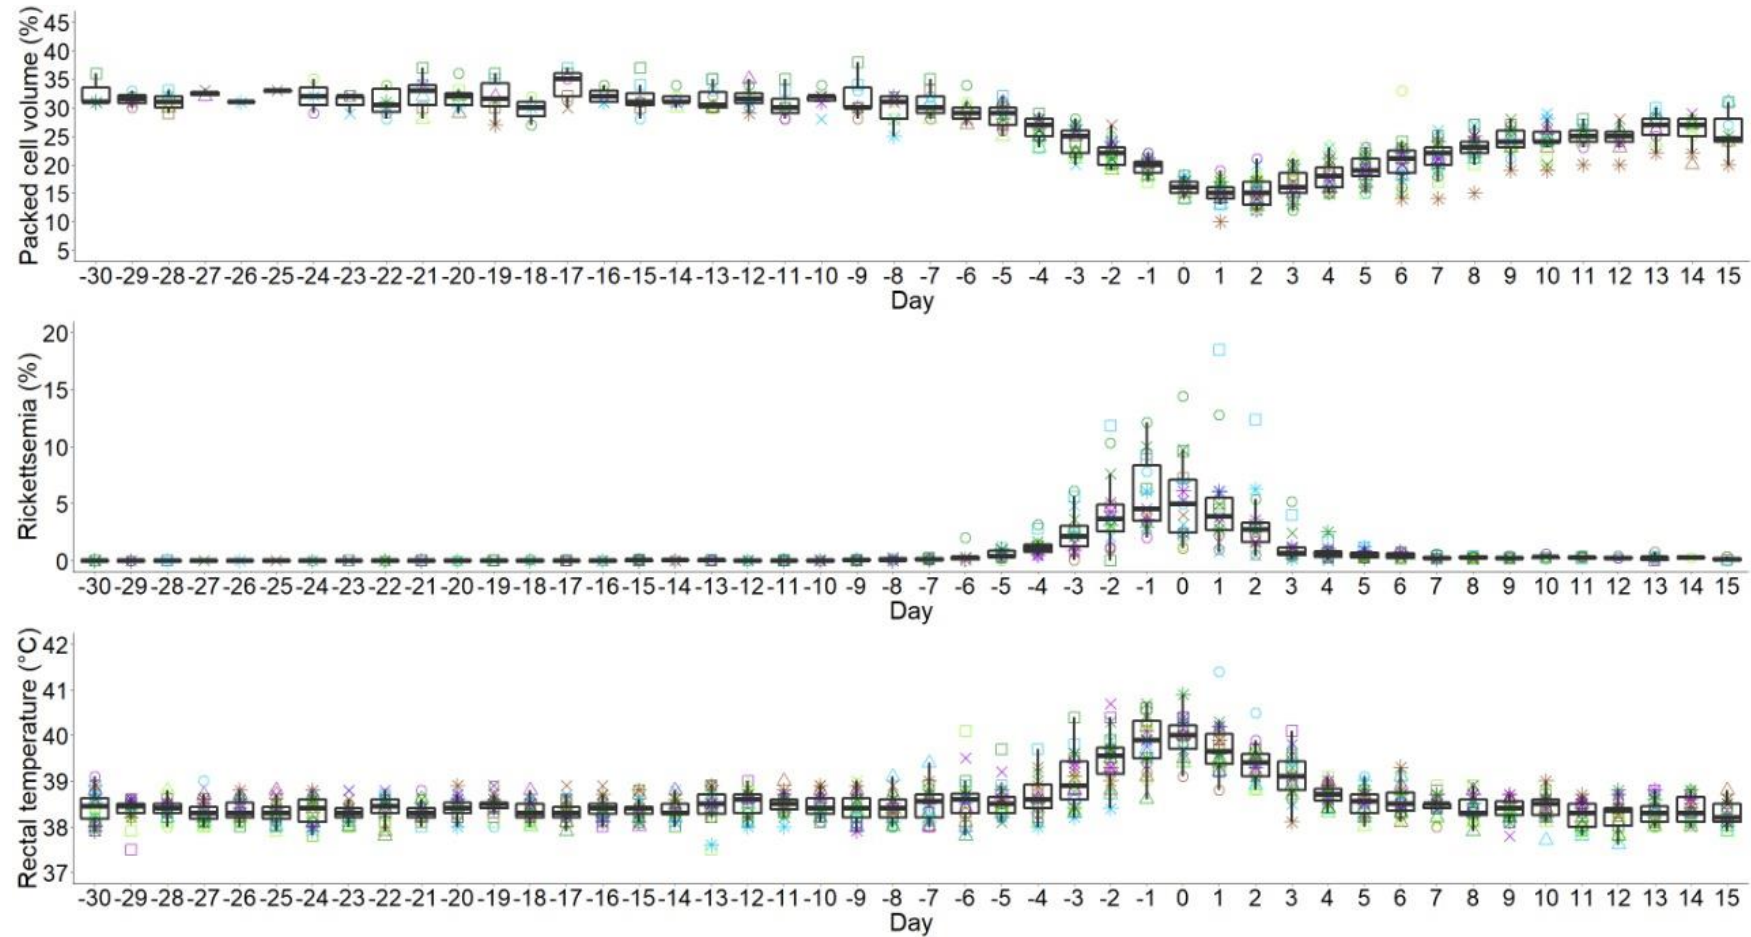


Figure 3. Effects of *Anaplasma marginale* inoculation on rumination time and activity index measured by SCR Heat time Hr® collars in dairy heifer calves according to days relative to sickness.

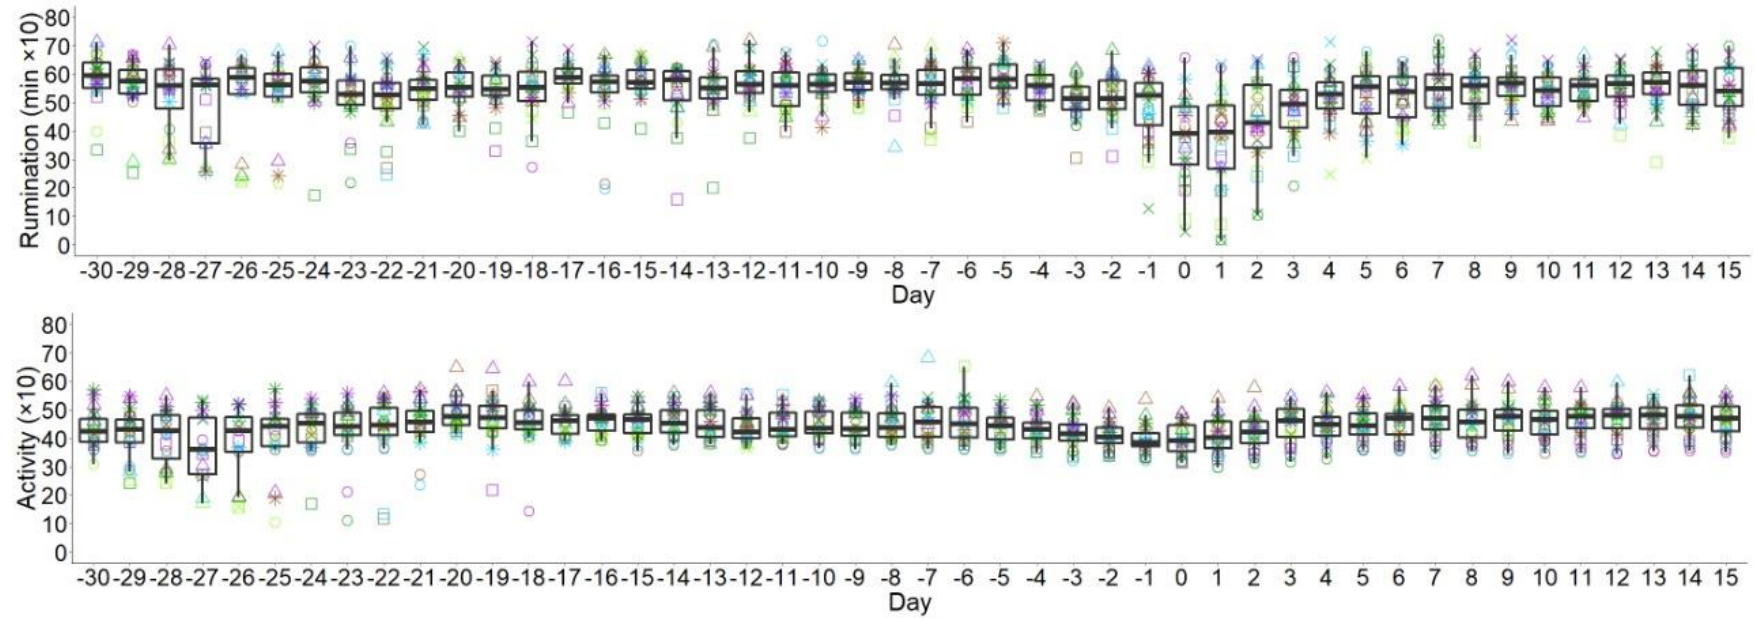


Figure 4. Rumination time and activity index measured by SCR Heat time Hr® collars in periods of 12 random days of healthy time (green) and 12 days before sickness (red) in dairy heifer calves.

