



**GLEICIELE MENDES DE SOUZA**

**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**

**LAVRAS - MG  
2022**

**GLEICIELE MENDES DE SOUZA**

**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**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Zootecnia, área de concentração em Nutrição e Produção de Ruminantes, para obtenção do título de Mestre.

Prof (a). Dr (a). Marina de Arruda Camargo Danes  
Orientadora

Dr. Luiz Gustavo Ribeiro Pereira  
Coorientador

**LAVRAS – MG  
2022**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Souza, Gleiciele Mendes de.

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 / Gleiciele Mendes de Souza. - 2022.

64 p.

Orientador (a): Marina Arruda Camargo Danes.

Coorientador (a): Luiz Gustavo Ribeiro Pereira.

Dissertação (mestrado acadêmico) - Universidade Federal de Lavras, 2022.

Bibliografia.

1. Sensor. 2. Inteligência artificial. 3. Pecuária de precisão. I. Danes, Marina Arruda Camargo. II. Pereira, Luiz Gustavo Ribeiro. III. Título.

**GLEICIELE MENDES DE SOUZA**

**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**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Zootecnia, área de concentração em Nutrição e Produção de Ruminantes, para obtenção do título de Mestre.

APROVADA em 27 de janeiro de 2022.

Dr (a). Marina de Arruda Camargo Danes, Universidade Federal de Lavras  
Dr. João Henrique Cardoso Costa, Universidade do Kentucky  
Dr. Luiz Gustavo Ribeiro Pereira, Embrapa Gado de Leite  
Dr. Tiago Bresolin, Universidade de Wisconsin

Prof (a). Dr (a). Marina de Arruda Camargo Danes  
Orientadora

Dr. Luiz Gustavo Ribeiro Pereira  
Coorientador

**LAVRAS – MG  
2022**

*A minha maior incentivadora, minha referência de fé, minha mãe Selma.*

*Ao meu exemplo de trabalho e honestidade, meu pai Ademar.*

*Ao meu irmão tão amado, Gleison.*

***Dedico.***

## **AGRADECIMENTOS**

Ao final deste ciclo, muita gratidão a Deus pela vida, pela saúde e por ser minha maior companhia.

Meu agradecimento mais profundo aos meus pais: minha mãe Selma, por me encorajar a acreditar nos meus sonhos, por embarcar comigo em todos os passos da jornada, por não medir esforços para me ajudar a chegar até aqui, e ao meu pai Ademar por me ensinar que o trabalho é valioso.

Ao meu irmão Gleison, por me apoiar e estar presente com nossos pais. Saiba que isso traz alento para minha caminhada.

Também presto minha gratidão ao querido Gilson, por ser uma inspiração diária de esforço e por todo incentivo durante esses anos. À Dona Vilma, por me ajudar em oração e por estar ao meu lado sendo otimista e me fazendo mais confiante.

Gostaria de expressar minha imensa gratidão a professora Marina Danes, por acreditar em mim, por sempre ter me concedido oportunidades de aprendizado ao longo dos anos e por trabalhar intensamente pelo meu crescimento.

Ao INPPAR, por ser minha casa e minha base de evolução.

Agradeço ao meu coorientador, Dr. Luiz Gustavo Ribeiro Pereira, pela oportunidade de trabalharmos juntos. Ao Dr. Thierry Tomich, por ter sido um pilar para execução deste projeto, por sua paciência e disposição em nos ajudar, e muito mais por tudo que aprendi com sua maneira de compreender a todos ao seu redor.

Aos funcionários da Embrapa Gado de Leite, que foram atenciosos e fundamentais para a condução deste trabalho. Aos estagiários e alunos de iniciação científica, que desempenharam um papel essencial na coleta de dados. A minha amiga Vanessa, pelo companheirismo e ajuda nos momentos mais desafiadores no campo.

Gostaria de agradecer também aos membros da banca examinadora que tão gentilmente aceitaram participar e colaborar com esta dissertação.

**MUITO OBRIGADA!**

## RESUMO

A mortalidade e a morbidez dos bezerros representam um custo significativo na criação e uma importante questão de bem-estar. A ferramenta de avaliação de saúde mais utilizada é a medida da temperatura corporal por meio de um termômetro retal, que pode ser trabalhosa, invasiva e estressante para o animal. Automatizar a medição de temperatura pode ser útil durante a ocorrência de doenças para identificação precoce e tratamento de animais. Os objetivos foram avaliar: *i*) dados de temperatura subcutânea coletados pelo microchip Bio-Thermo em comparação com a temperatura retal (TR) em bezerros expostos à anaplasmosse; e *ii*) a capacidade preditiva de *Recurrent Neural Networks* (RNN) e *Long Short-Term Memory* (LSTM) na identificação precoce da anaplasmosse. Adicionalmente, objetivamos investigar: *ii.a*) o efeito da duração da série temporal anterior ao diagnóstico da doença (5, 7 ou 10 dias consecutivos) no desempenho preditivo de RNN e LSTM; e *ii.b*) como a doença pode ser detectada precocemente em bezerros leiteiros (3 dias de antecedência ou apenas no dia do diagnóstico clínico). Vinte e quatro bezerros com  $132,4 \pm 13,9$  (média ± DP) dias de idade e  $146 \pm 23,3$  kg de peso corporal foram desafiadas com  $2 \times 10^7$  eritrócitos infectados com a cepa UFMG1 (GenBank no. EU676176) isolada de *Anaplasma marginale*. Após a inoculação, os animais foram monitorados diariamente pela avaliação do volume globular (VG). O menor valor de VG ( $14,8 \pm 2,6\%$ ) e a identificação de riquétsias em esfregaços sanguíneos foram utilizados como critérios para classificar um animal como doente (d0). Os dados de temperatura foram coletados diariamente por meio de identificação passiva por radiofrequência (RFID) e termômetro clínico. Duas séries temporais foram construídas incluindo a última sequência de -5, -7 ou -10 d precedendo d0 ou compreendendo uma sequência de 5, 7 ou 10 d selecionada aleatoriamente em uma janela de -50 a -15 d antes de d0 para garantir uma sequência de dias em que o VG foi considerado normal ( $32 \pm 2,3\%$ ). A validação cruzada *Leave-One-Animal-Out* (LOAOCV) foi usada para avaliar a qualidade da predição. A TR foi aumentada em resposta à doença, enquanto a temperatura medida pelo microchip apresentou apenas pequenas variações e a correlação entre essas duas temperaturas foi baixa ( $r = 0,35$ ,  $P < 0,001$ ). Em d0, para ambos os conjuntos de dados de temperatura (microchip e retal), a acurácia (ACC), sensibilidade (SEN) e especificidade (SPE) de RNN foi menor que LSTM. A ACC, SEN e SPE do LSTM na detecção de anaplasmosse em d0 usando dados de microchip variaram de 71 a 77%, 62 a 67% e 75 a 88%, respectivamente. Para os dados de TR em d0, ACC, SEN e SPE de LSTM variaram de 96 a 98%, 96 a 100% e 92 a 96%, respectivamente. O desempenho preditivo dos modelos não melhorou ao usar séries temporais mais longas. A ACC e SEN na predição de anaplasmosse até 3 dias antes do diagnóstico clínico foram superiores a 80% apenas para TR usando modelos RNN, confirmado que a TR permite a identificação precoce de alterações na temperatura corporal relacionadas à anaplasmosse. Já os modelos gerados com as temperaturas obtidas via microchip apresentaram qualidade preditiva inferior.

Palavras-chave: inteligência artificial, aprendizado de máquina, microchip, pecuária de precisão.

## ABSTRACT

Calf mortality and morbidity represent a significant cost in rearing and an important welfare issue. The most commonly used health assessment tool is the measure of body temperature using a rectal thermometer, which can be labor intensive, invasive and stressful for the animal. Automating temperature measurement can be useful during disease occurrence for early identification and treatment of animals. The objectives of this study were to evaluate: *i*) subcutaneous temperature data collected by the Bio-Thermo microchip compared to rectal temperature (RT) in calves exposed to anaplasmosis; and *ii*) the predictive ability of Recurrent Neural Networks (RNN) and Long Short-Term Memory (LSTM) in the early identification of anaplasmosis. Additionally, we aimed to investigate: *ii.a*) the effect of time series length prior to disease diagnosis (5, 7, or 10 consecutive days) on the predictive performance of RNN and LSTM; and *ii.b*) how early anaplasmosis disease can be detected in dairy calves (3 days in advance or just on the day of clinical diagnosis). Twenty-four Holstein calves with  $132.4 \pm 13.9$  (mean  $\pm$  SD) days of age and  $146 \pm 23.3$  kg of body weight were challenged with  $2 \times 10^7$  erythrocytes infected with the UFMG1 strain (GenBank no. EU676176) isolated from *Anaplasma marginale*. After inoculation, animals were monitored daily by assessing packed cell volume (PCV). The lowest PCV value ( $14.8 \pm 2.6\%$ ) and the identification of rickettsia on blood smears were used as criteria to classify an animal as sick (d0). Temperature data were collected daily using passive radiofrequency identification (RFID) and clinical thermometer. Two time series were built including last sequence of -5, -7 or -10 d preceding d0 or comprising a sequence of 5, 7 or 10 d randomly selected in a window from -50 to -15 d before d0 to ensure a sequence of days in which PCV was considered normal ( $32 \pm 2.3\%$ ). *Leave-One-Animal-Out* Cross-Validation (LOAOCV) was used to assess prediction quality. The RT was increased in response to the disease, while the temperature measured by the microchip showed only small variations and the correlation between these two temperatures was low ( $r = 0.35, P < 0.001$ ). On d0, for both temperature datasets (microchip and rectal), the precision (ACC), sensitivity (SEN) and specificity (SPE) of RNN was lower than LSTM. The ACC, SEN and SPE of LSTM in detecting anaplasmosis on d0 using microchip data ranged from 71 to 77%, 62 to 67% and 75 to 88%, respectively. For RT data on d0, ACC, SEN and SPE of LSTM ranged from 96 to 98%, 96 to 100% and 92 to 96%, respectively. The predictive performance of the models did not improve when using longer time series. The ACC and SEN in the prediction of anaplasmosis up to 3 days before clinical diagnosis were greater than 80% only for RT using RNN models, confirming that RT allows the early identification of anaplasmosis-related changes in body temperature. The models generated with the temperatures obtained via microchip showed lower predictive quality.

Keywords: artificial intelligence, machine learning, microchip, precision livestock.

**Use of a microchip with thermal sensor and machine learning to detect changes in body temperature in dairy calves using anaplasmosis as a disease model.**



Calf mortality and morbidity represent a significant cost in rearing and an important welfare issue.



Bovine anaplasmosis caused by *Anaplasma marginale* is endemic in some countries and is associated with large economic losses due to mortality, especially in young animals.

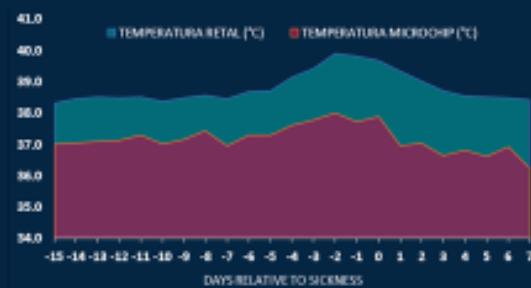
49%  
Incidence risk from birth to 180 days of age

60%  
Death in calves with clinical symptoms

The most commonly used health assessment tool is the measure of body temperature using a rectal thermometer, which can be labor intensive, invasive and stressful for the animal.



Can we detect changes in body temperature caused by an anaplasmosis challenge using a microchip implanted subcutaneously at the base of the tail?

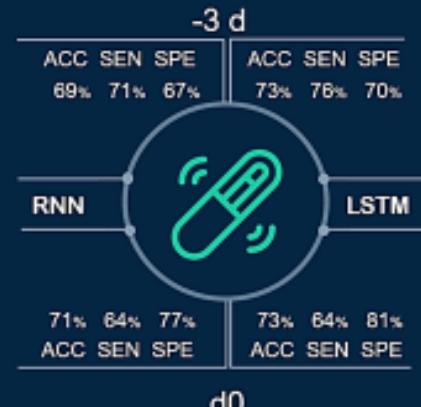


Twenty-four Holstein calves with 132 days of age were challenged with  $2 \times 10^7$  erythrocytes infected with a strain isolated from *Anaplasma marginale*.



After inoculation, animals were monitored by assessing packed cell volume (PCV).

The lowest PCV value was used as criteria to classify an animal as sick (d0).



## SUMÁRIO

PRIMEIRA SEÇÃO .....	9
1 INTRODUÇÃO.....	9
2 REFERENCIAL TEÓRICO.....	10
2.1 Anaplasmosse bovina .....	10
2.1.1 Transmissão .....	11
2.1.2 Ciclo da doença.....	11
2.1.3 Manifestações clínicas .....	12
2.1.4 Métodos de diagnóstico .....	13
2.1.6 Impactos econômicos.....	14
2.2 Adoção de tecnologias na atividade pecuária .....	14
2.2.1 Pecuária de precisão.....	14
2.2.2 Desafios atuais da produção pecuária e aplicação de recursos tecnológicos.....	15
2.2.3 Panorama do uso de sensores para gerenciamento de saúde animal .....	16
2.2.4 Fatores que influenciam a adoção de tecnologias na pecuária leiteira .....	18
2.3 Medições de temperatura em bovinos.....	19
2.3.1 Regulação da temperatura corporal .....	19
2.3.2 Medição de temperatura periférica em bovinos.....	20
2.4 Análise dos dados para gerenciamento de fazendas leiteiras.....	22
2.4.1 Inteligência artificial .....	23
2.4.2 Aprendizado de máquina ( <i>Machine Learning</i> ) .....	23
2.4.3 <i>Recurrent Neural Networks</i> (RNN) e <i>Long Short-Term Memory</i> (LSTM) .....	25
3 CONSIDERAÇÕES FINAIS .....	26
REFERÊNCIAS .....	27
SEGUNDA SEÇÃO – ARTIGO .....	39
Use of microchip with thermal sensor in the detection of changes in body temperature in dairy calves with anaplasmosis.....	39

## PRIMEIRA SEÇÃO

### 1 INTRODUÇÃO

A rentabilidade dos sistemas de criação animal é constantemente afetada pela ocorrência de doenças e por suas consequências nas perdas de produção. Identificar animais doentes envolve avaliações físicas regulares e, de modo geral, a mensuração da temperatura corporal é empregada como ferramenta auxiliar de diagnóstico. No entanto, existem gargalos associados a este protocolo de avaliação de saúde. O primeiro é que as fazendas tem apresentado um modelo de crescimento vertical, baseado no aumento do número de animais, de modo que a atenção individualizada diminui. Outro ponto importante é que para medir a temperatura corporal é necessário conter fisicamente o animal, o que torna a medição trabalhosa, além de impactar negativamente no bem-estar animal.

Dentre as doenças consideradas relevantes nos rebanhos tropicais, destaca-se a Tristeza Parasitária Bovina, cujos agentes etiológicos são *Anaplasma marginale*, *Babesia bovis* e *Babesia bigemina*. Em alguns países, a anaplasmosse bovina causada por *A. marginale* é endêmica, causando prejuízos diretos na produção devido a incidência e intensidade dos sinais clínicos, que podem acarretar em taxas de mortalidade em animais jovens de cerca de 60%. Por este motivo, a doença é notavelmente apontada nos relatórios de saúde animal.

Nas fazendas, normalmente o diagnóstico da anaplasmosse é realizado através da observação de sintomas clínicos, que incluem febre, anemia, perda de apetite e peso, desidratação, anorexia e letargia. Conjuntamente, protocolos de monitoramento da doença têm sido recomendados e se baseiam na avaliação do volume globular e esfregaços sanguíneos associados à mensuração de temperatura retal por termômetro clínico. Devido as dificuldades relativas à avaliação de saúde, torna-se fundamental desenvolver ferramentas e métodos de diagnóstico alternativos. Neste contexto, o uso de sensores associado ao emprego de inteligência artificial pode ser uma alternativa para identificar animais doentes, direcionar estratégias de tratamento precoce de modo criterioso e reduzir as taxas de mortalidade nas propriedades.

Portanto, uma melhor compreensão da anaplasmosse, dos mecanismos associados ao uso de sensores na criação animal e como eles respondem a mudanças em padrões fisiológicos, ajudará no desenvolvimento de alternativas de diagnóstico e facilitará a predição da ocorrência da doença. Assim, os principais objetivos desta revisão foram explorar o conhecimento sobre anaplasmosse, uso de sensores, regulação de temperatura corporal e inteligência artificial.

## 2 REFERENCIAL TEÓRICO

### 2.1 Anaplasmosose bovina

A anaplasmosose faz parte de um complexo de doenças hemolíticas, denominado Tristeza Parasitária Bovina (TPB) que é causador de perdas significativas na pecuária (SACCO *et al.*, 2001). É uma doença ocasionada por microrganismo intraeritrocitário 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. marginale* pode ser identificada microscopicamente por meio da visualização de pontos ou corpúsculos de inclusão às margens das hemácias. Esses pontos marginais e a ausência de citoplasma deram origem ao nome da espécie. Igualmente, quando os corpúsculos são observados no centro dos eritrócitos, caracterizam a espécie *A. centrale* (KOCAN *et al.*, 2003).

Sob a ótica estrutural, há duas formas de *A. marginale*: uma apresenta os corpúsculos de inclusão com presença de apêndice (KOCAN *et al.*, 1984) e outra é caracterizada pela ausência de apêndice (SMITH *et al.*, 1986). Tal característica morfológica é descrita como filamento, e tem função de alça e configurações de cometas formados por lâminas interconectadas de constituição protéica (KOCAN *et al.*, 1984).

Esta estrutura proporciona grande diversidade antigênica devido à capacidade de gerar proteção. A distinção entre elas pode ser realizada com base nas propriedades de transmissão por carapatos (WICKWIRE *et al.*, 1987), morfologia (KOCAN *et al.*, 1984) e capacidade de reação a anticorpos monoclonais (WAGHELA *et al.*, 2000). No trabalho de Coelho (2007), 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.

*A. marginale* tem distribuição cosmopolita, com maior prevalência em regiões de países tropicais e subtropicais como o Brasil, bem como 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 maior parte dos países da América Latina é considerada enzoótica, com exceção de áreas de deserto ou montanhas como os Andes (GUGLIELMONE, 1995).

### **2.1.1 Transmissão**

A infecção de bovinos por *A. marginale* pode ocorrer pelas vias mecânica, vertical e biológica. A transmissão mecânica acontece pela picada de insetos hematófagos ou pelo contato com fômites contaminados com sangue, como agulhas, brincos de identificação individual, tatuadores, argolas nasais e utensílios cirúrgicos (AUBRY; GEALE, 2011; KOCAN *et al.*, 2003). Neste caso, as hemárias infectadas passam de um animal para o outro sem que ocorra a fase de multiplicação no vetor.

A transmissão vertical (transplacentária) ocorre quando o animal gestante infectado com *A. marginale* contamina o feto durante a gestação (AUBRY; GEALE, 2011). No período de transição (três semanas pré e pós-parto) ocorrem modificações fisiológicas e hormonais, bem como alterações na ingestão de alimentos, no equilíbrio hormonal, e uma consequente imunossupressão (DIVERS; PEEK, 2008). Esta imunossupressão transitória é uma das prováveis fomentadoras da via transplacentária (SILVA; FONSECA, 2014).

A transmissão biológica é a via predominante de transmissão da anaplasmosose e é particularmente reconhecida pela participação dos carapatos em uma relação de parasitismo com os bovinos, na qual o vetor ingere eritrócitos infectados pela rickétsia e se infecta (MELO, 2018). Mais de vinte espécies de carapatos são exemplificadas como vetores biológicos de *A. marginale* em todo o mundo (MELO, 2018). O gênero considerado como o principal vetor da anaplasmosose no Brasil é *Rhipicephalus* spp., (RIBEIRO; LIMA, 1996) e é representado pelo carapato dos bovinos *Rhipicephalus (Boophilus) microplus*.

Em algumas regiões da África, América Central e do Sul não há população estável de carapatos - *Rhipicephalus (Boophilus) microplus* - transmissores da anaplasmosose. Assim, a picada de dípteros hematófagos dos gêneros *Tabanus* e *Stomoxys* e os mosquitos dos gêneros *Culex* e *Aedes* (FOIL, 1989) são determinantes da propagação da rickétsia (CORONADO, 2001).

### **2.1.2 Ciclo da doença**

O desenvolvimento da anaplasmosose envolve os vetores carapato, mosca ou mosquito e o hospedeiro bovino. Quando o hospedeiro é infectado com *A. marginale* e torna-se a via de contaminação do vetor, o ciclo biológico começa. Os eritrócitos infectados são ingeridos pelo vetor, alcançam o lúmen intestinal, a rickétsia se multiplica e atinge diversos tecidos, incluindo as glândulas salivares. Mais tarde, o vetor contamina outro hospedeiro a partir da inoculação

da saliva como preparação do local para alimentação, e o ciclo pode ser reiniciado (MELO, 2018).

Ao alcançarem a corrente sanguínea dos bovinos, as formas infectantes de *A. marginale* fazem com que os eritrócitos iniciem a rofecitose, uma invaginação da membrana plasmática das hemárias formando um vacúolo parasítóforo. No interior dos vacúolos, os corpúsculos iniciais se proliferam e deixam o glóbulo vermelho sem provocar ruptura da membrana celular, que caracteriza a rofecitose reversa. A passagem de uma hemácia para outra pode ocorrer por pontes intercelulares recomeçando o ciclo de multiplicação (RIBEIRO; PASSOS, 2002).

Os animais que superam a fase aguda da doença desenvolvem infecções permanentes, definidas por rickéttsemias baixas e cíclicas a cada 10-14 dias (KOCAN *et al.*, 2003) ou até 5 semanas (KIESER *et al.*, 1990), constituindo reservatórios de *A. marginale* para transmissão mecânica e biológica (BRITO *et al.*, 2010).

### **2.1.3 Manifestações clínicas**

O avanço da doença pode ser segmentado didaticamente em quatro fases: período de incubação ou pré-patente, fase de desenvolvimento ou de patência, período convalescente e fase de portador (RICHEY, 1993). A primeira fase (período pré-patente) representa o tempo entre a infecção com rickéttssia na hemácia até a primeira constatação do eritrócito parasitado nos esfregaços sanguíneos. Tem duração de 7 a 60 dias (média de 28 dias) e pode apresentar variação de acordo com a população de organismos na dose infectante (KOCAN *et al.*, 2003).

A segunda fase (período de patência) tem duração média de 15 dias, iniciando com a visualização das primeiras hemárias infectadas e avançando até o alcance dos menores valores de hematocrito do animal parasitado (VIDOTTO; MARANA, 2001). Os eritrócitos infectados e não infectados são fagocitados pelas células reticuloendoteliais esplênicas, que configura um quadro de anemia branda a grave e icterícia e hemoglobinúria (KOCAN *et al.*, 2003). A anemia é acompanhada por sintomas que podem ocasionar o óbito do animal: apatia, anorexia, mucosas pálidas ou ictéricas, hipertermia, dispneia, taquicardia, perda de peso, fadiga, sialorreia, diarreia e poliúria. A fase de patência denota valores de parasitemia elevados, mas que reduzem após o desenvolvimento da imunidade (MARANA *et al.*, 2009).

No período convalescente é percebida a recuperação do animal, que retoma o volume globular (VG) e expressa melhora na sintomatologia clínica geral (KOCAN *et al.*, 2003). Após esse período, o hospedeiro se torna permanentemente infectado e passa a ser reconhecido como portador. Nessa fase, os níveis de rickéttsemia são baixos, variando de 102 a 107 eritrócitos

infetados/mL sanguíneo, permanecem desta forma por meses ou anos e conferem resistência a novos quadros clínicos (BROWN, 2012).

Os sinais clínicos superagudos são raros e culminam na morte rápida do animal. A forma branda da patologia acomete animais jovens de até um ano de idade, e os resultados de uma infecção se tornam mais rigorosos conforme a idade avança. À vista disso, animais adultos que não foram expostos ao agente infeccioso previamente, de modo geral, apresentam quadros superagudos à fatais (RISTIC, 1968).

Na forma aguda da doença, a rickéttsemia aumenta rapidamente e o VG reduz de 30 a 50% em relação ao valor normal (BROWN, 2012). Nos episódios de maior intensidade pode ocorrer hipóxia, taquipneia e taquicardia (COELHO, 2007; LASMAR, 2012), mucosas hipocoradas, icterícia sem hemoglobinemia e sem hemoglobinúria. Conjuntamente, quadros de febre, depressão, anorexia, desidratação, fraqueza, aborto e diminuição da produção de leite podem ser observados (COELHO, 2007; WANER *et al.*, 2010).

Inicialmente a sintomatologia clínica da doença é discreta, aumentando de modo proporcional à intensidade da anemia, no entanto esta última não está associada diretamente à rickéttsemia. Desta forma, é possível que outras questões estejam relacionadas à fagocitose das hemárias (GIARDINA *et al.*, 1993). Durante o ciclo de *A. marginale* ocorrem alterações morfológicas e bioquímicas na membrana celular das hemárias infectadas que induzem uma resposta imune humoral, na qual os anticorpos se fixam às células 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 normal e repercute em anemia. No decurso da fase aguda da anaplasmosse, os menores valores de VG podem ser notados de 1 a 6 dias após o pico de parasitemia (GIARDINA *et al.*, 1993), o que destaca o envolvimento dos anticorpos na patogenia.

#### **2.1.4 Métodos de diagnóstico**

A infecção por *A. marginale* da forma aguda geralmente é diagnosticada de forma direta por microscopia, a partir da detecção de corpúsculos intraeritrocitários marginais de inclusões de *A. marginale* em esfregaços sanguíneos corados com Giemsa (AUBRY; GEALE; 2011, VIDOTTO; MARANA, 2001) ou pelo método de Romanowsky. Todavia, esses métodos só identificam proporções maiores que 106 hemárias infectadas por mL de sangue (GALE *et al.*, 1996), impossibilitando encontrar animais com baixa rickéttsemia (MELO, 2018).

Os métodos indiretos, chamados de sorológicos, determinam anticorpos específicos contra *Anaplasma* spp. Dentre eles estão os ensaios imunoabsorventes ligados a enzimas (ELISA) e a reação de imunofluorescência indireta (RIFI) (AUBRY; GEALE, 2011).

Na rotina laboratorial outras técnicas de diagnóstico são bastante utilizadas na identificação de *Anaplasma* spp., como a reação de polimerase em cadeia (PCR), suficientemente sensível e aplicada na diferenciação de animais naturalmente infectados com *A. marginale* e animais vacinados com *A. centrale* (MOLAD *et al.*, 2006).