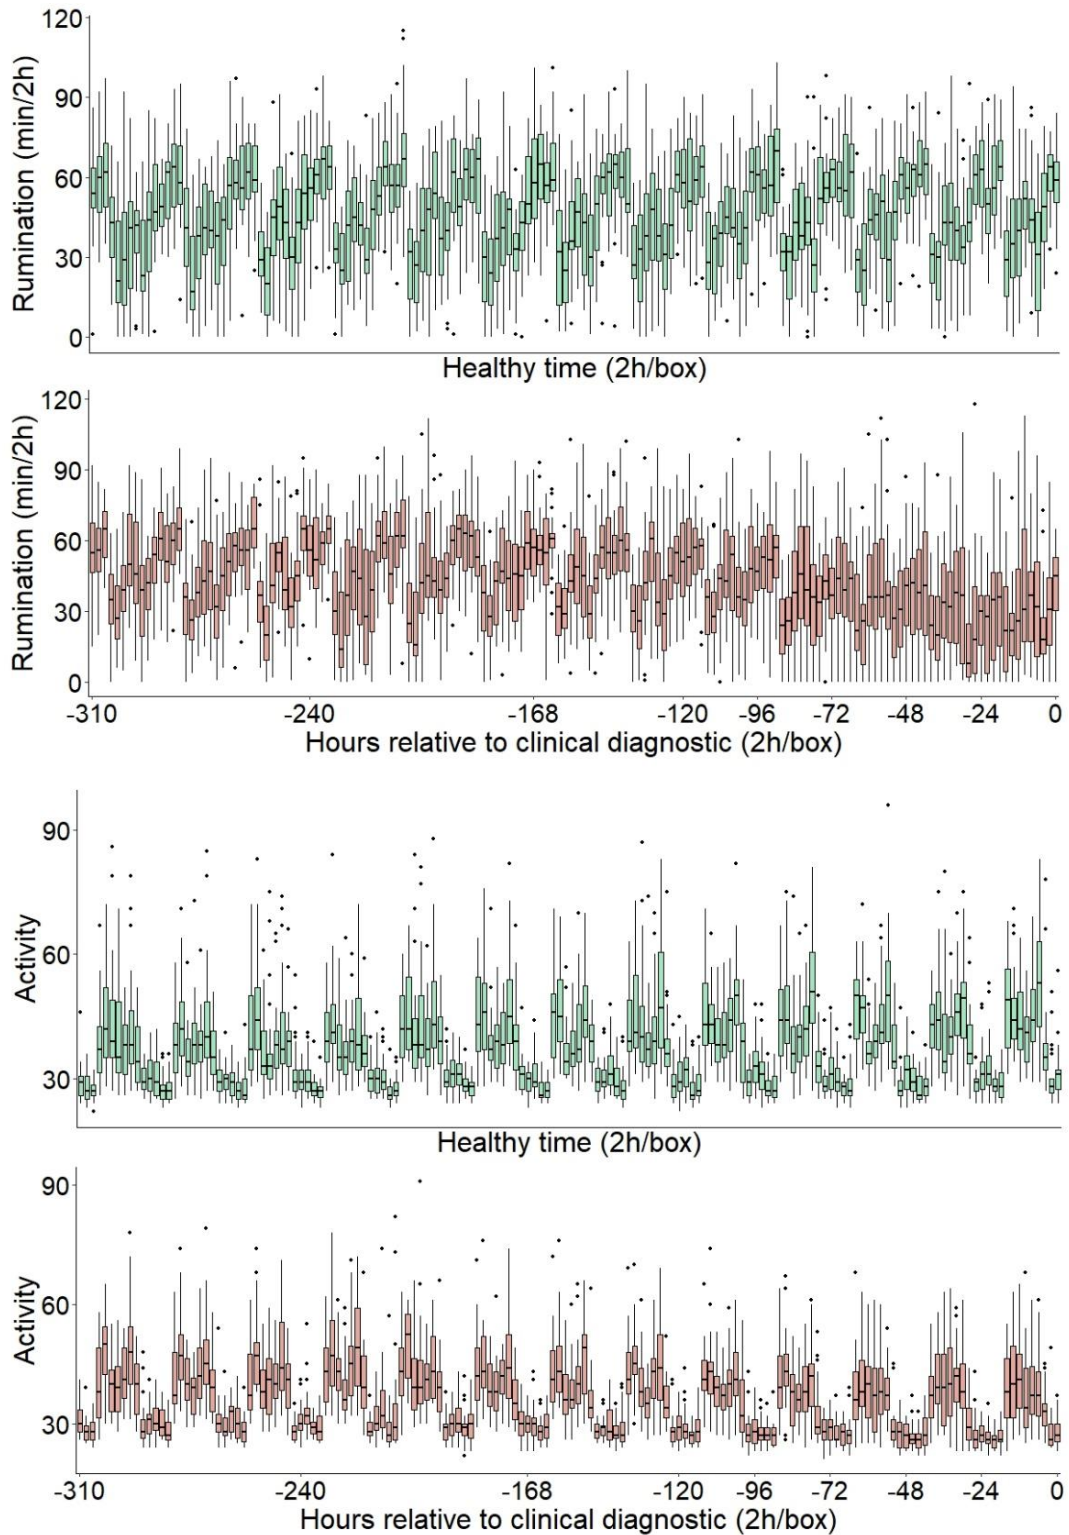


Table 1. Performance of different recurrent neural network models based on rumination time data to detect anaplasmosis using different time series length at different days relative to sickness (DRS) in dairy heifer calves.

Time series	Model description				Performance				
	DRS	Neurons	Dropout	Recurrent dropout	ACC	SEN	SPE	PPV	NPV
5 days	0	20	0.005	0.000	96	96	96	96	96
	-1	20	0.001	0.005	96	96	96	96	96
	-3	20	0.000	0.005	87	91	83	84	90
7 days	0	20	0.000	0.01	96	96	96	96	96
	-1	20	0.001	0.01	98	96	100	100	96
	-3	20	0.000	0.01	89	91	87	88	91
	-5	200	0.005	0.001	91	91	91	91	91
10 days	0	20	0.005	0.001	93	96	91	92	95
	-1	20	0.001	0.000	96	91	100	100	92
	-3	20	0.005	0.001	89	91	87	88	91
	-5	20	0.01	0.005	89	83	96	95	85
12 days	0	20	0.001	0.005	96	96	96	96	96
	-1	20	0.000	0.01	98	100	96	96	100
	-3	20	0.005	0.01	89	91	87	88	91
	-5	20	0.001	0.005	91	91	91	91	91

Accuracy (ACC), sensitivity (SEN), specificity (SPE), positive predicted value (PPV), and negative predicted value (NPV). All models used a Long Short-Term Memory layer, a batch size of 6, and 50 epochs. Data was collected using SCR Heat time Hr® collars.

Table 2. Performance of different recurrent neural network models based on activity index data to detect anaplasmosis using different time series length at different days relative to sickness (DRS) in dairy heifer calves.

Time series	Model description				Performance				
	DRS	Neurons	Dropout	Recurrent dropout	ACC	SEN	SPE	PPV	NPV
5 days	0	100	0.001	0.05	98	100	96	96	100
	-1	100	0.001	0.05	93	96	91	92	95
	-3	100	0	0.05	85	91	78	81	90
7 days	0	100	0	0.05	93	87	100	100	88
	-1	100	0	0.05	93	100	87	88	100
	-3	200	0.001	0.005	93	96	91	92	95
	-5	200	0.005	0.001	91	91	91	91	91
10 days	0	40	0.001	0	91	87	96	95	88
	-1	40	0	0	91	100	83	85	100
	-3	200	0.005	0.001	87	91	83	84	90
	-5	200	0	0.005	80	87	74	77	85
12 days	0	100	0.01	0	96	100	91	92	100
	-1	100	0.01	0	93	100	87	88	100
	-3	100	0	0.01	83	87	78	80	86
	-5	200	0.01	0	70	61	78	74	67

Accuracy (ACC), sensitivity (SEN), specificity (SPE), positive predicted value (PPV), and negative predicted value (NPV). All models used a Long Short-Term Memory layer, a batch size of 6, and 50 epochs. Data was collected using SCR Heat time Hr® collars.

Table 3. Performance of different recurrent neural network models based on rumination time and activity index data to detect anaplasmosis using different time series length at different days relative to sickness (DRS) in dairy heifer calves.

Time series	Model description				Performance				
	DRS	Neurons	Dropout	Recurrent dropout	ACC	SEN	SPE	PPV	NPV
5 days	0	20	0.005	0.005	93	91	96	95	92
	-1	20	0.005	0.005	93	91	96	95	92
	-3	20	0.005	0.005	91	96	87	88	95
7 days	0	20	0.001	0.001	96	96	96	96	96
	-1	20	0.01	0.005	98	96	100	100	96
	-3	20	0.005	0.05	89	91	87	88	91
	-5	20	0.01	0.005	85	91	78	81	90
10 days	0	20	0.001	0.000	96	96	96	96	96
	-1	20	0.000	0.05	98	96	100	100	96
	-3	20	0.001	0.005	89	91	87	88	91
	-5	20	0.000	0.05	89	96	83	85	95
12 days	0	20	0.000	0.05	96	96	96	96	96
	-1	20	0.01	0.01	98	96	100	100	96
	-3	20	0.01	0.01	89	87	91	91	88
	-5	20	0.005	0.000	93	91	96	95	92

Accuracy (ACC), sensitivity (SEN), specificity (SPE), positive predicted value (PPV), and negative predicted value (NPV). All models used a Long Short-Term Memory layer, a batch size of 6, and 50 epochs. Data was collected using SCR Heat time HR® collars.

SUPPLEMENTARY MATERIAL

Table 1. Models performance on the test set using activity, rumination, and activity + rumination behavior for five, seven, ten- and twelve-days time series length in dairy calves on the day of the event

Activity 5 days (A5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0.01	0.01	98.0	2.0	100.0	96.0	96.0	100.0
2	100	0.001	0.05	98.0	2.0	100.0	96.0	96.0	100.0
3	100	0.001	0	89.0	11.0	87.0	91.0	91.0	88.0
4	100	0.005	0.05	96.0	4.0	96.0	96.0	96.0	96.0
5	100	0	0.05	96.0	4.0	96.0	96.0	96.0	96.0
Activity 7 days (A7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0	0.05	93.0	7.0	87.0	100.0	100.0	88.0
2	200	0.001	0.005	72.0	28.0	74.0	70.0	71.0	73.0
3	200	0.01	0	87.0	13.0	91.0	83.0	84.0	90.0
4	200	0.005	0.001	85.0	15.0	87.0	83.0	83.0	86.0
5	200	0	0.005	83.0	17.0	83.0	83.0	83.0	83.0
Activity 10 days (A10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	40	0.001	0	91.0	9.0	87.0	96.0	95.0	88.0
2	40	0	0	76.0	24.0	74.0	78.0	77.0	75.0
3	100	0.01	0.01	83.0	17.0	78.0	87.0	86.0	80.0
4	200	0.005	0.001	89.0	11.0	91.0	87.0	88.0	91.0
5	200	0	0.005	83.0	17.0	87.0	78.0	80.0	86.0
Activity 12 days (A12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0.01	0.005	89.0	11.0	91.0	87.0	88.0	91.0
2	100	0.01	0	96.0	4.0	100.0	91.0	92.0	100.0
3	100	0.005	0.005	93.0	7.0	96.0	91.0	92.0	95.0
4	100	0	0.01	87.0	13.0	91.0	83.0	84.0	90.0
5	200	0.01	0	85.0	15.0	96.0	74.0	79.0	94.0
Rumination 5 days (R5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.001	96.0	4.0	96.0	96.0	96.0	96.0
2	20	0.01	0.005	93.0	7.0	91.0	96.0	95.0	92.0
3	20	0.001	0.005	91.0	9.0	87.0	96.0	95.0	88.0
4	20	0.005	0	96.0	4.0	96.0	96.0	96.0	96.0
5	20	0	0.005	93.0	7.0	91.0	96.0	95.0	92.0
Rumination 7 days (R7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	91.0	9.0	87.0	96.0	95.0	88.0
2	20	0.01	0.05	96.0	4.0	96.0	96.0	96.0	96.0
3	20	0.001	0	91.0	9.0	91.0	91.0	91.0	91.0
4	20	0	0.01	96.0	4.0	96.0	96.0	96.0	96.0
5	20	0	0	93.0	7.0	91.0	96.0	95.0	92.0
Rumination 10 days (R10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.005	89.0	11.0	87.0	91.0	91.0	88.0
2	20	0.001	0.05	93.0	7.0	91.0	96.0	95.0	92.0
3	20	0.001	0	93.0	7.0	91.0	96.0	95.0	92.0
4	20	0.005	0.001	93.0	7.0	96.0	91.0	92.0	95.0
5	20	0	0.01	93.0	7.0	91.0	96.0	95.0	92.0
Rumination 12 days (R12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV

1	20	0.001	0.01	93.0	7.0	91.0	96.0	95.0	92.0
2	20	0.001	0.005	96.0	4.0	96.0	96.0	96.0	96.0
3	20	0.01	0	96.0	4.0	96.0	96.0	96.0	96.0
4	20	0.005	0.01	96.0	4.0	96.0	96.0	96.0	96.0
5	20	0	0.01	96.0	4.0	96.0	96.0	96.0	96.0
Activity + Rumination 5 days (AR5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.01	93.0	7.0	91.0	96.0	95.0	92.0
2	20	0.001	0.05	91.0	9.0	87.0	96.0	95.0	88.0
3	20	0.01	0	91.0	9.0	87.0	96.0	95.0	88.0
4	20	0.005	0.01	93.0	7.0	91.0	96.0	95.0	92.0
5	20	0.005	0.005	93.0	7.0	91.0	96.0	95.0	92.0
Activity + Rumination 7 days (AR7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	93.0	7.0	91.0	96.0	95.0	92.0
2	20	0.001	0.001	96.0	4.0	96.0	96.0	96.0	96.0
3	20	0.01	0.005	91.0	9.0	87.0	96.0	95.0	88.0
4	20	0.005	0.05	93.0	7.0	91.0	96.0	95.0	92.0
5	20	0	0.05	93.0	7.0	91.0	96.0	95.0	92.0
Activity + Rumination 10 days (AR10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	96.0	4.0	96.0	96.0	96.0	96.0
2	20	0.001	0.005	96.0	4.0	96.0	96.0	96.0	96.0
3	20	0.001	0	96.0	4.0	96.0	96.0	96.0	96.0
4	20	0.005	0.05	93.0	7.0	91.0	96.0	95.0	92.0
5	20	0	0.05	93.0	7.0	91.0	96.0	95.0	92.0
Activity + Rumination 12 days (AR12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.01	96.0	4.0	96.0	96.0	96.0	96.0
2	20	0.01	0	96.0	4.0	96.0	96.0	96.0	96.0
3	20	0.005	0.05	96.0	4.0	96.0	96.0	96.0	96.0
4	20	0.005	0	91.0	9.0	91.0	91.0	91.0	91.0
5	20	0.05	0	96.0	4.0	96.0	96.0	96.0	96.0

Dropout (Drop.), Recurrent Dropout (Rec. Drop.), accuracy (Acc), error rate (Error), sensitivity (Sen), Specificity (Spe), Positive Predicted Value (PPV), and Negative Predicted Value (NPV). For all models 1 Long Short Term Memory layer, a batch size of 6, and 50 epochs were used.

Table 2. Models performance to predict health status for Anaplasmosis one day before the event using activity, rumination, and activity + rumination behavior considering five, seven, ten and twelve days time series length in dairy calves

Activity 5 days (A5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0.01	0.01	91.0	9.0	96.0	87.0	88.0	95.0
2	100	0.001	0.05	93.0	7.0	96.0	91.0	92.0	95.0
3	100	0.001	0	76.0	24.0	87.0	65.0	71.0	83.0
4	100	0.005	0.05	89.0	11.0	96.0	83.0	85.0	95.0
5	100	0	0.05	89.0	11.0	96.0	83.0	85.0	95.0
Activity 7 days (A7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0	0.05	93.0	7.0	100.0	87.0	88.0	100.0
2	200	0.001	0.005	89.0	11.0	100.0	78.0	82.0	100.0
3	200	0.01	0	89.0	11.0	96.0	83.0	85.0	95.0
4	200	0.005	0.001	85.0	15.0	100.0	70.0	77.0	100.0
5	200	0	0.005	89.0	11.0	96.0	83.0	85.0	95.0
Activity 10 days (A10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	40	0.001	0	87.0	13.0	96.0	78.0	81.0	95.0
2	40	0	0	91.0	9.0	100.0	83.0	85.0	100.0
3	100	0.01	0.01	91.0	9.0	96.0	87.0	88.0	95.0
4	200	0.005	0.001	83.0	17.0	91.0	74.0	78.0	89.0
5	200	0	0.005	87.0	13.0	91.0	83.0	84.0	90.0
Activity 12 days (A12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0.01	0.005	85.0	15.0	87.0	83.0	83.0	86.0
2	100	0.01	0	93.0	7.0	100.0	87.0	88.0	100.0
3	100	0.005	0.005	85.0	15.0	87.0	83.0	83.0	86.0
4	100	0	0.01	93.0	7.0	96.0	91.0	92.0	95.0
5	200	0.01	0	89.0	11.0	91.0	87.0	88.0	91.0
Rumination 5 days (R5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.001	93.0	7.0	96.0	91.0	92.0	95.0
2	20	0.01	0.005	93.0	7.0	91.0	96.0	95.0	92.0
3	20	0.001	0.005	96.0	4.0	96.0	96.0	96.0	96.0
4	20	0.005	0	96.0	4.0	96.0	96.0	96.0	96.0
5	20	0	0.005	93.0	7.0	91.0	96.0	95.0	92.0
Rumination 7 days (R7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	98.0	2.0	96.0	100.0	100.0	96.0
2	20	0.01	0.05	91.0	9.0	87.0	96.0	95.0	88.0
3	20	0.001	0	96.0	4.0	91.0	100.0	100.0	92.0
4	20	0	0.01	96.0	4.0	91.0	100.0	100.0	92.0
5	20	0	0	96.0	4.0	96.0	96.0	96.0	96.0
Rumination 10 days (R10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.005	96.0	4.0	91.0	100.0	100.0	92.0
2	20	0.001	0.05	91.0	9.0	87.0	96.0	95.0	88.0
3	20	0.001	0	96.0	4.0	91.0	100.0	100.0	92.0
4	20	0.005	0.001	93.0	7.0	91.0	96.0	95.0	92.0
5	20	0	0.01	93.0	7.0	91.0	96.0	95.0	92.0
Rumination 12 days (R12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	96.0	4.0	96.0	96.0	96.0	96.0
2	20	0.001	0.005	91.0	9.0	91.0	91.0	91.0	91.0
3	20	0.01	0	96.0	4.0	100.0	91.0	92.0	100.0
4	20	0.005	0.01	96.0	4.0	91.0	100.0	100.0	92.0

5	20	0	0.01	98.0	2.0	100.0	96.0	96.0	100.0
Activity + Rumination 5 days (AR5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.01	93.0	7.0	87.0	100.0	100.0	88.0
2	20	0.001	0.05	93.0	7.0	87.0	100.0	100.0	88.0
3	20	0.01	0	93.0	7.0	87.0	100.0	100.0	88.0
4	20	0.005	0.01	89.0	11.0	83.0	96.0	95.0	85.0
5	20	0.005	0.005	93.0	7.0	91.0	96.0	95.0	92.0
Activity + Rumination 7 days (AR7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	96.0	4.0	91.0	100.0	100.0	92.0
2	20	0.001	0.001	96.0	4.0	91.0	100.0	100.0	92.0
3	20	0.01	0.005	98.0	2.0	96.0	100.0	100.0	96.0
4	20	0.005	0.05	93.0	7.0	91.0	96.0	95.0	92.0
5	20	0	0.05	96.0	4.0	91.0	100.0	100.0	92.0
Activity + Rumination 10 days (AR10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	98.0	2.0	96.0	100.0	100.0	96.0
2	20	0.001	0.005	98.0	2.0	96.0	100.0	100.0	96.0
3	20	0.001	0	98.0	2.0	96.0	100.0	100.0	96.0
4	20	0.005	0.05	98.0	2.0	96.0	100.0	100.0	96.0
5	20	0	0.05	98.0	2.0	96.0	100.0	100.0	96.0
Activity + Rumination 12 days (AR12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.01	98.0	2.0	96.0	100.0	100.0	96.0
2	20	0.01	0	93.0	7.0	91.0	96.0	95.0	92.0
3	20	0.005	0.05	93.0	7.0	91.0	96.0	95.0	92.0
4	20	0.005	0	96.0	4.0	91.0	100.0	100.0	92.0
5	20	0.05	0	96.0	4.0	91.0	100.0	100.0	92.0

Dropout (Drop.), Recurrent Dropout (Rec. Drop.), accuracy (Acc), error rate (Error), sensitivity (Sen), Specificity (Spe), Positive Predicted Value (PPV), and Negative Predicted Value (NPV). For all models 1 Long Short Term Memory layer, a batch size of 6, and 50 epochs were used.

Table 3. Models performance to predict health status for Anaplasmosis two days before the event using activity, rumination, and activity + rumination behavior considering five, seven, ten and twelve days time series length in dairy calves

Activity 5 days (A5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0.01	0.01	93.0	7.0	91.0	96.0	95.0	92.0
2	100	0.001	0.05	89.0	11.0	83.0	96.0	95.0	85.0
3	100	0.001	0	98.0	2.0	96.0	100.0	100.0	96.0
4	100	0.005	0.05	91.0	9.0	91.0	91.0	91.0	91.0
5	100	0	0.05	91.0	9.0	87.0	96.0	95.0	88.0
Activity 7 days (A7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0	0.05	89.0	11.0	91.0	87.0	88.0	91.0
2	200	0.001	0.005	87.0	13.0	96.0	78.0	81.0	95.0
3	200	0.01	0	91.0	9.0	96.0	87.0	88.0	95.0
4	200	0.005	0.001	89.0	11.0	96.0	83.0	85.0	95.0
5	200	0	0.005	91.0	9.0	96.0	87.0	88.0	95.0
Activity 10 days (A10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	40	0.001	0	85.0	15.0	87.0	83.0	83.0	86.0
2	40	0	0	83.0	17.0	87.0	78.0	80.0	86.0
3	100	0.01	0.01	85.0	15.0	91.0	78.0	81.0	90.0
4	200	0.005	0.001	93.0	7.0	100.0	87.0	88.0	100.0
5	200	0	0.005	87.0	13.0	91.0	83.0	84.0	90.0
Activity 12 days (A12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0.01	0.005	89.0	11.0	96.0	83.0	85.0	95.0
2	100	0.01	0	87.0	13.0	96.0	78.0	81.0	95.0
3	100	0.005	0.005	89.0	11.0	100.0	78.0	82.0	100.0
4	100	0	0.01	91.0	9.0	91.0	91.0	91.0	91.0
5	200	0.01	0	87.0	13.0	100.0	74.0	79.0	100.0
Rumination 5 days (R5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.001	85.0	15.0	91.0	78.0	81.0	90.0
2	20	0.01	0.005	87.0	13.0	91.0	83.0	84.0	90.0
3	20	0.001	0.005	87.0	13.0	96.0	78.0	81.0	95.0
4	20	0.005	0	87.0	13.0	96.0	78.0	81.0	95.0
5	20	0	0.005	85.0	15.0	91.0	78.0	81.0	90.0
Rumination 7 days (R7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	89.0	11.0	87.0	91.0	91.0	88.0
2	20	0.01	0.05	83.0	17.0	83.0	83.0	83.0	83.0
3	20	0.001	0	83.0	17.0	74.0	91.0	89.0	78.0
4	20	0	0.01	83.0	17.0	83.0	83.0	83.0	83.0
5	20	0	0	85.0	15.0	78.0	91.0	90.0	81.0
Rumination 10 days (R10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.005	85.0	15.0	91.0	78.0	81.0	90.0
2	20	0.001	0.05	89.0	11.0	100.0	78.0	82.0	100.0
3	20	0.001	0	87.0	13.0	100.0	74.0	79.0	100.0
4	20	0.005	0.001	89.0	11.0	100.0	78.0	82.0	100.0
5	20	0	0.01	89.0	11.0	96.0	83.0	85.0	95.0
Rumination 12 days (R12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	89.0	11.0	96.0	83.0	85.0	95.0
2	20	0.001	0.005	87.0	13.0	96.0	78.0	81.0	95.0
3	20	0.01	0	91.0	9.0	100.0	83.0	85.0	100.0
4	20	0.005	0.01	89.0	11.0	96.0	83.0	85.0	95.0