No campo, a identificação de anaplasmosse normalmente ocorre mediante o reconhecimento dos sinais clínicos. No entanto, eles só aparecem alguns dias após o pico da rickéttsemia, quando a anemia já é intensa (COELHO, 2007) e o animal apresenta-se debilitado e a taxa de cura pode ser baixa.

### **2.1.6 Impactos econômicos**

As hemoparasitoses constituem fator de risco aos animais susceptíveis e causam danos econômicos aos sistemas de produção (MELO, 2018). De modo geral, as variáveis mais associadas a estes prejuízos são a perda de peso, redução na produção de leite, aborto e custos com o tratamento e controle da doença (KOCAN *et al.*, 2003). Além disso, a anaplasmosse pode ser um entrave para o melhoramento genético e para reposição de animais jovens dos rebanhos em países tropicais. Isso se traduz em importante restrição econômica da doença, principalmente porque bovinos importados de regiões temperadas são susceptíveis às doenças transmitidas por carapatos e comumente não resistem às infecções (MELÉNDEZ, 2005).

Poucos estudos determinaram a perda anual exata causada pela anaplasmosse. Na América Latina, os prejuízos anuais relatados são de US\$ 800 a 875 milhões, enquanto nos Estados Unidos, as perdas na pecuária de corte foram estimadas em torno de US\$ 300 milhões (KOCAN *et al.*, 2003).

## **2.2 Adoção de tecnologias na atividade pecuária**

### **2.2.1 Pecuária de precisão**

Os sistemas de produção pecuária em todo o mundo têm intensificado sua produtividade por animal nos últimos anos. Intensificar implica em preocupações sociais que se referem a abordagem dos consumidores sobre segurança alimentar, sustentabilidade, bem-estar animal e

aspectos de saúde animal e humana (CHARLTON; RUTTER, 2017; WINTER *et al.*, 2017). Considerando essas preocupações, foi demonstrado que um sistema de produção intensivo, representado por elevado nível de organização e eficiência, contribui para a sustentabilidade (LOVARELLI *et al.*, 2019; ZUCALI *et al.*, 2020).

Melhorias de produção geralmente resultam em contraposição com diversas questões, como intensificação versus biodiversidade (ELDESOUKY *et al.*, 2018; TICHIT *et al.*, 2011). O desenvolvimento da agricultura e pecuária de precisão tem impactos positivos no sistema e essa intensificação sustentável do setor é um dos desafios mais importantes para o futuro próximo (LINDBLOM *et al.*, 2017; LOVARELLI *et al.*, 2017).

A aplicação do conceito de precisão demanda o monitoramento do comportamento, bem-estar e produtividade dos animais visando a produção sustentável (FOURNEL *et al.*, 2017). O emprego de sensores permite a coleta automática de grande volume de dados, assim o processamento e análise demanda recursos estatísticos avançados para o desenvolvimento de modelos direcionados pelos dados, capazes de interpretar e prever o comportamento, condições de saúde e bem-estar dos animais.

Bell *et al.*, (2011) e Hou *et al.*, (2015) estudaram o efeito da tecnologia da informação sobre a possível redução das emissões poluentes ao ar, solo e água, enquanto Dominiak e Kristensen (2017) revisaram os sensores disponíveis apropriados para gerenciar questões ambientais, de saúde e bem-estar e sua aplicação para a melhoria dos níveis de desempenho animal.

### **2.2.2 Desafios atuais da produção pecuária e aplicação de recursos tecnológicos**

A maioria dos países em todo o mundo tem vivenciado uma redução no número de fazendas pequenas, e uma expansão de grandes fazendas caracterizadas pela criação de um grande número de animais (FOURNEL *et al.*, 2017). As propriedades pequenas estão enfrentando dificuldades para se manter no mercado, principalmente devido a economia de escala (CAVALIERE; VENTURA, 2018). Diante disso surge um entrave: ao passo que a fazenda e o número de animais aumentam, a atenção individualizada aos animais diminui (MEEN *et al.*, 2015).

Neste cenário, os recursos tecnológicos são promissores para alcançar a criação eficiente e sustentável de animais, ou seja, a pecuária de precisão tem potencial para auxiliar os produtores na criação de animais em boas condições, bem como produzir alimentos de forma segura e com mínimo impacto ambiental (BERCKMANS; GUARINO, 2017). A eficiência no

uso de alimentos e nutrientes (UWIZEYE *et al.*, 2016), o alerta precoce de doenças, a redução de emissões de poluentes para o ar, solo e água, simbolizam extensos benefícios ambientais. Ademais, o monitoramento e capacidade preditiva que a pecuária de precisão oferece, apoiam as decisões direcionadas por dados na fazenda, que são cada vez mais importantes para atender as necessidades alimentares e sociais coletivas (CHARLTON; RUTTER, 2017; ZUCALI *et al.*, 2020).

Ambos os sistemas, criação intensiva em áreas reduzidas ou a pecuária extensiva produzindo animais em grandes espaços, apresentam gargalos relacionados a mão de obra para o monitoramento, pois na produção intensiva, é impraticável controlar todos os animais criados, enquanto no sistema extensivo, o grande espaço disponível gera limitações no controle de localização dos animais (BERCKMANS; GUARINO, 2017). Deste modo, a pecuária de precisão mostra-se como a solução ou componente da solução para essas complexidades (ARCIDIACONO *et al.*, 2018).

As principais dificuldades associadas à tecnologia e coleta de dados correspondem a inúmeras informações de diferentes fontes que nem sempre se comunicam entre si, e a análise desse grande banco de dados que deve ser eficaz, objetiva e clara para o produtor (VAN HERTEM *et al.*, 2017). Para este último aspecto, é importante destacar que a vantagem da pecuária de precisão está ligada ao apoio ao produtor e não à substituição do mesmo na tomada de decisão (BAHLO *et al.*, 2019).

Conforme exposto, produções sustentáveis podem ser alcançadas particularmente com inovações e suporte de tecnologia (BERCKMANS; GUARINO, 2017) que permitem detecção rápida e precoce de doenças, contribuem para quantificar as emissões de poluentes ambientais e otimizam as produções. Também, à medida que os animais são monitorados com regularidade, torna-se mais fácil prever comportamentos inesperados e dar peso adequado às anomalias (BISHOP *et al.*, 2019; MEUNIER *et al.*, 2018).

### **2.2.3 Panorama do uso de sensores para gerenciamento de saúde animal**

O uso de biossensores está se tornando cada vez mais indispensável para a gestão da saúde animal. Esses dispositivos, se desenvolvidos e usados de forma correta, podem permitir o diagnóstico precoce e automático de doenças nos animais, diminuindo as perdas econômicas. Neste sentido, tais dispositivos são especialmente úteis para o gado leiteiro pois podem fornecer dados sobre o estado físico dos animais, bem como suas alterações.

Novas tecnologias vestíveis estão sendo personalizadas para atender às necessidades de animais de criação ou de estimação, permitindo mantê-los mais saudáveis e possibilitando que o trabalho humano seja feito em menos tempo. Desta maneira, o emprego de sensores pode ser útil para medir a temperatura corporal (JENSEN-JAROLIM; FLASCHBERGER, 2016; SELLIER *et al.*, 2014; NOGAMI *et al.*, 2014), avaliar o comportamento e o movimento (SA *et al.*, 2015; VAN NUFFEL *et al.*, 2015), detectar o estresse (LEE *et al.*, 2015), detectar constituintes do suor (GARCIA *et al.*, 2016; GLENNON *et al.*, 2016; HEIKENFELD, 2016), realizar análise de som (BERCKMANS *et al.*, 2015; BROOM; FRASER, 2015; FERRARI *et al.*, 2008), detectar pH (KIM *et al.*, 2016), diagnosticar doenças (RUTTEN *et al.*, 2013) e detectar a presença de vírus e patógenos (AYYAR; ARORA, 2013; MUNGROO *et al.*, 2016; KIZIL *et al.*, 2015). Muitas vezes os modelos preditivos desenvolvidos com base em dados de sensores permitem o diagnóstico precoce e automático de doenças, assim, podem direcionar o tratamento e prevenir a morte de animais.

Mais do que fornecer informações relevantes sobre a saúde animal, o monitoramento da fazenda também pode ser integrado a telefones celulares e equipamentos portáteis. Muitas funcionalidades foram desenvolvidas em dispositivos portáteis para reduzir a tarefa de registrar dados manualmente (FUKATSU; NANSEKI, 2011). Além disso, os dados são transferidos para servidores centrais de forma autônoma, possibilitando que as informações finais sejam facilmente visualizadas em um computador de escritório, o que torna a tecnologia mais acessível aos produtores.

Fornecer produtos de origem animal seguros e de boa qualidade para atender ao crescimento da demanda global por alimentos é um desafio e gera ainda mais preocupações relacionadas à saúde animal (IVANOV *et al.*, 2015). Dispositivos que possam ser integrados ao corpo do animal, implantados sob a pele, ou que permaneçam no trato digestivo, fornecem informações úteis em relação ao seu comportamento e condições de saúde. Assim, presume-se que sejam usados para a intervenção veterinária precoce, bem como para detecção de demandas especiais, como aquecimento ou resfriamento (HARROP, 2016).

Para atender aos desafios atuais de observação, diagnóstico e controle de doenças em animais de criação, é indiscutível que ocorra uma mudança dos padrões de identificação das doenças. Essa transição envolve, por exemplo, substituir o envio de amostras das fazendas para os laboratórios por um diagnóstico rápido na própria fazenda. A organização mundial de saúde animal (OIE) advertiu que as doenças zoonóticas de animais de criação podem ter impactos danosos na saúde pública se houver disseminação para fora das fazendas, e a indústria pecuária encontra-se sob forte pressão para melhorar seus protocolos de biossegurança, rastreabilidade

e bem-estar dos animais. À vista disso, produtores rurais, indústrias e agências de inspeção de segurança alimentar estão se empenhando em obter novas ferramentas e tecnologias para permitir o acompanhamento rápido e em tempo real de doenças (NEETHIRAJAN, 2017).

#### **2.2.4 Fatores que influenciam a adoção de tecnologias na pecuária leiteira**

À medida que as tecnologias evoluíram, novos parâmetros e métodos de monitoramento foram criados. Como resultado, os produtores de leite encontram muitas opções no tipo de ferramenta de precisão que eles podem implementar e muitos simplesmente desconhecem as tecnologias atualmente disponíveis.

A escolha de comprar e implementar uma tecnologia de precisão representa um investimento expressivo para os produtores, que muitas vezes enfrentam o desafio de optar por uma tecnologia que atenda às suas necessidades por vários anos, e por este motivo seja mais onerosa. Neste sentido, muitos fatores como a escala financeira devem ser levados em conta (BORCHERS; BEWLEY, 2015).

Um grande motivador para um produtor investir em tecnologia é a redução de tarefas que exigiam empenho dos colaboradores, menor custo de mão de obra, maior facilidade no manejo diário do rebanho e aumento de produtividade. No estudo de Steeneveld e Hogeveen (2015), fazendas que adotaram algum tipo de tecnologia de precisão alcançaram uma redução de até 23% das horas trabalhadas por vaca/semana, comparadas àquelas que não faziam uso de sistemas de monitoramento por sensores. Um estudo recente de Stone *et al.*, (2020) apontou aspectos fundamentais para a decisão do produtor em aderir às tecnologias de precisão, dentre eles a compatibilidade com a fazenda, o custo-benefício da tecnologia/vantagem relativa, complexidade e possibilidade de período de teste na propriedade.

Benaissa *et al.*, (2019) abordaram um aspecto relevante sobre a vida útil dos sensores, que influencia a decisão de aquisição: seu tempo de utilização e baterias. Na prática, os sensores usam baterias muito pequenas com baixos recursos de processamento e armazenamento. Além disso, estas baterias precisam operar de forma adequada e autônoma por longos períodos de tempo (anos ou enquanto durar a vida de um animal, como o bolus, por exemplo) sem serem recarregadas, substituídas ou agredidas pelo meio. Vários elementos podem afetar o consumo de energia, por exemplo, taxa de amostragem, taxa de transmissão e métodos de roteamento, e desta forma, o aproveitamento do dispositivo pode ser reduzido.

As tecnologias de monitoramento precisam ser uma solução para um problema, não uma solução à procura de uma aplicação. Por exemplo, observar as vacas em busca de sinais de estro

diariamente é tarefa que pode ser confiada a ferramentas tecnológicas para que os produtores usem o tempo para avaliações, decisões e até mesmo para implementar mudanças de manejo que melhorem o rebanho. Na pesquisa de Mayo *et al.*, 2019, seis ferramentas foram testadas e todas foram capazes de detectar o estro de modo tão eficaz quanto a observação visual. Ainda, quatro delas detectaram corretamente 15 a 35% mais vacas do que a observação visual realizada quatro vezes ao dia. Borchers e Bewley (2015) relataram que compreender o processo pelo qual os produtores se conscientizam da necessidade de adotarem novas tecnologias é de interesse dos setores público e privado, como forma de direcionamento específico de pesquisas e desenvolvimento de ferramentas inteligentes que auxiliem na gestão dos rebanhos.

### **2.3 Medições de temperatura em bovinos**

#### **2.3.1 Regulação da temperatura corporal**

Os animais homeotérmicos apresentam mecanismos reguladores de temperatura autônomos e comportamentais. A produção de calor derivada dos processos metabólicos deve ser trocada dentro de um corpo (pelas membranas celulares e vasculares), e entre um corpo e seu ambiente. Sob condições termoneutras, os mamíferos mantêm esses processos em um equilíbrio decorrente da contínua produção metabólica de calor e do transporte convectivo de calor através dos tecidos (TAYLOR *et al.*, 2014).