5	20	0	0.01	83.0	17.0	87.0	78.0	80.0	86.0
Activity + Rumination 5 days (AR5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.01	87.0	13.0	91.0	83.0	84.0	90.0
2	20	0.001	0.05	89.0	11.0	96.0	83.0	85.0	95.0
3	20	0.01	0	85.0	15.0	91.0	78.0	81.0	90.0
4	20	0.005	0.01	85.0	15.0	96.0	74.0	79.0	94.0
5	20	0.005	0.005	89.0	11.0	96.0	83.0	85.0	95.0
Activity + Rumination 7 days (AR7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	91.0	9.0	100.0	83.0	85.0	100.0
2	20	0.001	0.001	89.0	11.0	96.0	83.0	85.0	95.0
3	20	0.01	0.005	89.0	11.0	96.0	83.0	85.0	95.0
4	20	0.005	0.05	91.0	9.0	100.0	83.0	85.0	100.0
5	20	0	0.05	93.0	100.0	88.0	87.0	100.0	7.0
Activity + Rumination 10 days (AR10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	89.0	11.0	96.0	83.0	85.0	95.0
2	20	0.001	0.005	89.0	11.0	96.0	83.0	85.0	95.0
3	20	0.001	0	89.0	11.0	96.0	83.0	85.0	95.0
4	20	0.005	0.05	89.0	11.0	96.0	83.0	85.0	95.0
5	20	0	0.05	89.0	11.0	96.0	83.0	85.0	95.0
Activity + Rumination 12 days (AR12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.01	91.0	9.0	96.0	87.0	88.0	95.0
2	20	0.01	0	93.0	7.0	100.0	87.0	88.0	100.0
3	20	0.005	0.05	87.0	13.0	91.0	83.0	84.0	90.0
4	20	0.005	0	89.0	11.0	91.0	87.0	88.0	91.0
5	20	0.05	0	91.0	9.0	96.0	87.0	88.0	95.0

Dropout (Drop.), Recurrent Dropout (Rec. Drop.), accuracy (Acc), error rate (Error), sensitivity (Sen), Specificity (Spe), Positive Predicted Value (PPV), and Negative Predicted Value (NPV). For all models 1 Long Short Term Memory layer, a batch size of 6, and 50 epochs were used.

Table 4. Models performance to predict health status for Anaplasmosis three days before the event using activity, rumination, and activity + rumination behavior considering five, seven, ten and twelve days time series length in dairy calves.

Activity 5 days (A5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0.01	0.01	74.0	26.0	87.0	61.0	69.0	82.0
2	100	0.001	0.05	72.0	28.0	70.0	74.0	73.0	71.0
3	100	0.001	0	78.0	22.0	83.0	74.0	76.0	81.0
4	100	0.005	0.05	72.0	28.0	65.0	78.0	75.0	69.0
5	100	0	0.05	85.0	15.0	91.0	78.0	81.0	90.0
Activity 7 days (A7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0	0.05	80.0	20.0	91.0	70.0	75.0	89.0
2	200	0.001	0.005	93.0	7.0	96.0	91.0	92.0	95.0
3	200	0.01	0	89.0	11.0	83.0	96.0	95.0	85.0
4	200	0.005	0.001	93.0	7.0	96.0	91.0	92.0	95.0
5	200	0	0.005	89.0	11.0	96.0	83.0	85.0	95.0
Activity 10 days (A10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	40	0.001	0	76.0	24.0	83.0	70.0	73.0	80.0
2	40	0	0	83.0	17.0	96.0	70.0	76.0	94.0
3	100	0.01	0.01	85.0	15.0	96.0	74.0	79.0	94.0
4	200	0.005	0.001	87.0	13.0	91.0	83.0	84.0	90.0
5	200	0	0.005	80.0	20.0	87.0	74.0	77.0	85.0
Activity 12 days (A12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0.01	0.005	80.0	20.0	91.0	70.0	75.0	89.0
2	100	0.01	0	74.0	26.0	83.0	65.0	70.0	79.0
3	100	0.005	0.005	80.0	20.0	91.0	70.0	75.0	89.0
4	100	0	0.01	83.0	17.0	87.0	78.0	80.0	86.0
5	200	0.01	0	80.0	20.0	87.0	74.0	77.0	85.0
Rumination 5 days (R5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.001	85.0	15.0	87.0	83.0	83.0	86.0
2	20	0.01	0.005	87.0	13.0	91.0	83.0	84.0	90.0
3	20	0.001	0.005	85.0	15.0	87.0	83.0	83.0	86.0
4	20	0.005	0	85.0	15.0	87.0	83.0	83.0	86.0
5	20	0	0.005	87.0	13.0	91.0	83.0	84.0	90.0
Rumination 7 days (R7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	89.0	11.0	91.0	87.0	88.0	91.0
2	20	0.01	0.05	87.0	13.0	91.0	83.0	84.0	90.0
3	20	0.001	0	85.0	15.0	87.0	83.0	83.0	86.0
4	20	0	0.01	89.0	11.0	91.0	87.0	88.0	91.0
5	20	0	0	85.0	15.0	87.0	83.0	83.0	86.0
Rumination 10 days (R10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.005	89.0	11.0	91.0	87.0	88.0	91.0
2	20	0.001	0.05	89.0	11.0	91.0	87.0	88.0	91.0
3	20	0.001	0	87.0	13.0	87.0	87.0	87.0	87.0
4	20	0.005	0.001	89.0	11.0	91.0	87.0	88.0	91.0
5	20	0	0.01	89.0	11.0	91.0	87.0	88.0	91.0
Rumination 12 days (R12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	87.0	13.0	87.0	87.0	87.0	87.0
2	20	0.001	0.005	85.0	15.0	87.0	83.0	83.0	86.0
3	20	0.01	0	89.0	11.0	91.0	87.0	88.0	91.0
4	20	0.005	0.01	89.0	11.0	91.0	87.0	88.0	91.0

5	20	0	0.01	85.0	15.0	83.0	87.0	86.0	83.0
Activity + Rumination 5 days (AR5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.01	89.0	11.0	91.0	87.0	88.0	91.0
2	20	0.001	0.05	87.0	13.0	87.0	87.0	87.0	87.0
3	20	0.01	0	87.0	13.0	91.0	83.0	84.0	90.0
4	20	0.005	0.01	87.0	13.0	87.0	87.0	87.0	87.0
5	20	0.005	0.005	91.0	9.0	96.0	87.0	88.0	95.0
Activity + Rumination 7 days (AR7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	87.0	13.0	87.0	87.0	87.0	87.0
2	20	0.001	0.001	87.0	13.0	87.0	87.0	87.0	87.0
3	20	0.01	0.005	87.0	13.0	87.0	87.0	87.0	87.0
4	20	0.005	0.05	89.0	11.0	91.0	87.0	88.0	91.0
5	20	0	0.05	85.0	15.0	87.0	83.0	83.0	86.0
Activity + Rumination 10 days (AR10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	85.0	15.0	87.0	83.0	83.0	86.0
2	20	0.001	0.005	89.0	11.0	91.0	87.0	88.0	91.0
3	20	0.001	0	83.0	17.0	83.0	83.0	83.0	83.0
4	20	0.005	0.05	89.0	11.0	91.0	87.0	88.0	91.0
5	20	0	0.05	83.0	17.0	83.0	83.0	83.0	83.0
Activity + Rumination 12 days (AR12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.01	89.0	11.0	87.0	91.0	91.0	88.0
2	20	0.01	0	85.0	15.0	87.0	83.0	83.0	86.0
3	20	0.005	0.05	87.0	13.0	83.0	91.0	90.0	84.0
4	20	0.005	0	85.0	15.0	87.0	83.0	83.0	86.0
5	20	0	0.05	87.0	13.0	87.0	87.0	87.0	87.0

Dropout (Drop.), Recurrent Dropout (Rec. Drop.), accuracy (Acc), error rate (Error), sensitivity (Sen), Specificity (Spe), Positive Predicted Value (PPV), and Negative Predicted Value (NPV). For all models 1 Long Short Term Memory layer, a batch size of 6, and 50 epochs were used.

Table 5. Models performance to predict health status for Anaplasmosis four days before the event using activity, rumination, and activity + rumination behavior considering five, seven, ten and twelve days time series length in dairy calves

Activity 5 days (A5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0.01	0.01	83.0	17.0	87.0	78.0	80.0	86.0
2	100	0.001	0.05	80.0	20.0	87.0	74.0	77.0	85.0
3	100	0.001	0	78.0	22.0	83.0	74.0	76.0	81.0
4	100	0.005	0.05	78.0	22.0	83.0	74.0	76.0	81.0
5	100	0	0.05	80.0	20.0	83.0	78.0	79.0	82.0
Activity 7 days (A7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0	0.05	87.0	13.0	83.0	91.0	90.0	84.0
2	200	0.001	0.005	87.0	13.0	87.0	87.0	87.0	87.0
3	200	0.01	0	96.0	4.0	91.0	100.0	100.0	92.0
4	200	0.005	0.001	93.0	7.0	91.0	96.0	95.0	92.0
5	200	0	0.005	91.0	9.0	91.0	91.0	91.0	91.0
Activity 10 days (A10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	40	0.001	0	78.0	22.0	65.0	91.0	88.0	72.0
2	40	0	0	76.0	24.0	70.0	83.0	80.0	73.0
3	100	0.01	0.01	74.0	26.0	70.0	78.0	76.0	72.0
4	200	0.005	0.001	78.0	22.0	87.0	70.0	74.0	84.0
5	200	0	0.005	70.0	30.0	70.0	70.0	70.0	70.0
Activity 12 days (A12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0.01	0.005	85.0	15.0	83.0	87.0	86.0	83.0
2	100	0.01	0	80.0	20.0	78.0	83.0	82.0	79.0
3	100	0.005	0.005	78.0	22.0	70.0	87.0	84.0	74.0
4	100	0	0.01	85.0	15.0	83.0	87.0	86.0	83.0
5	200	0.01	0	89.0	11.0	91.0	87.0	88.0	91.0
Rumination 5 days (R5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.001	76.0	24.0	74.0	78.0	77.0	75.0
2	20	0.01	0.005	67.0	33.0	65.0	70.0	68.0	67.0
3	20	0.001	0.005	78.0	22.0	70.0	87.0	84.0	74.0
4	20	0.005	0	78.0	22.0	70.0	87.0	84.0	74.0
5	20	0	0.005	83.0	17.0	74.0	91.0	89.0	78.0
Rumination 7 days (R7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	85.0	15.0	83.0	87.0	86.0	83.0
2	20	0.01	0.05	76.0	24.0	78.0	74.0	75.0	77.0
3	20	0.001	0	83.0	17.0	83.0	83.0	83.0	83.0
4	20	0	0.01	87.0	13.0	91.0	83.0	84.0	90.0
5	20	0	0	78.0	22.0	78.0	78.0	78.0	78.0
Rumination 10 days (R10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.005	83.0	17.0	91.0	74.0	78.0	89.0
2	20	0.001	0.05	83.0	17.0	87.0	78.0	80.0	86.0
3	20	0.001	0	70.0	30.0	78.0	61.0	67.0	74.0
4	20	0.005	0.001	76.0	24.0	83.0	70.0	73.0	80.0
5	20	0	0.01	87.0	13.0	91.0	83.0	84.0	90.0
Rumination 12 days (R12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	83.0	17.0	87.0	78.0	80.0	86.0
2	20	0.001	0.005	72.0	28.0	70.0	74.0	73.0	71.0
3	20	0.01	0	78.0	22.0	83.0	74.0	76.0	81.0
4	20	0.005	0.01	80.0	20.0	83.0	78.0	79.0	82.0