Condições ambientais que demandam o mínimo empenho metabólico para manter a temperatura interna estável, sendo observada apenas a alteração da temperatura da pele e com perdas de calor por evaporação irrisórias, caracterizam a zona de conforto térmico (CURTIS, 1983). Durante os períodos de excesso de calor ou frio, os mecanismos homeostáticos do corpo são estimulados para restabelecer o estado térmico ou para regulá-lo dentro de limites aceitáveis fisiologicamente (WERNER *et al.*, 2008).

Tendo em conta a exposição ao calor, foram observadas reações fisiológicas, como o aumento do fluxo de sangue através da pele (dilatação dos vasos sanguíneos), estímulo das glândulas sudoríparas e um aumento da perda de calor por evaporação (BARNES *et al.*, 2004; CONNOLLY; WORTHLEY, 2000). Já os impulsos causados pelo frio, incluindo a vasoconstricção cutânea que leva a um aumento da temperatura central, minimizam o gradiente corpo-ambiente (TAYLOR *et al.*, 2014).

O estabelecimento de reações termorreguladoras comportamentais está relacionado à percepção de variações na temperatura envolvendo o córtex cerebral. Essas alterações de

comportamento permitem que os animais lidem com temperaturas ambiente altas ou baixas (ANGRECKA; HERBUT, 2017; HERBUT; ANGRECKA, 2018; REFINETTI; HORVATH, 1989).

A temperatura corporal é definida pelas temperaturas interna e externa. A temperatura interna determina as condições térmicas vitais nas regiões da cavidade abdominal, caixa torácica e crânio, ao passo que a temperatura externa se refere à superfície da pele, tecido subcutâneo e muscular (GAGGE *et al.*, 1986). Os mecanismos termorreguladores possibilitam que a temperatura central do corpo se mantenha em um nível estável, em contrapartida, a temperatura superficial sofre grande flutuação. Alguns órgãos são tidos como fontes de calor, pois apresentam maior taxa metabólica (cérebro, coração, fígado, rins), enquanto a pele, o tecido adiposo e os ossos são menos ativos, podendo desempenhar papel de dissipadores de calor de curto prazo.

As funções biológicas de grande importância, como alimentação e digestão, têm grandes efeitos na temperatura (MADER *et al.*, 2010; MONTANHOLI *et al.*, 2010). A temperatura corporal também é alterada quando os animais são submetidos a situações de estresse ou dor, conforme observado por McCafferty (2013) em pássaros e Stewart *et al.* (2007, 2008 e 2010) em bezerros, que atribuíram esta modificação as alterações no fluxo sanguíneo mediadas pela regulação simpática.

Em síntese, muitos mecanismos envolvidos no enfrentamento de agressores patogênicos, durante uma infecção sistêmica, ou mesmo localmente logo que haja inflamação do tecido, levam à hipertermia. Portanto, a temperatura corporal é um critério de grande interesse na produção animal e o monitoramento sistemático pode permitir a detecção precoce e o tratamento de doenças economicamente importantes, como a febre aftosa (RAINWATER-LOVETT *et al.*, 2009), doença respiratória bovina (SCHAEFER *et al.*, 2012) e tristeza parasitária bovina (MELO, 2018).

### **2.3.2 Medição de temperatura periférica em bovinos**

Considerando o metabolismo local distinto, a oscilação do fluxo sanguíneo, a condução no tecido e a constante redistribuição de energia térmica, torna-se claro que áreas individuais do corpo são caracterizadas por diferentes temperaturas (TAYLOR *et al.*, 2014). Sellier *et al.* (2014) conduziu uma revisão de literatura sobre os métodos para mensurar com precisão a temperatura corporal do animal. Três zonas do corpo nas quais a temperatura pode ser medida

foram definidas: temperatura corporal central, temperatura médio-periférica e temperatura superficial.

Atualmente, câmeras com tecnologia infravermelho têm sido utilizadas nos estudos com animais. Estes dispositivos possibilitam avaliar a distribuição de temperatura ou oscilações na superfície corporal. Por ser um método não invasivo, sem contato direto com o animal, o equipamento é especialmente útil na medição térmica em animais de grande porte. O olho, úbere e a base da orelha são caracterizados por apresentarem temperaturas mais elevadas do que outras localizações do corpo (POIKALAINEN *et al.*, 2012; SOERENSEN; PEDERSEN, 2015).

Diversos estudos sobre detecção de mastite avaliaram a temperatura do úbere (BERRY *et al.*, 2003; PEZESHKI *et al.*, 2011). Em alguns desses estudos, realizou-se uma infecção experimental dos quartos mamários individuais com bactérias patogênicas. Em contrapartida, Sathiyabarathi *et al.* (2016) realizaram seu estudo com vacas supostamente saudáveis. A mastite de ocorrência natural foi detectada por mensuração diária da temperatura infravermelha do úbere. Além disso, testes de condutividade elétrica e de contagem de células somáticas foram realizados diariamente ao longo do estudo, e foram observadas diferenças entre a temperatura do úbere em quartos saudáveis e afetados por mastite. A mastite subclínica foi determinada em uma temperatura média do úbere de 38,0 °C, enquanto a mastite clínica com 38,2 °C. A temperatura média superficial do úbere no quarto sem mastite foi 37,2 °C.

Salvo a termografia infravermelha, existem medidores de temperatura que podem ser aderidos à pele do animal ou implantados por via subcutânea (MCCAFFERTY *et al.*, 2015). A telemetria tem sido usada em muitas áreas de estudo e em suas respectivas aplicações, inclusive nos estudos com bovinos (HAMRITA; PAULISHEN, 2011). Na telemetria, o sistema para mensuração de temperatura é pautado em três componentes: um sensor (elemento de medição) com um transdutor de sinal e transmissor, um receptor e uma unidade de aquisição de dados. O sensor de temperatura e os transmissores são conjugados em uma única unidade que é colocada dentro ou sobre o corpo do animal.

O estudo de Kou *et al.* (2017) exemplifica tais mensurações. Os autores criaram uma tecnologia de monitoramento automatizado da temperatura superficial em bovinos, que incluía um termistor conectado à perna do animal, mensurando a temperatura da pele do metatarso da pata traseira. Com isso foi possível o monitoramento contínuo da temperatura superficial por três dias durante o inverno, outono e verão. As medições realizadas pelo dispositivo foram comparáveis às obtidas por uso de um termômetro convencional.

Outro procedimento foi aplicado no estudo de Lee *et al.* (2016). Os pesquisadores utilizaram implantes subcutâneos para monitorar a temperatura de sete novilhos da raça Holandês. Os dispositivos foram implantados em três locais do pescoço dos animais e as leituras foram feitas após quatro a seis meses. As avaliações mostraram que há flutuações características de temperatura ao longo de 24 horas, mas com estabilidade nas leituras de temperatura (37,1 - 37,4 °C). Os resultados do estudo evidenciaram que os dispositivos aplicados na medição da temperatura superficial do corpo são úteis, embora, de acordo com os autores, o melhor potencial de detecção de febre em vacas usando este método possa ser alcançado com a construção de algoritmos de correção.

Integrando o conjunto de ferramentas que podem mensurar temperatura periférica, os microchips de identificação por radiofrequência (RFID) podem ser implantados via subcutânea ou intramuscular para fornecer número de identificação e temperatura. Auclair-Ronzaud *et al.* (2020) avaliaram as variações de temperatura corporal com o objetivo de prever o parto, por meio de um microchip implantado no pescoço de éguas gestantes. A temperatura média diária reduziu 0,3 °C no dia do parto em comparação com a temperatura média nos 5 dias anteriores. Também, uma diminuição significativa da temperatura foi detectada 12 horas antes do início do parto (-0,5 °C). O modelo de predição de parto com base na temperatura do microchip proposto pelos autores apresentou sensibilidade e especificidade de 96,6% e 95,0%, respectivamente.

Reid *et al.* (2012) avaliaram a temperatura periférica de bezerros Holandês em condição de imunodeficiência (desafio por lipopolissacarídeo) utilizando microchips implantados via subcutânea em três locais distintos. Os autores também mensuraram a temperatura retal, considerada o padrão ouro de mensuração de temperatura corporal, para fins de comparação, e encontraram correlação moderada entre as temperaturas subcutânea e retal.

Uma avaliação do uso de microchips subcutâneos para estimar a temperatura corporal de bezerros foi conduzida por Woodrum Setser *et al.* (2020). Os autores também elegeram três locais para implantar os dispositivos, mas os resultados não indicaram correlação entre o locais de implante e a temperatura retal. Apesar disso, foi destacado que os microchips tem potencial para identificar temperaturas basais e desvios que se associem a doenças.

#### **2.4 Análise dos dados para gerenciamento de fazendas leiteiras**

Com a adoção de inovações tecnológicas, há em concomitância, aumento considerável na quantidade de dados disponíveis (CABRERA *et al.*, 2020). Quando analisados de forma

independente, o banco de dados é informativo e descreve muitas das atividades que ocorrem em uma fazenda de gado leiteiro, mas quando integrados, podem gerar conhecimento ainda mais significativo de diferentes situações que acontecem na fazenda e melhorar a tomada de decisão (LIBERATI; ZAPPAVIGNA, 2009).

Os resultados de pesquisa realizado no meio-oeste dos EUA mostraram que 64% dos produtores utilizam pelo menos um tipo de tecnologia digital. Cerca de 47% adotaram aplicativos de *smartphones* para receber informações ou intervir na fazenda, 20 a 25% aplicam a agricultura de precisão e 11% usam sensores em animais ou drones (SHUTSKE *et al.*, 2018). Este aumento exponencial no volume de dados precisa ser gerenciado. Diante desta necessidade, destaca-se a ciência de dados e abordagens para relacionados ao armazenamento, mineração e análise desses megadados (DE MAURO *et al.*, 2018).

#### **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 observado (DE HOLLANDA-FERREIRA, 1988). Shankar (2018) assume que a inteligência artificial (IA) se refere a programas, algoritmos, sistemas e máquinas que demonstram inteligência.

Neste contexto, IA é uma subárea da ciência da computação que utiliza mecanismos e dispositivos tecnológicos capazes de simular o cérebro humano. O início do desenvolvimento da IA foi 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 relevantes e formação de redes artificiais com habilidade de aprendizado (COPPIN; LEGRAS, 2012).

A maioria dos aspectos construídos sobre IA concentraram-se em criar algoritmos para aprimorar a precisão da modelagem ou a velocidade de sua construção (CHOU *et al.*, 2015). Aprendizado de máquina, redes neurais, *deep learning*, robôs físicos e automação de processos robóticos fazem parte das tecnologias-chave da IA (DAVENPORT, 2018). Ao empregar essas ferramentas, a IA viabiliza a interpretação de dados corretamente, o aprendizado com esses dados e, consequentemente, a demonstração de informações que possam sanar questões de áreas como as ciências biológicas, exatas e humanas (KAPLAN; HAENLEIN, 2020).

#### **2.4.2 Aprendizado de máquina (*Machine Learning*)**

O aprendizado de máquina (ML) é uma ferramenta eficaz para regressão e/ou classificação de sistemas não lineares que 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 (LARY *et al.*, 2016). Os algoritmos trabalham construindo um modelo por meio de unidades de entrada amostrais. Essas unidades podem aprender um padrão e gerar respostas, consideradas predições ou decisões direcionadas pelos dados, ao invés de simplesmente seguir programações prévias (HEMPSTALK *et al.*, 2015).

Um dos ramos mais amplos do ML é o aprendizado supervisionado, que permite que o modelo preveja resultados futuros, depois de treinado com base em dados observados (SEN *et al.*, 2020). Assim, cada observação do conjunto de dados dispõe de um vetor de medições para variáveis preditoras, 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, há uma associação entre o modelo e a resposta dos preditores, de modo que ele consiga predizer essa resposta em observações futuras para as quais estarão disponíveis apenas dados relativos aos preditores (RASCHKA; MIRJALILI, 2017).

A variável resposta pode ser quantitativa, que envolve a regressão e apresenta saídas contínuas, ou qualitativa, que envolve a classificação, com saídas 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 campo da produção animal, o ML tem sido aplicado em diversas áreas, por exemplo, na tentativa de prever resultados de fertilidade (FENLON *et al.*, 2016), genética (GIANOLA *et al.*, 2011; KESHAVARZI *et al.*, 2020), genoma (ABDOLLAHI-ARPANAH *et al.*, 2020), qualidade do leite (EBRAHIMIE *et al.*, 2018), mastite (HYDE *et al.*, 2020), início do parto (BORCHERS *et al.*, 2017; KECELI *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 (ABDELLA *et al.*, 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), 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 (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, 2020; SEMENENKO *et al.*, 2020), dentre outros.

#### **2.4.3 Recurrent Neural Networks (RNN) e Long Short-Term Memory (LSTM)**

Os métodos para prever os dados de séries temporais podem ser classificados principalmente em dois tipos, métodos de aprendizado de máquina e aprendizado profundo. Os modelos de aprendizado profundo são superiores aos modelos estatísticos de aprendizado de máquina para prever as aplicações não lineares, como por exemplo, previsão do tempo e gravações de eletrocardiograma (CHAWLA *et al.*, 2008).

Redes Neurais Recorrentes (RNN's) e Redes Neurais Feed Forward (FFNN's) são dois tipos de técnicas de aprendizado profundo amplamente utilizadas, mas as FFNN's não apresentam um bom desempenho para previsão de dados temporais, pois não são capazes de considerar as interdependências presentes em dados de séries temporais. Por outro lado, as RNN's são tipos poderosos e robustos de redes neurais artificiais que usam dados de séries temporais existentes para prever os dados futuros em um período de tempo especificado. A RNN recebe os dados de entrada atual e também os que foram vistos anteriormente. As informações das entradas anteriores podem ser mantidas nas camadas ocultas da RNN, o que influenciará o cálculo da entrada atual. A principal diferença entre a rede recorrente e o feedforward é o olhar de feedback conectado as suas decisões passadas.