5	20	0	0.01	78.0	22.0	78.0	78.0	78.0	78.0
Activity + Rumination 5 days (AR5)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.01	78.0	22.0	78.0	78.0	78.0	78.0
2	20	0.001	0.05	83.0	17.0	83.0	83.0	83.0	83.0
3	20	0.01	0	78.0	22.0	78.0	78.0	78.0	78.0
4	20	0.005	0.01	76.0	24.0	74.0	78.0	77.0	75.0
5	20	0.005	0.005	76.0	24.0	74.0	78.0	77.0	75.0
Activity + Rumination 7 days (AR7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	85.0	15.0	83.0	87.0	86.0	83.0
2	20	0.001	0.001	91.0	9.0	96.0	87.0	88.0	95.0
3	20	0.01	0.005	91.0	9.0	91.0	91.0	91.0	91.0
4	20	0.005	0.05	91.0	9.0	87.0	96.0	95.0	88.0
5	20	0	0.05	83.0	17.0	87.0	78.0	80.0	86.0
Activity + Rumination 10 days (AR10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	87.0	13.0	83.0	91.0	90.0	84.0
2	20	0.001	0.005	80.0	20.0	83.0	78.0	79.0	82.0
3	20	0.001	0	78.0	22.0	83.0	74.0	76.0	81.0
4	20	0.005	0.05	78.0	22.0	83.0	74.0	76.0	81.0
5	20	0	0.05	85.0	15.0	87.0	83.0	83.0	86.0
Activity + Rumination 12 days (AR12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.01	80.0	20.0	87.0	74.0	77.0	85.0
2	20	0.01	0	78.0	22.0	87.0	70.0	74.0	84.0
3	20	0.005	0.05	78.0	22.0	91.0	65.0	72.0	88.0
4	20	0.005	0	89.0	11.0	96.0	83.0	85.0	95.0
5	20	0	0.05	76.0	24.0	87.0	65.0	71.0	83.0

Dropout (Drop.), Recurrent Dropout (Rec. Drop.), accuracy (Acc), error rate (Error), sensitivity (Sen), Specificity (Spe), Positive Predicted Value (PPV), and Negative Predicted Value (NPV). For all models 1 Long Short Term Memory layer, a batch size of 6, and 50 epochs were used.

Table 6. Models performance to predict health status for Anaplasmosis five days before the event using activity, rumination, and activity + rumination behavior considering five, seven, ten and twelve days time series length in dairy calves.

Activity 7 days (A7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0	0.05	70.0	30.0	78.0	61.0	67.0	74.0
2	200	0.001	0.005	83.0	17.0	78.0	87.0	86.0	80.0
3	200	0.01	0	87.0	13.0	83.0	91.0	90.0	84.0
4	200	0.005	0.001	91.0	9.0	91.0	91.0	91.0	91.0
5	200	0	0.005	83.0	17.0	83.0	83.0	83.0	83.0
Activity 10 days (A10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	40	0.001	0	76.0	24.0	83.0	70.0	73.0	80.0
2	40	0	0	76.0	24.0	78.0	74.0	75.0	77.0
3	100	0.01	0.01	78.0	22.0	78.0	78.0	78.0	78.0
4	200	0.005	0.001	74.0	26.0	83.0	65.0	70.0	79.0
5	200	0	0.005	80.0	20.0	87.0	74.0	77.0	85.0
Activity 12 days (A12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	100	0.01	0.005	61.0	39.0	61.0	61.0	61.0	61.0
2	100	0.01	0	67.0	33.0	70.0	65.0	67.0	68.0
3	100	0.005	0.005	63.0	37.0	61.0	65.0	64.0	62.0
4	100	0	0.01	61.0	39.0	74.0	48.0	59.0	65.0
5	200	0.01	0	70.0	30.0	61.0	78.0	74.0	67.0
Rumination 7 days (R7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	74.0	26.0	78.0	70.0	72.0	76.0
2	20	0.01	0.05	80.0	20.0	91.0	70.0	75.0	89.0
3	20	0.001	0	80.0	20.0	87.0	74.0	77.0	85.0
4	20	0	0.01	80.0	20.0	78.0	83.0	82.0	79.0
5	20	0	0	83.0	17.0	87.0	78.0	80.0	86.0
Rumination 10 days (R10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.005	89.0	11.0	83.0	96.0	95.0	85.0
2	20	0.001	0.05	85.0	15.0	83.0	87.0	86.0	83.0
3	20	0.001	0	83.0	17.0	87.0	78.0	80.0	86.0
4	20	0.005	0.001	85.0	15.0	91.0	78.0	81.0	90.0
5	20	0	0.01	85.0	15.0	87.0	83.0	83.0	86.0
Rumination 12 days (R12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	89.0	11.0	87.0	91.0	91.0	88.0
2	20	0.001	0.005	91.0	9.0	91.0	91.0	91.0	91.0
3	20	0.01	0	83.0	17.0	83.0	83.0	83.0	83.0
4	20	0.005	0.01	89.0	11.0	87.0	91.0	91.0	88.0
5	20	0	0.01	85.0	15.0	83.0	87.0	86.0	83.0
Activity + Rumination 7 days (AR7)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	83.0	17.0	91.0	74.0	78.0	89.0
2	20	0.001	0.001	83.0	17.0	87.0	78.0	80.0	86.0
3	20	0.01	0.005	85.0	15.0	91.0	78.0	81.0	90.0
4	20	0.005	0.05	83.0	17.0	91.0	74.0	78.0	89.0
5	20	0	0.05	85.0	15.0	87.0	83.0	83.0	86.0
Activity + Rumination 10 days (AR10)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.001	0.01	83.0	17.0	91.0	74.0	78.0	89.0
2	20	0.001	0.005	85.0	15.0	91.0	78.0	81.0	90.0
3	20	0.001	0	83.0	17.0	91.0	74.0	78.0	89.0
4	20	0.005	0.05	89.0	11.0	96.0	83.0	85.0	95.0

5	20	0	0.05	89.0	11.0	96.0	83.0	85.0	95.0
Activity + Rumination 12 days (AR12)									
Models	Neurons	Drop.	Rec. Drop.	Acc	Error	Sen	Spe	PPV	NPV
1	20	0.01	0.01	91.0	9.0	87.0	96.0	95.0	88.0
2	20	0.01	0	89.0	11.0	87.0	91.0	91.0	88.0
3	20	0.005	0.05	85.0	15.0	78.0	91.0	90.0	81.0
4	20	0.005	0	93.0	7.0	91.0	96.0	95.0	92.0
5	20	0	0.05	89.0	11.0	83.0	96.0	95.0	85.0

Dropout (Drop.), Recurrent Dropout (Rec. Drop.), accuracy (Acc), error rate (Error), sensitivity (Sen), Specificity (Spe), Positive Predicted Value (PPV), and Negative Predicted Value (NPV). For all models 1 Long Short Term Memory layer, a batch size of 6, and 50 epochs were used.

3.2 Artigo 2 - Developing predictive models for early detection of anaplasmosis based on data from collar or ear tag accelerometers in dairy heifer calves

Este artigo foi **submetido** na revista JDS Communications.

Developing predictive models for early detection of anaplasmosis based on data from collar and ear tag accelerometers in dairy heifer calves

Keywords: activity, *Anaplasma marginale*, early diagnosis, neural networks, rumination time, precision livestock farming

V. A. Teixeira,¹ A. M. Q. Lana,¹ G. M. Souza,² J. P. P. Rodrigues,³ T. R. Tomich,⁴ J. Furlong⁴, T. Brezolin,⁵ J. A. G. Silveira⁶, L. D. Ferreira,¹ E. J. Facury Filho¹, M. M. Campos,⁴ J. R. R. Dorea^{5*}, L. G. R. Pereira^{4*}

¹Department of Animal Science, School of Veterinary, Federal University of Minas Gerais, Minas Gerais, 30161-970, Brazil

²Department of Animal Science, Federal University of Lavras, Minas Gerais, 37200-000, Brazil

³Faculty of Animal Science, Federal University of the Southern and Southeastern Pará, Xinguara, Pará, 68507-590, Brazil

⁴Brazilian Agricultural Research Corporation - Embrapa, Embrapa Dairy Cattle, Minas Gerais, 36038-330, Brazil

⁵University of Wisconsin, Madison, WI, USA

⁶Departament of Parasitology, Institute of Biological Sciences, Federal University of Minas Gerais, Minas Gerais, 31270-901, Brazil,

*Corresponding authors: joao.dorea@wisc.edu, ⁵University of Wisconsin, Madison, WI, USA 53706-1205

HIGHLIGHTS

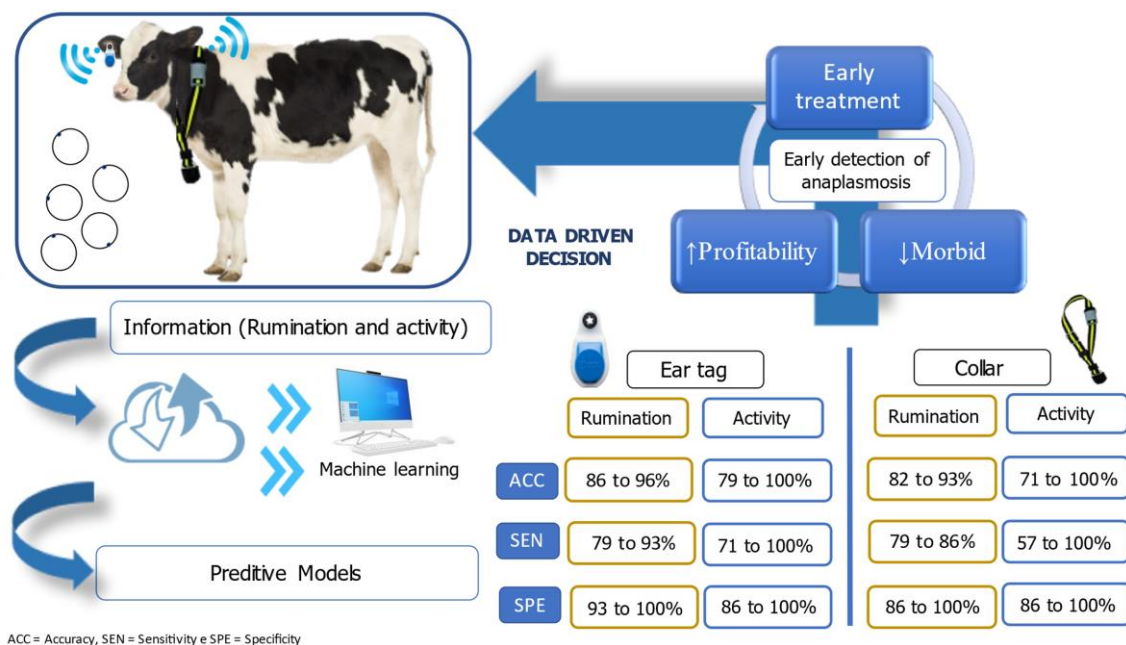
- Default health alerts of commercial devices are not efficient to detect anaplasmosis
- Machine learning approach was used to develop predictive models for early detection of anaplasmosis
- Models based on activity and rumination were able to detect anaplasmosis accurately
- Collar and ear tag sensors have sensitivity to detect anaplasmosis