No entanto, as RNN's podem apenas recuperar as informações recentes, mas não as informações anteriores. Embora as RNN's possam ser treinados por retropropagação, será muito difícil treiná-las para longas sequências de entrada devido a gradientes de fuga, que são referidos como a perda de informação na rede neural. Portanto, a principal desvantagem da arquitetura RNN é sua memória mais curta para lembrar os recursos, desaparecendo e explodindo gradientes (YIN *et al.*, 2019).

Hochreier *et al.* (1997) propuseram o LSTM para resolver o problema do desaparecimento do gradiente criando caminhos onde o gradiente flui por longas durações. A ideia central por trás da arquitetura LSTM é a unidade de memória que mantém seu estado ao longo do tempo e armazena informações úteis por um período prolongado.

A arquitetura LSTM usa a tecnologia de portões de controle para determinar a exclusão ou preservação de dados históricos e dados de entrada por meio de portões de esquecimento, de entrada e de saída. Estes portões são as chaves para controlar o fluxo de informações. Com

isso, a LSTM pode minimizar os problemas de desaparecimento de gradiente e explosão no processo de treinamento de RNN (GERS *et al.*, 2000; SUNDERMEYER *et al.*, 2015).

### **3 CONSIDERAÇÕES FINAIS**

O conhecimento sobre a utilização de sensores na atividade pecuária está evoluindo à medida que um número crescente de estudos quantifica a eficiência da utilização destas ferramentas para monitoramento dos animais e gerenciamento das fazendas. À medida que a compreensão do funcionamento de modelos computacionais associados à previsão de mudanças no estado fisiológico dos animais se aprofunda, será possível desenvolver estratégias de avaliação que melhorem o status de saúde em geral. Identificar precocemente animais doentes é um exemplo de estratégia com potencial de promover melhor rentabilidade do sistema de criação associado ao bem-estar animal. Entendendo a maneira como uma doença se comporta, é possível utilizá-la oportunamente como modelo para indução de respostas fisiológicas específicas e avaliar registros realizados por sensores nestas situações. À medida que o efeito direto da quebra de homeostase causada por um desafio patogênico é refletido na atividade de sensores, torna-se evidente que eles são alternativas viáveis para facilitar processos dentro das fazendas, contribuir com a tomada de decisão de forma eficaz e minimizar perdas na criação.

## REFERÊNCIAS

- ABDELLA, G. M. *et al.* Sustainability assessment and modeling based on supervised machine learning techniques: The case for food consumption. **Journal of Cleaner Production**, v. 251, p. 119661, 2020.
- ABDOLLAHI-ARPANAH, R.; GIANOLA, D.; PEÑAGARICANO, F. Deep learning versus parametric and ensemble methods for genomic prediction of complex phenotypes. **Genetics Selection Evolution**, v. 52, p. 1-15, 2020.
- ABREU, L. H. *et al.* Artificial neural networks for prediction of physiological and productive variables of broilers. **Engenharia Agrícola**, v. 40, p. 1-9, 2020.
- ALONSO, R. S. *et al.* An intelligent Edge-IoT platform for monitoring livestock and crops in a dairy farming scenario. **Ad Hoc Networks**, v. 98, p. 102047, 2020.
- ALVARENGA, F. A. P. *et al.* Discrimination of biting and chewing behaviour in sheep using a tri-axial accelerometer. **Computers and Electronics in Agriculture**, v. 168, p. 105051, 2020.
- ANGRECKA, S.; HERBUT, P. Eligibility of lying boxes at different THI levels in a free stall barn. **Ann. Anim. Sci.**, v. 17, n. 1, p. 257–269, 2017.
- ARCIDIACONO, C. *et al.* A software tool for the automatic and real-time analysis of cow velocity data in free-stall barns: the case study of oestrus detection from Ultra-Wide-Band data. **Biosyst. Eng.**, v. 173, p. 157-165, 2018.
- AUBRY, P.; GEALE, D. W. A review of bovine anaplasmosis. **Transbound. Emerg. Dis.**, v.58, p.1-30, 2011.
- AUCLAIR-RONZAUD. *et al.* No-contact microchip measurements of body temperature and behavioural changes prior to foaling. **Theriogenology**, v. 157, p. 399-406, 2020.
- AYYAR, B. V.; ARORA, S. Antibody-based biosensors for detection of veterinary viral pathogens, **Adv. Anim. Vet. Sci.** v. 1, p. 37–44, 2013.
- BAHLO, C. *et al.* The role of interoperable data standards in precision livestock farming in extensive livestock systems: a review. **Comput. Electron. Agric.**, v. 156, p. 459-466, 2019.
- BARNES, A. *et al.* Physiology of heat stress in cattle and sheep. **Project number LIVE. 209, Australia. Meat and Livestock Australia Limited**, p. 35, 2004.
- BELL, M. J. *et al.* The effect of improving cow productivity, fertility and longevity on the global warming potential of dairy systems. **J. Dairy Sci.**, v. 94, 2011.
- BENAISSE, S. *et al.* On the use of on-cow accelerometers for the classification of behaviours in dairy barns. **Research in veterinary science**, v. 125, p. 425-433, 2019.

- BENNI, S. *et al.* A generalised additive model to characterise dairy cows' responses to heat stress. **Animal**, v. 14, p. 418-424, 2020.
- BERCKMANS, D. *et al.* Animal sound... talks! Real-time sound analysis for health monitoring in livestock, **Proc. Animal Environment and Welfare**, p. 215–222, 2015.
- BERCKMANS, D.; GUARINO, M. From the Editors: precision livestock farming for the global livestock sector. **Anim. Front.**, v. 7, n. 1, p. 4 e 5, 2017.
- BERRY, R. J. *et al.* Daily variation in the udder surface temperature of dairy cows measured by infrared thermography: Potential for mastitis detection. **Can. J. Anim. Sci.**, v. 83, p. 687–693, 2003.
- BISHOP, J. C. *et al.* Livestock vocalisation classification in farm soundscapes. **Comput. Electron. Agric.**, v. 162, p. 531-542, 2019.
- BORCHERS, M. R. *et al.* Machine-learning-based calving prediction from activity, lying, and ruminating behaviors in dairy cattle. **Journal of Dairy Science**, v. 100, p. 5664-5674, 2017.
- 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, p. 4198-4205, 2015.
- BRITO, L. G. *et al.* *Anaplasma marginale* infection in cattle from south-western Amazonia. **Pesq. Vet. Bras.**, v. 30, p. 249-254, 2010.
- BROOM, D. M.; FRASER, A. F. Domestic Animal Behaviour and Welfare, **CABI, Oxfordshire, United Kingdom**, p. 101–125, 2015.
- BROUGHTON-NEISWANGER, L. E. *et al.* Urinary chemical fingerprint left behind by repeated NSAID administration: Discovery of putative biomarkers using artificial intelligence. **PLoS one**, v. 15, e0228989, 2020.
- BROWN, W. C. Adaptative immunity to *Anaplasma* pathogens and immune dysregulation: implications for bacterial persistence. **Comp. Immunol. Microbiol. Infect. Dis.**, v. 35, p. 241-252, 2012.
- CABRERA, V. E. *et al.* Symposium review: Real-time continuous decision making using big data on dairy farms. **Journal of Dairy Science**, v. 103, p. 3856-3866, 2020.
- CATAL, C.; KASSAHUN, A.; HOVİNG, H. J. Improving Farm Management Information Systems with Data Mining. Balkan, **Journal of Electrical and Computer Engineering**, v. 8, p. 21-30, 2020.
- CAVALIERE, A.; VENTURA, V. Mismatch between food sustainability and consumer acceptance toward innovation technologies among Millennial students: the case of Shelf Life Extension. **J. Clean. Prod.**, v. 175, p. 641-650, 2018.

- CHARLTON, G. L.; RUTTER, S. M. The behaviour of housed dairy cattle with and without pasture access: a review. **Appl. Anim. Behav. Sci.**, v. 192, p. 2-9, 2017.
- CHAWLA, M.; VERMA, H.; KUMAR, V. RETRACTED: A new statistical PCA-ICA algorithm for location of R-peaks in ECG. Elsevier (2008)
- CHOU, J. S. *et al.* Optimized artificial intelligence models for predicting project award price. **Automation in Construction**, v. 54, p. 106-115, 2015.
- COELHO, L. C. T. *Anaplasmosse bovina: parâmetros clínicos e de patologia clínica em bezerros infectados experimentalmente*. 65f. **Dissertação (Mestrado em Medicina Veterinária) – Universidade Federal de Minas Gerais, Belo Horizonte, 2007.**, 2007.
- COMINOTTE, A. *et al.* Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases. **Livestock Science**, v. 232, p. 103904, 2020.
- CONNOLLY, E.; WORTHLEY, L. I. Induced and accidental hypothermia. **Crit. Care Resusc.**, v. 2, p. 22–29, 2000.
- 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. **Rev. Cie. FCV-LUZ**, v. 11, p. 408-411, 2001.
- CURTIS, S. E. Environmental Management in Animal Agriculture. **University Press**, Ames, IA: Iowa State 67, 1983.
- DAVENPORT, T. H.; RONANKI, R. Artificial intelligence for the real world. **Harvard business review**, v. 96, p. 108-116, 2018.
- DE HOLLANDA-FERREIRA, A. B., & DOS ANJOS, M. **Dicionário Aurélio básico da língua portuguesa**. Editora Nova Fronteira, 1988.
- DE MAURO, A. *et al.* Human resources for Big Data professions: A systematic classification of job roles and required skill sets. **Information Processing & Management**, v. 54, p. 807-817, 2018.
- DELHEZ, P. *et al.* 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.
- DIVERS, T. J.; PEEK, S. F. “Metabolic diseases” **Rebhun's Diseases of Dairy Cattle, 2<sup>a</sup> Ed, Saunders Elsevier**, p. 590-596, 2008.
- DOLECHECK, K. A. *et al.* 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.

- DOMINIAK, K. N.; KRISTENSEN, A. R. Prioritizing alarms from sensor-based detection models in livestock production - a review on model performance and alarm reducing methods. **Comput. Electron. Agric.**, v. 133, p. 46-67, 2017.
- DUMLER, J. S. A. F. *et al.* 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*. **Int. J. Syst. Evol. Microbiol.**, v. 51, p. 2145-2165, 2001.
- EBRAHIMIE, E. *et al.* Hierarchical pattern recognition in milking parameters predicts mastitis prevalence. **Computers and Electronics in Agriculture**, v. 147, p. 6-11, 2018.
- EHRET, A. *et al.* 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, p. 322-329, 2015.
- ELDESOUKY, A. *et al.* Can extensification compensate livestock greenhouse gas emissions? A study of the carbon footprint in Spanish agroforestry systems. **J. Clean. Prod.**, v. 200, p. 28-38, 2018.
- FENLON, C. *et al.* A comparison of machine learning techniques for predicting insemination outcome in Irish dairy cows. **Irish Conference on Artificial Intelligence and Cognitive Science, University College Dublin**, 2016.
- FERRARI, S. *et al.* Cough sound analysis to identify respiratory infection in pigs, **Comput. Electron. Agric.** v. 64, n. 2, p. 318–325, 2008.
- FOIL, L. D. Tabanids as vectors of disease agents. **Parasitol Today**, v. 5, p. 88-96, 1989.
- FOURNEL, S.; ROUSSEAU, A. N.; LABERGE, B. Rethinking environment control strategy of confined animal housing systems through precision livestock farming. **Biosyst. Eng.**, v. 155, p. 96-123, 2017.
- 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, p. 102973, 2020.
- FUKATSU, T.; NANSEKI, T. Farm Operation Monitoring System with Wearable Sensor Devices Including RFID, **INTECH**, Open Access Publisher, 2011.
- GAGGE, A. P.; FOBELETS, A. P.; BERGLUND, L. G. A standard predictive index of human response to the thermal environment. **ASHRAE Trans.** v. 92, p. 709–731, 1986.
- GALE, K. R. *et al.* *Anaplasma marginale*: detection of carrier cattle by PCR-ELISA. **Int. J. Parasitol.**, v. 26, p. 1103-1109, 1996.
- GARCIA, S. O. *et al.* Wearable sensor system powered by a biofuel cell for detection of lactate levels in sweat, **Eur. J. Sol. State Tech.**, v. 5, n. 8, p. 3075–3081, 2016.

- GATES, M. C. *et al.* Guidelines for implementing a low-cost volunteer desexing skills training program for veterinary and veterinary technology students. **Journal of Veterinary Medical Education**, v. 47, p. 27-38, 2020.
- GERS, F. A.; SCHMIDHUBER, J.; CUMMINS, F. Learning to forget: continual prediction with LSTM. **Neural Comput.** v. 12, n. 10, p. 2451-2471, 2000.
- GIANOLA, D. *et al.* 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. **Vet. Immunol. Immunopathol.**, v. 38, p. 183-191, 1993.
- GLENNON, T. *et al.* ‘SWEATCH’: a wearable platform for harvesting and analysing sweat sodium content, **Electroanalysis**, v. 28, p. 1283–1289, 2016.
- 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, p. 105124, 2020.
- GUGLIELMONE, A. A. Epidemiology of babesiosis and anaplasmosis in south and Central America. **Vet. Parasitol.**, v. 57, 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, p. 190, 2020.
- HAMRITA, T. K.; PAULISHEN, M. Advances in management of poultry production using biotelemetry. In **Modern Telemetry** (eds. Ondrej Krejcar, Croatia), v. 8, p. 165–182, 2011.
- HARROP, P. Wearable technology for animals 2017-2027: technologies, markets, forecasts, **IDTechEx**, 2016.
- HAZARI, P. K. *et al.* Analysis of Factors of Milk Production and Use of ICT in Diary: India Versus Jharkhand. In **Smart Intelligent Computing and Applications**, Springer, Singapore, p. 77-91, 2020.
- HEIKENFELD, J. Bioanalytical devices: technological leap for sweat sensing, **Nature**, v. 529, n. 7587, p. 475–476, 2016.
- 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.
- HERBUT, P.; ANGRECKA, S. Relationship between THI level and dairy cows’ behaviour during summer period. **Ital. J. Anim. Sci.**, v. 17, n. 1, p. 226–233, 2018.

- HIGAKI, S. *et al.* Estrous detection by continuous measurements of vaginal temperature and conductivity with supervised machine learning in cattle. **Theriogenology**, v. 123, p. 90-99, 2019.
- HOCHREITER, S.; SCHMIDHUBER, J.; Long short-term memory, **Neural Comput.** v. 9, n. 8, p.1735-1780, 1997.
- HOCHREITER, S.; SCHMIDHUBER, J.; LSTM can solve hard long time lag problems, **Adv. Neural Inform. Process. Sys.**, p. 473-479, 1997.
- HOU, Y.; VELTHOF, G. L.; OENEMA, O. Mitigation of ammonia, nitrous oxide and methane emissions from manure management chains: a meta-analysis and integrated assessment. **Global Change Biol.**, v. 21, p. 1293-1312, 2015.
- HU, H. *et al.* Cow identification based on fusion of deep parts features. **Biosystems Engineering**, v. 192, p. 245-256, 2020.
- HUR, B. A. *et al.* 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, e0230049, 2020.
- HYDE, R. M. *et al.* Automated prediction of mastitis infection patterns in dairy herds using machine learning. **Scientific Reports**, v. 10, p.1-8, 2020.
- IVANOV, S.; BHARGAVA, K.; DONNELLY, W. Precision farming: sensor analytics, **IEEE Intell. Syst.** 30, v. 4, p. 76–80, 2015.
- JENSEN, D. B.; LARSEN, M. L. V.; PEDERSEN, L. J. Predicting pen fouling in fattening pigs from pig position. **Livestock Science**, v. 231, p. 103852, 2020.
- JENSEN-JAROLIM, E.; FLASCHBERGER, I. U.S. Patent No. 9,282,725. Washington, DC: **U.S. Patent and Trademark Office**. 2016
- KAPLAN, A.; HAENLEIN, M. Rulers of the world, unite! The challenges and opportunities of artificial intelligence. **Business Horizons**, v. 63, p. 37-50, 2020.
- KECELI, A. S. *et al.* Development of a recurrent neural networks-based calving prediction model using activity and behavioral data. **Computers and Electronics in Agriculture**, v. 170, p.105285, 2020.
- KEDARI, S. *et al.* 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, Springer, Singapore**, p. 383-404, 2020.
- KESHAVARZI, H. *et al.* 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, p. 104869, 2020.

- KIESER, S. T.; ERIKS, I. S.; PALMER, G. H. Cyclic rickettsemia during persistent *Anaplasma marginale* infection of cattle. **Infect. Immun.**, v. 58, p. 1117-1119, 1990.
- KIM, J. et al. A wearable fingernail chemical sensing platform: pH sensing at your fingertips, **Talanta**, p. 622–628, 2016
- KIZIL, Ü. et al. Design and test of a low-cost electronic nose system for identification of *Salmonella enterica* in poultry manure, **T. ASABE 58**, v. 3, p. 819–826, 2015.
- KOCAN, K. M. et al. Antigens and alternatives for control of *Anaplasma marginale* infection in cattle. **Clin. Microbiol. Rev.**, v. 16, p. 698-712, 2003.
- KOCAN, K. M. et al. Demonstration of the inclusion appendage of *Anaplasma marginale* in nymphal *Dermacentor andersoni*. **Am Vet Res.**, v. 45, p. 1800-1807, 1984.
- KOCAN, K. M. et al. The natural history of *Anaplasma marginale*. **Vet. Parasitol.**, v. 167, p. 95-107, 2010.
- KOU, H. et al. Automated measurement of cattle surface temperature and its correlation with rectal temperature. **Williams BO, ed. PLoS ONE**, v. 12, n. 4, Art. no. e0175377, 2017
- LARSON, L. L. et al. Guidelines Toward More Uniformity in Measuring and Reporting Calf Experimental Data. **J. Dairy Sci.**, v. 60, n. 6, p. 989-991, 1977.
- LARY, D. J. et al. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3–10, 2016.
- LASMAR, P. V. F. et al. Evaluating the effectiveness of an inactivated vaccine from *Anaplasma marginale* derived from tick cell culture. **Rev. Bras. Parasitol. Vet.**, v. 21, p. 112-117, 2012.
- LEE, J. et al. Stress detection and classification of laying hens by sound analysis, **Asian. Australas. J. Anim. Sci.** v. 28, n. 4, p. 592, 2015.
- LEE, Y. et al. Body temperature monitoring using subcutaneously implanted thermo-loggers from Holstein steers. **Asian-Australas. J. Anim. Sci.**, v. 29, n. 2, p. 299–306, 2016.
- LIBERATI, P.; ZAPPAVIGNA, P. Improving the automated monitoring of dairy cows by integrating various data acquisition systems. **Computers and Electronics in Agriculture**, v. 68, n. 1, p. 62-67, 2009.
- LINDBLOM, J. et al. Promoting sustainable € intensification in precision agriculture: review of decision support systems development and strategies. **Precis. Agric.**, v. 18, n. 3, p. 309-331, 2017.
- LOSOS, G.J. Rickettsial Diseases – Anaplasmosis. In: **Infectious tropical diseases of domestic animals. 1<sup>a</sup> Ed., New York: Churchill Livingstone Inc.**, 938p., p. 742-795, 1986.

- LOVARELLI, D. *et al.* Improvements to dairy farms for environmental sustainability in Grana Padano and Parmigiano Reggiano production systems. **Ital. J. Anim. Sci.**, v. 18, n. 1, p. 1035-1048, 2019.
- LOVARELLI, D.; BACENETTI, J.; FIALA, M. Effect of local conditions and machinery characteristics on the environmental impacts of primary soil tillage. **J. Clean. Prod.**, v. 140, p. 479-491, 2017.
- MADER, T. L. *et al.* Tympanic temperature in confined beef cattle exposed to excessive heat load. **International Journal of Biometeorology**, v. 54, p. 629-635, 2010.
- MARANA, E. R. M. *et al.* 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. **Res. Bras. Parasitol. Vet.**, v. 18, p. 20-26, 2009.
- MAYO, L. M. *et al.* Detecção automatizada de estro usando múltiplas tecnologias comerciais de monitoramento de precisão em vacas leiteiras sincronizadas. **J. Dairy Sci.**, v. 102, n. 3, p. 2645-2656, 2019.
- MCCAFFERTY, D. J. Applications of thermal imaging in avian science. **International Journal of Avian Science**, v. 155, p. 4-15, 2013.
- MCCAFFERTY, D. J.; GALLON, S.; NORD, A. The thermal physiology of most birds and mammals is characterised by considerable spatial and temporal variation in body temperature. **Anim. Biotelem.**, v. 3, n. 1, p. 2050-3385, 2015.
- MEEN, G. H. *et al.* Sound analysis in dairy cattle vocalisation as a potential welfare monitor. **Comput. Electron. Agric.**, v. 118, p. 111-115, 2015.
- MELÉNDEZ, R. D. Phagocytosis of *Anaplasma marginale* infected and uninfected erythrocytes by bovine peripheral blood leucocytes. **Rev. Cient. FCV-LUZ**, v. 15, p. 305-309, 2005.
- MELO, I. O. Balanço ácido-base, hidroeletrolítico e hemograma de bezerros inoculados com *Anaplasma marginale*. 77p. **Dissertação (Mestrado em Ciência Animal) – Escola de Veterinária, Universidade Federal de Minas Gerais, Belo Horizonte, 2018.**, 2018.
- MEUNIER, B. *et al.* Image analysis to refine measurements of dairy cow behaviour from a real-time location system. **Biosyst. Eng.**, v. 173, p. 32-44, 2018.
- MOLAD, T. *et al.* Molecular and serological detection of *A. centrale* and *A. marginale*-infected cattle grazing within an endemic area. **Vet. Microbiol.**, v. 113, p. 55-62, 2006.
- MONTANHOLI, Y. R. *et al.* Assessing feed efficiency in beef steers through feeding behavior, infrared thermography and glucocorticoids. **Animal**, v. 4, p. 692-701, 2010.
- MUNGROO, N. A.; NEETHIRAJAN, S. Biosensors for the detection of antibiotics in poultry industry—a review, **Biosensors**, v. 4, n. 4, p. 472–493, 2014.

- MUNGROO, N. A.; OLIVEIRA, G.; NEETHIRAJAN, S. SERS based point-of-care detection of food-borne pathogens, **Microchim. Acta** **183**, v. 2, p. 697–707, 2016.
- NEETHIRAJAN, S. Recent advances in wearable sensors for animal health management. **Sensing and Bio-Sensing Research**, v. 12, p. 15-29, 2017.
- NOGAMI, H. *et al.* Wearable wireless temperature sensor nodes appressed to base of a calf's tail, **Sensor. Mater.** v. 26, n. 8, p. 539–545, 2014.
- 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.
- PEZESHKI, A. *et al.* Variation of inflammatory dynamics and mediators in primiparous cows after intra mammary challenge with Escherichia coli. **Vet. Res**, v. 42, p. 15. 2011.
- POIKALAINEN, V. *et al.* Infrared temperature patterns of cow's body as an indicator for health control at precision cattle farming. **Agron Res**, v. 10, n. 1, 187–194, 2012.
- RAINWATER-LOVETT, K. *et al.* Detection of foot-and-mouth disease virus infected cattle using infrared thermography. **Veterinary Journal**, v. 180, p. 317-324, 2009.
- RASCHKA, S.; MIRJALILI, V. Python Machine Learning: Machine Learning and Deep Learning with Python. **Scikit-Learn, and TensorFlow**, 2<sup>a</sup> ed, 2017.
- REFINETTI, R.; HORVATH, S. M. Thermo referendum of the rat - Inter-subject and intrasubject variabilities. **Behav. Neural. Biol**, v. 52, n. 1, p. 87–94, 1989.
- REID, E. D. *et al.* Correlation of rectal temperature and peripheral temperature from implantable radio-frequency microchips in Holstein steers challenged with lipopolysaccharide under thermoneutral and high ambient temperatures. **Journal of Animal Science**, v. 90, p. 4788-4794, 2012.
- RIBEIRO, M. F. B.; LIMA, J. D. Morphology and development of *Anaplasma marginale* in midgut of engorged female ticks of *Boophilus microplus*. **Vet. Parasitol.**, v. 61, p. 31-39, 1996.
- RIBEIRO, M. F. B.; LIMA, J. D.; SALCEDO, J. H. P. Attempted transmission of *Anaplasma marginale* by infected *Boophilus microplus*. **Arq. Bras. Med. Vet. Zootec.**, v. 48, p. 397-402, 1996.
- RIBEIRO, M. F. B.; PASSOS L. M. F. Tristeza Parasitária Bovina. **Cad. Tec. Vet. Zootec.** v. 39, p. 36-52, 2002.
- RICHEY, E. J. Bovine Anaplasmosis In: Howard - **Current Veterinary Therapy: Food Animal Practice**. 3<sup>a</sup> Ed. Philadelphia:W.B. Saunders Company, 1233p., 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.
- RUTTEN, C. J. *et al.* Can sensor technology benefit mastitis control, **Proceedings of the British Mastitis Conference Sixways, Worcester, 2013**, p. 23–34, 2013
- RUTTEN, C. J. *et al.* Invited review: sensors to support health management on dairy farms. **Journal of Dairy Science**, v. 96, p. 1928–1952, 2013.
- SA, J. *et al.* Detection of low-weight pigs by using a top-view camera, **Proceedings of The fourth International Conference on Information Science and Cloud Computing (ISCC2015)**, p. 18–19 (Guangzhou, China. Online at <http://pos.sissa.it/cgi-bin/reader/conf.cgi?confid=264, id. 24>). 2015
- 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. **C. Rural**, v. 31, p. 849-855, 2001.
- SARANYA, P. Identification of Diseases in Dairy Cow Based on Image Texture Feature and Suggestion of Therapeutical Measures. **International Journal for Research in Applied Science and Engineering Technology**. v. 8, p. 531-536, 2020.
- SATHIYABARATHI, M. *et al.* Investigation of body and udder skin surface temperature differentials as an early indicator of mastitis in Holstein Friesian crossbred cows using digital infrared thermography technique. **Vet. World**, v. 9, n. 12, p. 1386–1391, 2016.
- SCHAEFER, A. L. *et al.* The non-invasive and automated detection of bovine respiratory disease onset in receiver calves using infrared thermography. **Research in Veterinary Science**, v. 93, p. 928-935, 2012.
- SELLIER, N.; GUETTIER, E.; STAUB, C. A review of methods to measure animal body temperature in precision farming. **Am. J. Agric. Sci. Technol.**, v. 2, n. 2, p. 74–99, 2014.
- SEMENENKO, M. P. *et al.* Methodology of development and diagnostic efficiency of expert systems in animal hepatopathies. In **IOP Conference Series: Earth and Environmental Science**, v. 421, p. 052038. IOP Publishing, 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.
- SETSER, M. W.; CANTOR, M. C.; COSTA, J. H. C. A comprehensive evaluation of microchips to measure temperature in dairy calves. **Journal of Dairy Science**, v. 103, p. 9290-9300, 2020.
- SHANKAR, V. How artificial intelligence (AI) is reshaping retailing. **Journal of Retailing**, v. 94, n. 4, p. 6-11, 2018.