ABSTRACT

The use of wearable devices to monitor animal behavior could be a powerful tool to early predict diseases in dairy calves. The objective of this study was to compare the predictive ability of Recurrent Neural Network (RNN) to detect anaplasmosis on day zero (0d, when the minor packed cell volume - PCV value was achieved) or 3 days in advance (-3), based on rumination (RUM) and activity (ACT) data retrieved from two devices: collar (Heatime HR) and ear tag (eSense Flex[®]). Fourteen dairy calves (119 ± 15 days old and 148 ± 20 kg of BW) were challenged with 2×10^7 erythrocytes infected with UFMG 1 strain (GenBank no. EU676176) isolated from *Anaplasma marginale*. Both devices were used in each calve to collect the behavior data. The lowest PCV value (14 ± 1.8%) was used to distinguish sick from (d0) healthy animals (PCV = 32 ± 2.4%). A 7-day sequence was randomly selected from a time window varying from -50 to -15d before d0. This time-series was used to classify a healthy pattern (sequence of days that did not result in a positive case: Anaplasmosis). The second time-series consisted in a sequence of days that resulted in a positive case (from -7 to 0d) or a sequence of days that ended 3 days before a positive case (-10 to -3d). The last two time series were used to classify a sick animal. RNN was implemented in Keras R package, and to validate the trained algorithms, a leave-one-animal-out cross-validation was implemented. The ACC, SEN,

and SPE for predictions at 0d were similar for collar and ear tag (100%) using ACT data. The predictions based on ACT for -3d in the advance decrease the ACC 21% percentual points (ear tag) and 29% (collar) when compared with 0d models. When RUM data was used, the ACC, SEN, and SPE were lower compared to ACT data for both devices. The analytical approach used to early detect anaplasmosis disease achieved great predictive performance for both collar and ear-tag sensors.

GRAPHICAL ABSTRACT



The reduction in the number of dairy farms and the increase in herd size is a common trend observed in the most important dairy regions worldwide. (USDA ERS - Milk Cost of Production Estimates); (Miller et al., 2020). Thus, individual animal monitoring becomes more complex and challenging (Maltz, 2020). Precision farming technologies (PFT) appear as a potential strategy to automate data collection and to effectively improve farm management decisions. In this context, the use of PFT for early

diagnosis of diseases can positively impact dairy production systems by reducing economic losses and improving animal health and welfare.

Bovine anaplasmosis is one of the most common post-weaning diseases, and it is responsible for high economic losses (Oliveira Júnior et al., 2018; Miller et al., 2020; Souza et al., 2021).

To minimize the effects of anaplasmosis, some farmers promote the early treatment of calves with initial clinical signs, such as apathy, reduced feed intake; fever; mucosal yellowness and evaluation of hematocrit pore microhematocrit; and monitoring weight gain and milk production (Oliveira Júnior et al., 2018; Souza et al., 2021). However, a systematic clinical monitoring of individual animals for anaplasmosis diagnosis requires time, training, and specialized labor, which become a limiting factor in large-scale livestock operations (Kocan et al., 2003; Silvestre et al., 2016; Oliveira Júnior et al., 2018).

The use of PFT can generate sufficient data to develop data-driven useful algorithms to detect diseases (Cockburn, 2020). In this sense, early detection of diseases such as anaplasmosis may reduce the excessive use of antimicrobials and antiparasitic in livestock. Inappropriate use of these drugs is the main factor responsible for the increase in drug resistance and reduction of treatment effectiveness (Farrell et al., 2021; Silva et al., 2021). Teixeira et al. (2022) proposed a methodology that evaluated the use of a collar as an auxiliary tool in the early detection of anaplasmosis. However, applicability of ear tags was not evaluated for anaplasmosis, and equivalence of these sensors should be evaluated.

The aims of the study were: *i*) to compare rumination and activity estimates collected by the collar and ear tags in calves facing anaplasmosis, and *ii*) to compare collars and ear tags as a data source for the development of machine learning models.

This study was approved by the Embrapa Dairy Cattle Ethics Committee (number: 4498240316). The experiment was conducted at the Embrapa Dairy Cattle Experimental Farm located in Coronel Pacheco, Minas Gerais, Brazil. Details of management and housing, anaplasmosis inoculation procedure and laboratory and hematological evaluation are described by Teixeira et al. (2022).

Fourteen calves averaging 119 ± 15 days old and 148.4 ± 20.3 kg of BW received an Hr-Tag collar (SCR Engineers LTD., Netanya, Israel) and an Allflex Young Stock® eSense Flex® ear-tag (SCR Engineers LTD., Netanya, Israel). The collars were placed following the directions of Rodrigues et al. (2019). The ear tags were placed in the middle of the left ear, between the two cartilage ribs and $2/3$ from the outside edge of the ear (Macmillan et al., 2020). The RUM and ACT data were directly transmitted to the computer via a wireless network, using the software “SCR Healthy Cow 24® Solution”, platform Heatime® Pro +. Standard health alerts of each sensor were also recorded daily.

The animals were considered sick when the packed cell volume (PCV) value dropped and achieved 50% or less of healthy value ($32 \pm 1.49\%$) for each animal and positive rickettsemia (Teixeira et al., 2022). The animals were classified as healthy when they had no parasitized red blood cells and the PCR/RIFI test was negative. To standardize the days relative to sickness, day zero (d0) was considered the day that the minimum PCV value was reached. A 7-day sequence was randomly selected from a time window varying from -50 to -15d before d0. This time-series was used to classify a healthy pattern, defined as a sequence of days that does not result in a positive case of anaplasmosis. The second time-series consisted in a sequence of days that resulted in a

positive case (from -7 to 0d) or a sequence of days that ended 3 days before a positive case (-10 to -3d). The last two time series were used to classify a sick animal. All calves had both time series (healthy and sick) and each animal served as her own control. A Recurrent Neural Network (RNN) called Long Short-Term Memory (LSTM) was used as predictive approach to detect sick events at d0 and at 3 days in advance to d0. It was implemented in Python 3.6 using the computational resources provided by UW-Madison Center for High Throughput Computing (CHTC). The analytical method was implemented according to Teixeira et al (2022).

Model validation was performed using Leave-One-Animal-Out Cross-Validation (LOAOCV). In each iteration, all healthy and sickness data from each calf were deleted and used for test, and the remaining dataset was used to train and tune the model. This approach was repeated n times (n = number of calves) until all calves were excluded once from the training set. For each LOAOCV iteration, hyperparameter tuning was performed using the remained dataset ($n - 2$), and the grid search was performed to define the best combination of hyperparameters through a second leave-one-out cross-validation (nested in each iteration), and these combinations were ranked based on accuracy. The best combination of hyperparameters was defined as the combination with greatest frequency after all iterations; this combination was adopted as the final architecture and used to reanalyze specific iterations.

To evaluate the performance of the models, ACC, SEN, SPE, positive predicted value (PPV), and negative predicted value (NPV) were calculated using the equations: Accuracy = $(TP + TN) / (TP + TN + FP + FN)$, Sensitivity = $TP / (TP + FN)$, Specificity = $TN / (TN + FP)$, PPV = $TP / (TP + FP)$ where TP, FP, FN, and TN are true positive, false positive, false negative and true negative, respectively. A description of the strategy used for

hyperparameters search and models training and testing is presented in Teixeira et al. (2022).

Measurements of RUM and ACT by ear-tag and collar sensors were correlated (RUM Collar x RUM EarTag $r = 0.649$, $P < 0.0001$ | $n = 5116$; ACT Collar x ACT EarTag $r = 0.904$, $P < 0.0001$ | $n = 5116$) were associated, mainly for ACT (Figure 1; A and B). Frequency distribution between sensors had similar pattern, however ear tags had greater frequencies of RUM and ACT at lower values of RUM and ACT (Figure 1; C and D). For our knowledge there are no studies evaluating the accuracy and precision of RUM measurements by ear tags in calves. The great correlation between collar and ear-tag suggests that behavior patterns found in one device would most likely be observed on the other. Specifically for the commercial devices evaluated in our study, there are no recommendations for collar use in calves.

Alterations in PCV, rickettsemia and rectal temperature due to the exposure to *A. marginale* can be observed in Figure 2 (A, B, and C). The PCV on d0 was $14 \pm 1.8\%$, which means 40% of the standard PCV value between -40 and -16 days ($32 \pm 1.49\%$). The mean rickettsemia value on d0 was $6.12 \pm 3.07\%$. Regarding rectal temperature, values higher than the standard physiological value of $39.5 \text{ }^\circ\text{C}$ were observed after -3d, reaching an average of $40.9 \pm 0.5 \text{ }^\circ\text{C}$ on d0. These values make it clear that all animals used in this study became sick.

Rumination and activity daily pattern is presented in Figure 2 (D and E), and the frequency of health alerts by the default algorithms of each sensor is shown in Figure 2F. Fever and apathy are common signs of anaplasmosis and may be associated with reduced motivation to eat and drink (Hart, 1988; Feitosa, 2008), supporting RUM reduction, which is usually an early sign of illness (Johnson, 2002).

Regarding the performance of default health alerts available in collar and ear tag, both did not perform well, proved by the low number of alerts observed for sick animals, with a maximum of 20% of alerts for collars at day -1. On the other hand, the greater number of health alerts triggered by collars indicates a better capacity of this device to identify animals with anaplasmosis than ear tag; however, the alerts triggered by both devices should not be used as a decision criteria to monitor anaplasmosis.

The sensors performed similarly to detect anaplasmosis, with slightly more outstanding performance for ear tags (Figure 3). The prediction at -3d was less accurate than d0. Although all combinations of sensors, days relative to clinical diagnosis and data presented potential usefulness to predict anaplasmosis, both devices demonstrated 100% of ACC, SEN, and SPE at d0 using ACT data (Figure 3). When RUM data was used, the ACC, SEN, and SPE were smaller compared to ACT data.

The performance of machine learning models to predict anaplasmosis using RUM or ACT data from ear tags or collars support the possibility of using such devices as auxiliary tools in tick fever precision therapy suggested by Souza et al. (2021). It may avoid the indiscriminate use of antimicrobials and the development of antimicrobial resistance, and better financial and economic performance within the production systems (Farrell et al., 2021; Lardé et al., 2021). At the same time, this approach can improve prognosis due to early detection ranging from 70% to 80% at -3d. Models based on RUM showed greater prediction quality for early detection (-3d in advance); in contrast, ACT based models performed better when 0d was included in time series.

Our results were obtained in a fully controlled experiment, where only anaplasmosis affected the evaluated variables. In farm conditions, there are several distinct pathogens that can cause health problems. Therefore, future studies under farm conditions, with a larger number of animals, should be carried out to verify the feasibility

of using commercial devices to identify specific diseases, such as anaplasmosis. Anyway, the machine learning prediction models developed in this study can be interpreted as a health alert to indicate animals for clinical analysis, which is a key tool for precision health monitoring in dairy farms.

Default health alert of collar and ear tag evaluated in this study did not provide a reliable prediction of anaplasmosis in dairy calves, however, these sensors were not developed to perform specific detections such as anaplasmosis. The specific RNN models developed to detect anaplasmosis for both devices achieved high predictive quality. Regardless of the sensor, the models based on activity data detected perfectly the disease on the same day of the clinical diagnosis. The predictive quality of models to detect anaplasmosis at the same day the clinical diagnosis was better for models based on the activity than rumination data. Besides this, both sensors were capable to detect anaplasmosis with 3 days in advance. For early detection, the models based on rumination data performed better than those based on activity.