- SHUTSKA, J. M. *et al.* 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, p. 1, 2018.
- SILVA, J. B.; FONSECA, A. H. Risk factors for anaplasmosis in dairy cows during the peripartum. **Trop. Anim. Health. Prod.**, v. 46, p. 461-465, 2014.
- SMITH, R. *et al.* Isolate of *Anaplasma marginale* not transmitted by ticks. **Am. J. Vet. Res.**, v. 47, p. 127-129, 1986.
- SOERENSEN D., PEDERSEN L. Infrared skin temperature measurements for monitoring health in pigs: a review. **Acta Vet. Scand**, v. 57, n. 1, p. 1–11, 2015.
- SPARE, M. R. *et al.* Bovine anaplasmosis herd prevalence and management practices as risk-factors associated with herd disease status. **Veterinary Parasitology**, v. 3, p. 100021, 2020.
- STEENEVELD, W.; HOGEVEEN, H. Characterization of Dutch dairy farms using sensor systems for cow management. **Journal of Dairy Science**, v. 98, p. 709-717, 2015.
- STEWART, M. *et al.* Eye temperature and heart rate variability of calves disbudded with or without local anaesthetic. **Physiology and Behaviour**, v. 93, p. 789-797, 2008.
- STEWART, M. *et al.* Noninvasive assessment of autonomic activity for evaluation of pain in calves, using surgical castration as a model. **Journal of Dairy Science**, v. 93, p. 3602-3609, 2010.
- STEWART, M. *et al.* Non-invasive measurement of stress in dairy cows using infrared thermography. **Physiology and Behaviour**, v. 92, p. 520- 525, 2007.
- STONE, A. E. *Symposium review*: The most important factors affecting adoption of precision dairy monitoring technologies. **J. Dairy Sci.**, v. 103, n. 6, p. 5740-5745, 2020.
- SUNDERMEYER. M.; NEY. H.; SCHLUTER. R. From feedforward to recurrent LSTM neural networks for language modeling. **IEEE/ACM Trans. Audio Speech Lang. Process.** v. 23, n. 3, p. 517-529, 2015.
- TAYLOR, N. A.; TIPTON, M. J.; KENNY, G. P. Considerations for the measurement of core, skin and mean body temperatures. **J. Therm. Biol.**, v. 46, p. 72–101, 2014.
- 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.

- TICHIT, M. *et al.* Multicriteria performance and sustainability in livestock farming systems: functional diversity matters. **Livest. Sci.**, v. 139, p. 161-171, 2011.
- UWIZEYE, A. *et al.* A comprehensive framework to assess the sustainability of nutrientuse in global livestock supply chains. **J. Clean. Prod.**, v. 129, p. 647-658, 2016.
- VAN HERTEM, T. *et al.* Appropriate data visualisation is key to Precision Livestock Farming acceptance. **Comput. Electron. Agric.**, v. 138, p. 1-10, 2017.
- VAN NUFFEL, A. *et al.* Lameness detection in dairy cows: part 2. Use of sensors to automatically register changes in locomotion or behavior, **Animals**, v. 5, n. 3, p. 861–885, 2015.
- VIDOTTO, O.; MARANA, E. R. M. Diagnóstico em anaplasmosse bovina. **C. Rural**, v. 31, p. 361-368, 2001.
- WAGHELA, S. D. *et al.* Antigenic analysis of *Anaplasma marginale* grown in bovine erythrocytes co-cultured with bovine endothelial cells. **Vet. Parasitol.**, v. 94, p. 133-139, 2000.
- WANER, T. *et al.* Rickettsiales. In: GYLES, C.L.; PRESCOTT, J.F.; SONGER, J. G. *et al.* **Pathogenesis of Bacterial Infections in Animals. 4<sup>a</sup> ed.** Wiley-blackwell, c. 31, p.589-621, 2010.
- WERNER, J.; MEKJAVIC, I. B.; TAYLOR, N. A. S. Concepts in physiological regulation: a thermos regulatory perspective. In: Taylor, N.A.S., Groeller, H. (Eds.), **Physiological Bases of Human Performance During Work and Exercise**, p.325–340, 2008.
- WICKWIRE, K. B. *et al.* Infectivity of three *Anaplasma marginale* isolates for *Demarcentor andersoni*. **Am. J. Vet. Res.**, v. 48, p. 96-99, 1987.
- WINTER, L. *et al.* Including biodiversity in life cycle assessment e state of the art, gaps and research needs. **Environ. Impact Assess. Rev.**, v. 67, p. 88-100, 2017.
- YIN, Q. *et al.* CNN and RNN mixed model for image classification, **MATEC Web Conf.** 277(8) p. 1-7, 2019.
- ZUCALI, M. *et al.* Management options to reduce the environmental impact of dairy goat milk production. **Livest. Sci.**, v. 231, p. 103888, 2020.

## SEGUNDA SEÇÃO – ARTIGO

### Use of microchip with thermal sensor in the detection of changes in body temperature in dairy calves with anaplasmosis.

Article formatted according to Journal of Thermal Biology guidelines

#### Highlights

- Body temperature is an important tool in health assessment
- Implantable microchips could be an alternative for measuring body temperature
- The use of predictive models contributes to more accurate decision making
- Rectal temperature makes possible to identify sick animals with 3 days in advance
- Microchips did not show high accuracy in identifying febrile animals

#### ABSTRACT

Calf mortality and morbidity represent a significant cost in rearing and an important welfare issue. The most commonly used health assessment tool is the measure of body temperature using a rectal thermometer, which can be labor intensive, invasive and stressful for the animal. Automating temperature measurement can be useful during disease occurrence for early identification and treatment of animals. The objectives of this study were to evaluate: *i*) subcutaneous temperature data collected by the Bio-Thermo microchip compared to rectal temperature (RT) in calves exposed to anaplasmosis; and *ii*) the predictive ability of Recurrent Neural Networks (RNN) and Long Short-Term Memory (LSTM) in the early identification of anaplasmosis. Additionally, we aimed to investigate: *ii.a*) the effect of time series length prior to disease diagnosis (5, 7, or 10 consecutive days) on the predictive performance of RNN and LSTM; and *ii.b*) how early anaplasmosis disease can be detected in dairy calves (3 days in advance or just on the day of clinical diagnosis). Twenty-four heifer calves with  $132.4 \pm 13.9$  (mean  $\pm$  SD) days of age and  $146 \pm 23.3$  kg of body weight were challenged with  $2 \times 10^7$  erythrocytes infected with the UFMG1 strain (GenBank no. EU676176) isolated from *Anaplasma marginale*. After inoculation, animals were monitored daily by assessing packed cell volume (PCV). The lowest PCV value ( $14.8 \pm 2.6\%$ ) and the identification of rickettsia on blood smears were used as criteria to classify an animal as sick (d0). Temperature data were collected daily using passive radiofrequency identification (RFID) and clinical thermometer.

Two time series were built including last sequence of -5, -7 or -10 d preceding d0 or comprising a sequence of 5, 7 or 10 d randomly selected in a window from -50 to -15 d before d0 to ensure a sequence of days in which PCV was considered normal ( $32 \pm 2.3\%$ ). Leave-One-Animal-Out Cross-Validation (LOAOCV) was used to assess prediction quality. The RT was increased in response to the disease, while the temperature measured by the microchip showed only small variations and the correlation between these two temperatures was low ( $r = 0.35, P < 0.001$ ). On d0, for both temperature datasets (microchip and rectal), the precision (ACC), sensitivity (SEN) and specificity (SPE) of RNN was lower than LSTM. The ACC, SEN and SPE of LSTM in detecting anaplasmosis on d0 using microchip data ranged from 71 to 77%, 62 to 67% and 75 to 88%, respectively. For RT data on d0, ACC, SEN and SPE of LSTM ranged from 96 to 98%, 96 to 100% and 92 to 96%, respectively. The predictive performance of the models did not improve when using longer time series to predict anaplasmosis. The ACC and SEN in predicting anaplasmosis up to 3 days before clinical diagnosis were greater than 80% only for RT using RNN models, confirming that RT allows for early identification of changes in body temperature related to anaplasmosis. On the other hand, the microchip did not have the same potential.

**Keywords:** artificial intelligence, machine learning, microchip, body temperature

## 1. INTRODUCTION

Production losses due to the occurrence of diseases can affect the profitability of production units. Currently, methods of identifying sick animals rely on visual and physical assessments to identify physiological changes related to the disease. The measurement of body temperature is used in this context as an auxiliary diagnostic tool, and is usually done using a rectal thermometer. However, to measure the rectal temperature (RT) it is necessary to physically contain the animal, which makes the measurement laborious, in addition to negatively impacting the well-being of the animals.

In some countries, bovine anaplasmosis caused by *Anaplasma marginale* is endemic and is associated with large economic losses due to mortality, especially in young animals (Aubry and Geale, 2011; Ueti et al., 2012). As example, the incidence risks from birth to 180 days of age were 49% in a pasture system (Moreira, 2017) and 58% in a semi-confined heifer system (Mendonça, 2015). Calves with clinical symptoms had a 60% mortality (Bastos et al., 2010), so it is listed as an important disease by the World Organization report of Animal Health (OIE, 2019). In general, the diagnosis of anaplasmosis is carried out on farms through

observation of clinical symptoms, such as: fever, anemia, loss of appetite and weight, dehydration, anorexia and lethargy (Kocan et al., 2003, 2010; Oliveira Júnior et al., 2018; Souza et al., 2001).

*Anaplasma marginale*, along with *Babesia bovis* and *Babesia bigemina* are the etiologic agents of bovine tick fever in Brazil. Recently, a monitoring protocol for this disease was recommended by Souza et al. (2021) and is based on blood smears associated with RT. In this context, the use of sensors can be an auxiliary tool in the early diagnosis of the disease, in order to reduce animal slaughter rates, and as a strategy for the rational use of medicines on properties. Research in temperature monitoring has evaluated the use of implantable microchips in detecting changes in body temperature (Auclair-Ronzaud et al., 2020; Giro et al., 2019; Iwasaki et al., 2019; Lee et al., 2016; Woodrum Setser et al., 2020). We established anaplasmosis as a disease model to test the ability of microchips to detect changes in body temperature associated with infection.

The objectives of this study were to evaluate: i) subcutaneous temperature and RT data collected from dairy calves exposed to anaplasmosis; ii) Long Short-Term Memory (LSTM) and Recurrent Neural Network (RNN) for detection of anaplasmosis using microchip and RT data; and iii) investigate the effect of time series length on the predictive performance of LSTM and RNN. Our hypothesis is that the changes in body temperature caused by anaplasmosis challenge in dairy calves can be detected by microchips and that they are useful in detecting the disease without the need to use a clinical rectal thermometer.

## 2. 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.

### 2.1. Pre-weaning period

#### 2.1.1. Calves, housing, and management

Fifty-five Holstein calves with birth weight of  $34.4 \pm 6.3$  kg (mean  $\pm$  SD) were randomly selected from the Embrapa Dairy Cattle experimental farm. Calves were individually raised 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 control 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®).

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 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 a separate 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: RT, nasal discharge, cough, eye discharge, ear positioning, and fecal score according to Larson et al. (1977) and McGuirk (2008). 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 polymerase chain reaction (PCR; Silveira et al., 2014) and indirect immunofluorescence reaction (RIFI; Santos et al., 2017). Twenty-one 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.

### *2.1.2. Microchip implantation and temperature measurement*

Thermal sensing microchips (LifeChip® with Bio-Thermo™ Technology, Destron Fearing™, Langeskov, Denmark) were implanted subcutaneously at the base of the tail on the first day of life of the calves, inserted perpendicularly to the skin through a pre-sterilized 12-gauge needle. The implant site was cleaned with an antiseptic solution. Two milliliters of local anesthetic (20 mg/mL lidocaine hydrochloride) were injected subcutaneously five minutes before microchip implantation. The device is a transponder with an electromagnetic coil and a built-in temperature biosensor that works as passive radio frequency identification (RFID). An Allflex RS420 reader (Allflex - Sistemas de Identificação - Animal Ltda, Joinville, Brazil) was used to read the temperatures given by the microchip (range 33.0 °C – 43.0 °C). Rectal temperature measurements using a Domotherm digital clinical thermometer (Incoterm, Porto Alegre, Brazil, capable of identifying temperatures in the range of 32.0 – 44.0 °C) were performed simultaneously with the measurement of the microchip data. Both measurements (rectal and microchip readings) took place once a day at 6 am. Animals were considered to have fever when the RT was > 39.5 °C.

## *2.2. Post-weaning period*

### *2.2.1. Calves, housing, and management*

After the pre-weaning period, the remaining 24 dairy calves averaging  $132.4 \pm 13.9$  days of age and  $146 \pm 23.3$  kg of BW were randomly grouped (8/group) and moved to three paddocks with  $280 \text{ m}^2$  each, with concrete floor in front of the feed troughs. 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) composed of whole corn silage, ground corn, soybean meal, monensin, and mineral-vitamin (Bovigold Prima®, DSM / Tortuga, Mairinque - SP, Brazil). The 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), which were freely accessible to all animals in the group. 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 RT, nasal discharge, cough, eye discharge, ear positioning, and fecal score.