REFERENCES

- Cockburn, M. 2020. Review: Application and prospective discussion of machine learning for the management of dairy farms. *Animals*. doi:10.3390/ani10091690.
- Farrell, S., C. McKernan, T. Benson, C. Elliott, and M. Dean. 2021. Understanding farmers' and veterinarians' behavior in relation to antimicrobial use and resistance in dairy cattle: A systematic review. *J. Dairy Sci.* 104:4584–4603. doi:10.3168/JDS.2020-19614.
- Feitosa, F.L.F. 2008. Exame físico geral ou de rotina. *Semiologia Veterinária A arte do diagnóstico*.

- Hart, B.L. 1988. Biological basis of the behavior of sick animals. *Neurosci. Biobehav. Rev.* 12:123–137. doi:10.1016/S0149-7634(88)80004-6.
- Johnson, R.W. 2002. The concept of sickness behavior: A brief chronological account of four key discoveries. Page in *Veterinary Immunology and Immunopathology*.
- Kocan, K.M., J. De la Fuente, A.A. Guglielmone, and R.D. Meléndez. 2003. Antigens and Alternatives for Control of *Anaplasma marginale* Infection in Cattle. *Clin. Microbiol. Rev.* doi:10.1128/CMR.16.4.698-712.2003.
- Lardé, H., S. Dufour, M. Archambault, J. Massé, J.P. Roy, and D. Francoz. 2021. An observational cohort study on antimicrobial usage on dairy farms in Quebec, Canada. *J. Dairy Sci.* 104:1864–1880. doi:10.3168/JDS.2020-18848.
- Macmillan, K., M. Gobikrushanth, G. Plastow, and M.G. Colazo. 2020. Performance and optimization of an ear tag automated activity monitor for estrus prediction in dairy heifers. *Theriogenology* 155:197–204. doi:10.1016/J.THERIOGENOLOGY.2020.06.018.
- Maltz, E. 2020. Individual dairy cow management: Achievements, obstacles and prospects. *J. Dairy Res.* doi:10.1017/S0022029920000382.
- Miller, G.A., M. Mitchell, Z.E. Barker, K. Giebel, E.A. Codling, J.R. Amory, C. Michie, C. Davison, C. Tachtatzis, I. Andonovic, and C.A. Duthie. 2020. Using animal-mounted sensor technology and machine learning to predict time-to-calving in beef and dairy cows. *Animal*. doi:10.1017/S1751731119003380.
- Oliveira Júnior, B.R., B.F. Silper, M.N. Ribas, F.S. Machado, J.A.M. Lima, L.F.L. Cavalcanti, and S.G. Coelho. 2018. Short communication: Tick-borne disease is associated with changes in feeding behavior in automatically fed weaned dairy

calves. *J. Dairy Sci.* doi:10.3168/jds.2018-14637.

Rodrigues, J.P.P., L.G.R. Pereira, H. do C. Diniz Neto, M.C. Lombardi, C.F. de A.

Lage, S.G. Coelho, J.P. Sacramento, F.S. Machado, T.R. Tomich, R.M. Maurício, and M.M. Campos. 2019. Technical note: Evaluation of an automatic system for monitoring rumination time in weaning calves. *Livest. Sci.*

doi:10.1016/j.livsci.2018.11.017.

Silva, S.R., J.P. Araujo, C. Guedes, F. Silva, M. Almeida, J.L. Cerqueira, and K.

Salama. 2021. Precision Technologies to Address Dairy Cattle Welfare: Focus on Lameness, Mastitis and Body Condition. doi:10.3390/ani11082253.

Silvestre, B., J. Silveira, ... R.M.-T. and tick-borne, and U. 2016. 2016. Identification of a vertically transmitted strain from *Anaplasma marginale* (UFMG3): molecular and phylogenetic characterization, and evaluation of virulence. Elsevier.

Souza, R.S., M.F.S. Resende, L.C.A. Ferreira, R.S. Ferraz, M.V.V. Araújo, C.V. Bastos,

J.A.G. Silveira, T.F. Moreira, R.M. Meneses, A.U. Carvalho, F.O.P. Leme, and E.J.F. Filho. 2021. Monitoring bovine tick fever on a dairy farm: An economic proposal for rational use of medications. *J. Dairy Sci.* 104:5643–5651.

doi:10.3168/JDS.2020-19504.

USDA ERS - Milk Cost of Production Estimates. . Accessed November 9, 2020.

<https://www.ers.usda.gov/data-products/milk-cost-of-production-estimates/>.

Teixeira, V.A., Lana, A.M. Q., Bresolin, T., Tomich, T. R., Souza, G. M., Furlong, J.,

Rodrigues, J. P. P., Coelho, S. G., Gonçalves, L. C., Silveira, J. A. G., Ferreira, L. D., Facury Filho, E. J., Campos, M. M., Dorea, J. R. R. and Pereira, L. G. R. 2022.

Using activity and rumination data for early detection of anaplasmosis disease in dairy heifer calves. *J. Dairy Sci.* doi:

ACKNOWLEDGMENTS

The authors declare they have no conflicts of interest. The authors would like to thank the Brazilian Federal Agency for the Support and Evaluation of Graduate Education (CAPES), the National Council for Scientific and Technological Development (CNPq), the Minas Gerais Research Foundation (FAPEMIG), and the Brazilian Agricultural Research Corporation (Embrapa) for financing this study. The mention of commercial names or commercial products in this article is for the sole purpose of providing specific information and does not imply recommendation or endorsement by the authors or their institutions.

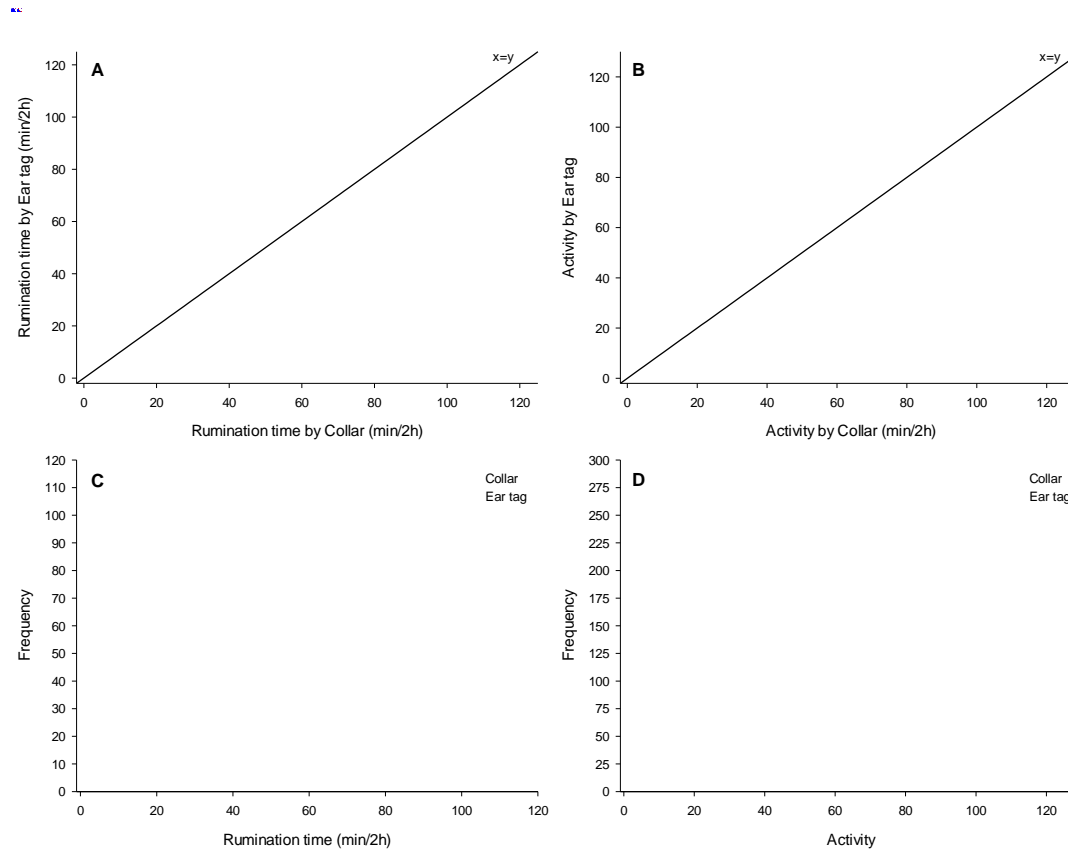


Figure 1. Scatter plots and histograms for contrasting rumination time and activity measured by Collars (Hr-Tag system) and Ear tags (eSense Flex system) in calves facing anaplasmosis.

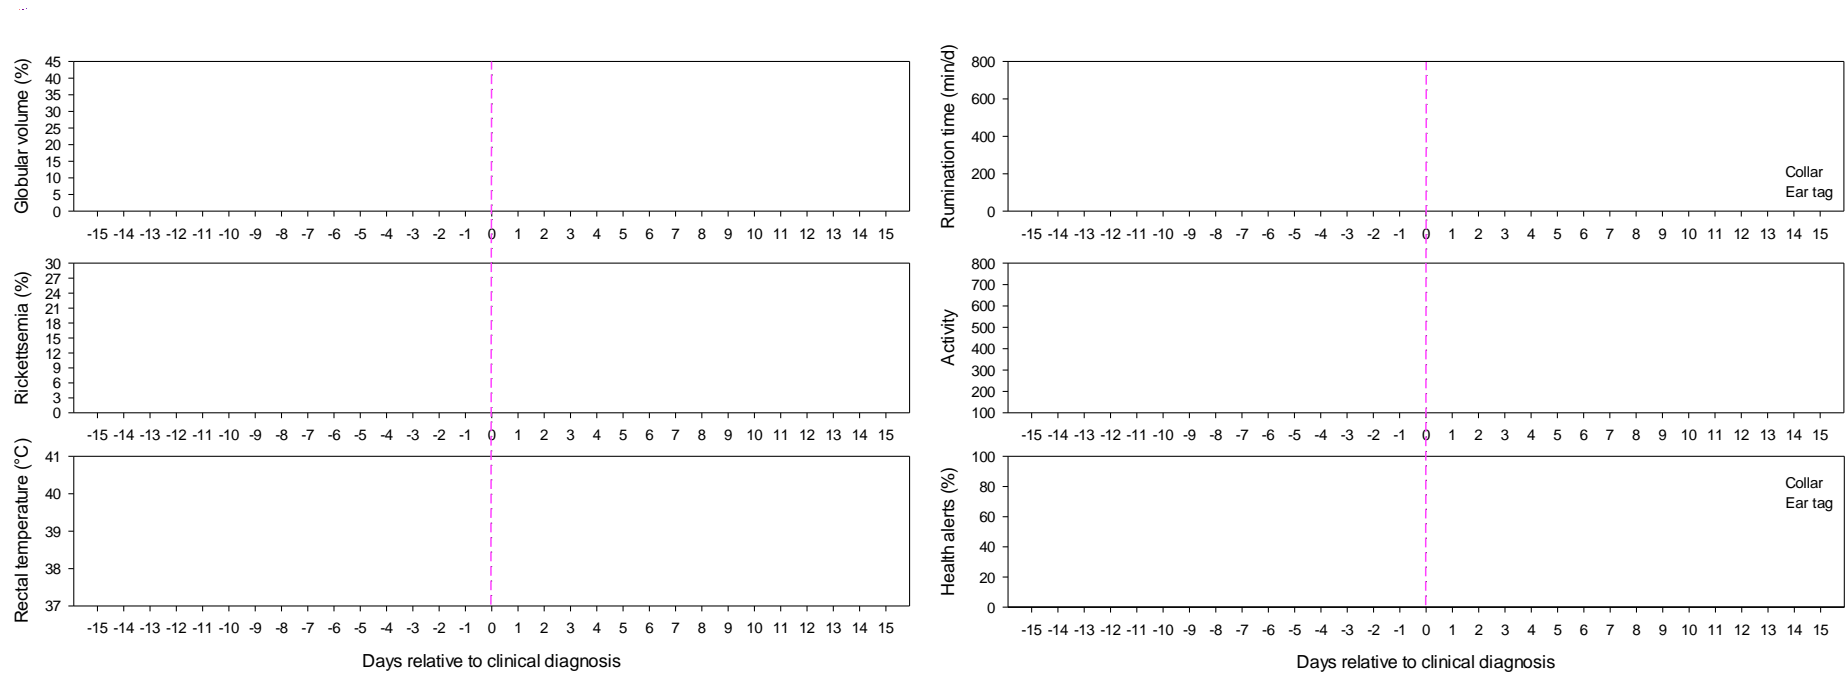


Figure 2. Description of clinical characteristics (A, globular volume; B, rickettsemia; C, rectal temperature) and Collar or Ear tag data (D, ruminant time; E, activity; F, health alerts) observed in calves as a function of days relative to clinical diagnosis (pink dotted line) of anaplasmosis.

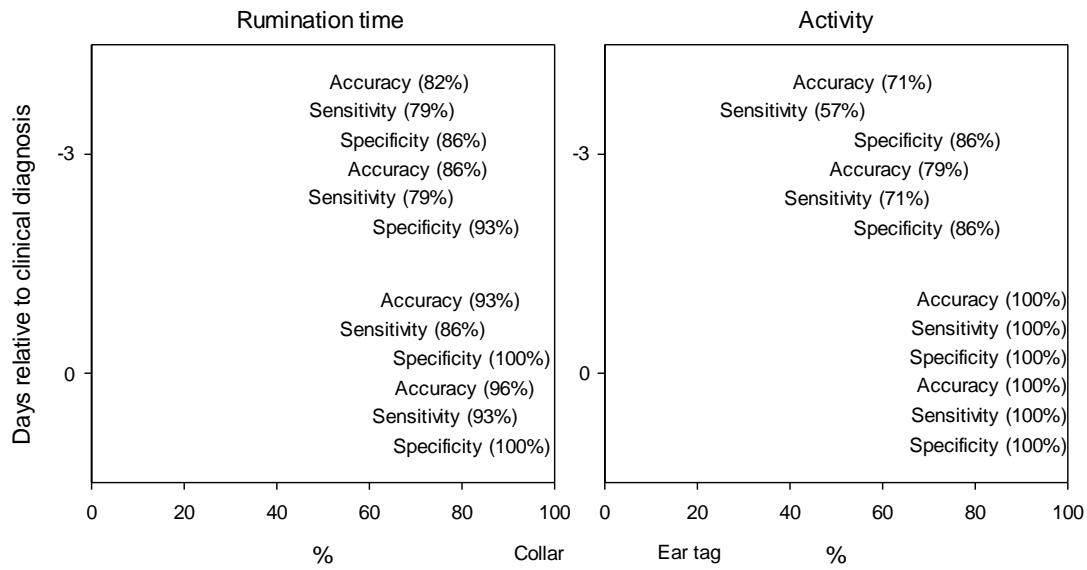


Figure 3. Accuracy, specificity, and sensitivity of different recurrent neural networks on detecting anaplasmosis in calves based on rumination time or activity data collected from Collars or Ear tags in days relative to clinical diagnosis.

4 CONSIDERAÇÕES FINAIS

Neste estudo conseguiu-se desenvolver tecnologias auxiliares no diagnóstico de anaplasmoses em bezerras leiteiras. Nossos resultados sugerem que o monitoramento do tempo de ruminação e do índice de atividade podem ser úteis para a detecção precoce dessa doença.

Esse fato pode agregar na recria das fazendas de leite de uma forma geral. Com a detecção precoce o animal poderá ter um melhor prognóstico, por ser tratado no momento ideal. O método proposto reduz o trabalho gasto com os procedimentos de diagnóstico, mão de obra e tratamento de suporte secundário (por exemplo, transfusão e terapia de fluido). Essa abordagem pode resultar em melhor bem-estar evitando o uso indiscriminado de antimicrobianos e a resistência antimicrobiana. Assim, a prescrição precoce pode melhorar a eficácia do tratamento e reduzir a morbidade e mortalidade por anaplasmoses.

Outro aspecto relevante nesta pesquisa é que o alto desempenho dos modelos de *machine learning* para prever anaplasmoses com base em dados dos sensores apontaram possibilidades de uso desses dispositivos como ferramentas auxiliares na terapia de anaplasmoses de precisão, otimizando economicamente e socialmente os sistemas de produção.

Nossos resultados foram obtidos em um experimento totalmente controlado, onde apenas a anaplasmoses afetou as variáveis avaliadas. Em condições de fazenda, existem vários patógenos distintos que podem causar problemas de saúde agindo concomitantemente. Portanto, estudos futuros nas condições das fazendas devem ser realizados para verificar a viabilidade do uso de dispositivos comerciais para identificar doenças específicas, como a anaplasmoses.

ANEXO A – Ciclo biológico da anaplasmosose




Figura 1 - Esquema do ciclo de desenvolvimento de *A. marginale* em bovinos e carrapatos. (Adaptado de KOCAN *et al.*, 2003).

ANEXO B – Artigos e resumos apresentados em eventos

1. Artigos aceitos

V. A. TEIXEIRA, A. M. Q. LANA, T. BRESOLIN, T. R. TOMICH, G. M. SOUZA, J. FURLONG, J. P. P. RODRIGUES, S. G. COELHO, L. C. GONÇALVES, J. A. G. SILVEIRA, L. D. FERREIRA, E. J. FACURY FILHO, M. M. CAMPOS, J. R. R. DOREA, L. G. R. PEREIRA. Using activity and rumination data for early detection of anaplasmosis disease in dairy heifer calves. Aceito na revista **Journal Dairy Science**.

SILVI, R.; PEREIRA, L. G. R.; PAIVA, C. A. V.; TOMICH, T. R.; TEIXEIRA, V. A.; SACRAMENTO, J. P.; FERREIRA, R. A. P.; COELHO, S. G.; MACHADO, F. S.; CAMPOS, M. M.; DÓREA, J. R. R. Adoption of Precision Technologies by Brazilian Dairy Farms: The Farmer's Perception. **Animals**, v. 11, p. 3488, 2021. <https://doi.org/10.3390/ani11123488>.

LUIZ, L. C.; TEIXEIRA, V. A.; CAMPOS, MARIANA. M.; PEREIRA, L.G.R.; TOMICH, T. R.; LEITE, J. L. B.; BELL, M. J. V.; ANJOS, V. C. Use of near-infrared spectroscopy with Fourier Transform (FT-NIR) to accompany the Bovine Parasitic Sadness process. **Brazilian Journal of Animal and Environmental Research**, v. 4, p. 1594-1605, 2021. <https://doi.org/10.34188/bjaerv4n2-003>.

2. Artigos Submetidos

V. A. TEIXEIRA, A. M. Q. LANA, G. M. SOUZA, J. P. P. RODRIGUES, T. R. TOMICH, J. FURLONG, T. BRESOLIN, J. A. G. SILVEIRA, L. D. FERREIRA, E. J. FACURY FILHO, M. M. CAMPOS, J. R. R. DOREA, L. G. R. PEREIRA. Developing predictive models for early detection of anaplasmosis based on data from collar or ear tag accelerometers in dairy heifer calves. Submetido na revista **JDS Communications**.

G. M. SOUZA, M. A. DANES, V. A. TEIXEIRA, T. BRESOLIN, T. R. TOMICH, J. P. P. RODRIGUES, M. M. CAMPOS, J. R. R. DOREA, L. G. R. PEREIRA. Use of a thermal sensor microchip and machine learning in the detection of changes in body temperature in dairy calves using anaplasmosis as a disease model. **Journal of Thermal Biology**.

3. Textos em jornais de notícias/revistas

TEIXEIRA, V. A.; DINIZ NETO, H. C.; CAMPOLINA, J. P.; NEVES, L. F. M.; COELHO, S. G. Nova era. Revista Leite Integral, p. 48 - 56, 10 abr. 2021.

TEIXEIRA, V. A.; DINIZ NETO, H. C.; LOMBARDI, M. C.; COELHO, S. G. Com precisão. Revista Leite Integral, Belo Horizonte, v. 136, p. 20 - 24, 07 jul. 2020.

4. Resumos publicados em anais de congressos

TEIXEIRA, V. A.; LANA, A. M. Q.; SOUZA, G. M.; TOMICH, T. R.; BRESOLIN, T.; RODRIGUES, J. P. P.; GONÇALVES, L. C.; COELHO, S. G.; FERREIRA, L. D.; SILVEIRA, J. A. G.; FACURY FILHO, E. J.; PEREIRA, L. G. R.; DÓREA, J. R. R. Early detection of anaplasmosis in dairy calves using activity and rumination data from commercial devices. In: ADSA 2021 Annual Meeting, 2021, Louisville. Abstracts of the 2021 American Dairy Science Association® Annual Meeting. Champaign: Journal of Dairy Science, 2021. v. 1. p. 219.

SILVI, R. R.; PEREIRA, L. G. R.; PAIVA, C. A. V.; TOMICH, T. R.; **TEIXEIRA, V. A.**; COELHO, S. G.; SACRAMENTO, J. P.; CAMPOS, M. M.; MACHADO, F. S.; FERREIRA, R. E. P.; DÓREA, J. R. R. Adoption of precision technologies by Brazilian dairy farms: The farmers' perception. In: ADSA 2021 Annual Meeting, 2021, Louisville. Abstracts of the 2021 American Dairy Science Association® Annual Meeting. Champaign: Journal of Dairy Science, 2021. v. 1. p. 274.

TEIXEIRA, V. A.; GOIS, G. C.; FERREIRA, L.D.; TOMICH, T.; BRESOLIN, T.; CAMPOS, M. M.; LANA, A. M. Q.; COELHO, S. G.; SILVEIRA, J. A. G.; CARVALHO, A. U.; FACURY FILHO, E. J.; PEREIRA, L. G. R.; DÓREA, João Ricardo Rebouças. Using activity and rumination data to early predict anaplasmosis in dairy calves. In: ADSA 2020 Annual Meeting, 2020, West Palm Beach. Abstracts of the 2020 American Dairy Science Association® Annual Meeting. Champaign: Journal of Dairy Science, 2020. v. 103. p. 285.

SOUZA, G. M.; **TEIXEIRA, V. A.**; RODRIGUES, J. P. P.; PEREIRA, L. G. R.; TOMICH, T. R.; DANES, M. A. C. CORRELATIONS BETWEEN RECTAL AND TAIL BASE TEMPERATURE OBTAINED BY THERMAL SENSOR IN DAIRY CALVES. In: 56° Reunião da Sociedade Brasileira de Zootecnia, 2021, Virtual. Anais da 56° Reunião da Sociedade Brasileira de Zootecnia, 2021. p. 399.