### *2.2.2. Anaplasmosis inoculation procedure*

Fifteen days before *A. marginale* inoculation, blood samples were collected from the jugular to determine the absence of *A. marginale*, *Babesia bovis*, and *B. bigemina* using PCR and RIFI techniques. Based on PCR and RIFI results, all 24 animals averaging  $132.4 \pm 13.9$  days of age and  $146 \pm 23.3$  kg of BW tested negative and were challenged with a low virulence inoculum dosage ( $2 \times 10^7$  erythrocytes infected) of *A. marginale* UFMG1-EU676176 (Bastos et al., 2010).

### *2.2.3. Laboratory and hematological evaluation*

The PCV and rickettsemia values were used to monitor anaplasmosis progression. The average of PCV values taken twice (once a week for two weeks of adaptation before inoculation) was 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).

The PCV was performed using the microhematocrit method (Weiss and Wardrop, 2010) using heparinized blood in a capillary tube, which was then centrifuged (SPIN 1000, MICRO SPINTM, São Paulo, Brazil) at 800xg for 5 minutes (Schalm et al., 1975). Subsequently, the PCV was obtained using a Hematocrit Reader Card (SPINTM, 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).

## *2.3. Data processing and analysis*

The animals were considered sick when PCV value dropped and achieved 50% or less of average healthy value ( $32 \pm 2.3\%$ ), and the presence of *A. marginale* 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  $35 \pm 3$ d.

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

Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) was used as predictive approaches to detect sick events (50% of healthy PCV value) at d0 and 3 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 layers with 20, 40, 80, 100, or 200 neurons, *tanh* as activation function, dropout ranging from 0–0.01, and recurrent dropout varying from 0–0.05. All models tested used a batch size of 8, 50 epochs, a binary cross-entropy loss function, and *rmsprop* optimizer.

Model validation was performed using Leave-One-Animal-Out Cross-Validation (LOAOCV). In each iteration, the 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. 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 =  $TP/(TP + FP)$  and NPV =  $TN/(TN + FN)$ , where TP, FP, FN, and TN are true positive, false positive, false negative and true negative, respectively.

### 3. RESULTS

Subcutaneous temperature measured by the microchip showed a weak positive relationship ( $r = 0.35$ ,  $P < 0.001$ ) with RT (Figure 1). Moreover, microchip temperatures were, on average,  $1.6^{\circ}\text{C}$  lower than the RT. Rectal temperature, microchip temperature, PCV and rickettsemia as a consequence of exposure to *A. marginale* (15 d before and after d0) are shown in Figure 2. It is worth noting that besides being lower than RT, microchip temperatures were also more variable.

Clinical symptoms (RT, PCV and rickettsemia) were clearly altered due to the disease. The value of PCV at d0 was  $14.8 \pm 2.6\%$ , which represents 46.4% of normal PCV value between -35 and -15 days ( $31.9 \pm 2.3$ ). The mean rickettsemia at d0 was  $4.26 \pm 3.48\%$ .

Rectal temperature values observed up to day -7 were within the physiological range considered normal (below  $39.5^{\circ}\text{C}$ , average of  $38.5 \pm 0.5$ ). There was an increase in RT from -6d. In -3d, the observed RT was  $39.4 \pm 0.7$ , followed by  $39.9 \pm 0.5$  in -2d,  $39.8 \pm 0.6$  in -1d and  $39.7 \pm 0.5^{\circ}\text{C}$  on d0. The response of microchip temperatures to the disease was not as clear. During this same period (-3d to d0), the temperature measured by the microchip presented values of  $37.7 \pm 0.9$ ,  $37.9 \pm 0.9$ ,  $37.6 \pm 1.0$  and  $37.7 \pm 1.3^{\circ}\text{C}$ , respectively.

The architectures of the RNN and LSTM algorithms with the best performance for each time series length (5, 7 and 10 d) in -3d and d0 in relation to anaplasmosis, for temperature measured by the microchip or RT are presented in Tables 1 and 2, respectively. The hyperparameters of the RNN and LSTM models are shown in Tables 3 and 4.

#### *3.1. Performance of predictive models using microchip-measured temperature data*

Using microchip data to detect changes in body temperature caused by anaplasmosis at d0 in relation to disease, ACC values ranged from 62-75% with RNN algorithms and 71-77% with LSTM. At -3d in relation to disease, the RNN algorithms presented ACC values ranging from 56-69% and LSTM from 62-73% (Table 1). The duration of time series moderately

affected the ACC values of the LSTM predictive models at d0 (mean 73, 75 and 74% for time series of 5, 7 and 10d, respectively), while they affected the RNN models more intensely, reducing the values from 71% ACC (time series of 5 and 7d) to 67% (time series of 10d).

At d0, using RNN algorithms, the SEN value was highest in the time series of 5d (64%) and the SPE value was highest in the time series of 7d (80%). Regarding the LSTM algorithms in d0, the duration of the time series did not affect the SEN (mean of 64, 64 and 63% for time series of 5, 7 and 10d, respectively) and had a greater effect on the SPE, which was greater on the time series of 7d (87%) compared to 5d (80.6%) and 10d (84%).

In -3d, the time series of 5d presented the highest SEN and SPE values when compared to the time series of 7d and 10d for both algorithms (RNN and LSTM). Using RNN, the mean values of SEN were 71, 58 and 68% and of SPE were 67, 63 and 50%, in the time series of 5, 7 and 10d respectively. For LSTM, SEN reduced from 76 to 71%, and later to 69%, while SPE presented values of 70, 61 and 64% (time series of 5, 7 and 10d respectively).

### *3.2. Predictive Modeling Performance Using RT Data*

The ACC of the predictive models of RNN and LSTM using RT data related to anaplasmosis at d0 ranged from 92-98% and 96-98%, respectively. At -3d, RNN had ACC values ranging from 77-88% and LSTM had ACC of 71-83% (Table 2).

At d0, the length of the time series did not affect the mean ACC values of the RNN models (mean 96%). In the LSTM models, the mean ACC was 96, 97 and 97% in the time series of 5, 7 and 10 d, respectively, also not showing significant effects of the time series length. In all time series at d0, we found models with SEN and NPV of 100% and with SPE and PPV of 96%.

At -3d, the ACC of the models reduced with the increase in the length of the time series. In the RNN models, the ACC presented mean values of 86, 83 and 81%, while in the LSTM the ACC presented values of 81, 74 and 75%, for time series of 5, 7 and 10 d, respectively. The SEN of the RNN models was not substantially affected by time series (81% in the 5 and 7 d TS, and 79% in 10 d), while the SPE reduced from 90 to 85% (time series of 5 to 7 d), and later to 83% (time series of 10 d). In LSTM models, SEN presented values of 71, 60 and 69%, and SPE presented mean values of 91, 89 and 80% in time series of 5, 7 and 10 d respectively.

## **4. DISCUSSION**

We evaluated the feasibility of using a BioThermo microchip to detect changes in subcutaneous temperature compared to RT measured by a clinical thermometer. Such changes

in body temperature were related to anaplasmosis disease in dairy calves, based on a challenge model with a low virulence inoculum of *A. marginale* UFMG1 - EU676176. Through clinical evaluation during the challenge and by applying machine learning approaches on the data analysis, we observed that the microchip temperatures did not have the same potential in detecting anaplasmosis in calves compared to RT. Thus, the hypothesis “changes in body temperature caused by anaplasmosis challenge in dairy calves can be detected by microchips and these devices are useful in detecting the disease without the need to use a clinical rectal thermometer” was rejected.

#### *4.1. Evaluation of the microchip as a temperature measure device*

In several studies, rectal or ear temperatures are considered the standard for body temperature in mammals and are used as a reference for the development of alternative, less laborious, methods of temperature measurement (Adams et al., 2013; Iwasaki et al., 2019; Lee et al., 2016; Woodrum Setser et al., 2020). We observed a weak, despite significant, correlation between RT and microchip temperature. The microchip was placed subcutaneously on the left side of the tail base. This site was chosen based on previous studies that used implants to assess temperature at different anatomical sites. Iwasaki et al. (2019) evaluated ten thermometer implantation sites in a cow and observed a good correlation between the base of the tail and RT ( $r = 0.62$ ). Vieira et al. (2021) found a greater correlation between measurements of the microchip implanted subcutaneously at the tail base and RT ( $r = 0.60$ ) when compared to the implant in the ear ( $r = 0.56$ ), leg ( $r = 0.53$ ) and navel ( $r = 0.48$ ) in calves.

In a review of the evaluation of core, skin, and other body tissue temperatures in humans, Taylor et al. (2014) reported that the temperature is influenced by the measurement site, as tissue temperatures are modified by local metabolism and blood flow. Furthermore, the authors stated that unless the measurement sites are closely located, perfused by the same blood vessels, and have equivalent metabolic rates, temperatures would have no relationship. In fact, the proximity between the base of the tail and the rectum was the explanation for the correlation observed by Vieira et al. (2021). However, our results did not agree with those of the previous study. One possible explanation is that blood flow is limited in superficial tissues compared to deeper tissues, and because of this, the area where the microchip was placed does not experience the same temperature changes guided by blood flow in a feverish situation as in the visceral tissues, more specifically in this study, the rectum.

Woodrum Setser et al. (2020) highlighted the variability found among animals for the correlations of microchip temperature with RT and emphasized that individual variation should

be weighted to improve temperature prediction technologies. In our study, we did find positive correlations between microchip and RT in individual animals, however, values were low (data not shown).

Besides the weak correlation, microchip temperature was consistently lower and more variable than RT. Similar results have been reported with ponies (Goodwin, 1998), horses (Robinson et al., 2008), dogs (Greer et al., 2007) and cow (Iwasaki et al., 2019). In fact, Reid et al. (2012), during a lipopolysaccharide (LPS) challenge in steers reported differences between RT (using a clinical thermometer) and the temperature of subcutaneous microchips similar to our findings ( $1.8^{\circ}\text{C}$ ). Moreover, Giro et al. (2019) found an even larger difference between microchip-measured subcutaneous temperature and RT ( $2.7^{\circ}\text{C}$ ).

These results demonstrated that the microchip device is not a good replacement for the clinical thermometer to assess body temperature of dairy calves. However, it could still be useful in detecting disease using its own measurements during health periods as baseline.

#### *4.2. Clinical condition associated with inoculation-induced anaplasmosis*

The strain of *A. marginale* - UFMG1 used in this study is considered to have low virulence (Bastos et al., 2010; Coelho, 2007; Silvestre et al., 2016), but capable of triggering the disease in calves, as evidenced by the decreased PCV values and the increase in RT and rickettsemia observed in our results. These responses throughout the challenge are consistent with previous reports.

While typical PCV values in healthy cattle range from 24 to 46% (Radostits et al., 2007), Coelho (2007) and Oliveira Júnior et al. (2018), who also worked with *A. marginale*, observed mean PCV values of 13.0 and 13.4%, respectively, similar to the 14.8% from our study. On the other hand, the RT reported by Oliveira Júnior et al. (2018) was  $40.4 \pm 0.5^{\circ}\text{C}$  at d0, higher than that observed in this study. A positive correlation between RT and rickettsemia was reported by Kocan et al. (2003) and was observed in our results, also in agreement with the characteristic responses of anaplasmosis reported by Coelho (2007).

Woodrum Setser et al. (2020) evaluated the performance of microchips in measuring body temperature and suggested that future research investigate the functioning of this device during periods of illness and fever. The increase in red blood cells infected by *A. marginale* intensifies the immune response, releasing inflammatory mediators that cause fever (Coelho, 2007). In this perspective, we expected that during the anaplasmosis challenge, the microchip temperature data would change in a similar manner to the RT data, which did not occur.

Gordon et al. (2002) observed a decrease in tail temperature in rats when challenged by LPS. The authors reported that core body temperature increased from 37.0 to 38.5 °C and tail temperature decreased from 28.0 to 25.5 °C after LPS administration, suggesting that heat dissipation mechanisms are altered to avoid a feverish response.

In the study by Reid et al. (2012), also during an LPS-induced febrile response, the microchip data behaved contrary to the RT data. The rationale for these findings is that as blood flow shifts from the periphery to the center of the body during fever, blood pressure decreases, corresponding to that reported in mice (Romanovsky et al., 1996). After the reduction in blood pressure, a decrease in subcutaneous temperature could be seen. However, we did not observe a clear decrease in the microchip temperature during the challenge.

#### *4.3. Effects of time series length on the predictive quality of models*

We investigated the effect of time series length on the predictive performance of the models since it can expressively affect the computational needs for data processing. Overall, there was no benefit in using a longer time series to establish healthy base line in detecting anaplasmosis. When evaluating the microchip data, we observed higher values of ACC, SEN and SPE in the 5 and 7 d time series compared to 10 d. For RT, there was no effect of time series on model performance. Thus, a sequence of 5 to 7 days sequence was adequate to establish the healthy base line for disease detection. Teixeira et al. (2022) found similar results for the detection of anaplasmosis in dairy calves based on rumination and activity data. The great relevance of using shorter time series is the possibility of reducing the use of computational resources in future studies.

#### *4.4. Prediction of anaplasmosis from temperature data and machine learning approaches*

We evaluated whether it would be possible to identify sick calves before the onset of the most critical symptoms of anaplasmosis (-3 d) or on the day considered most severe during the challenge (d0), using predictive models based on microchip-measured subcutaneous temperature and RT data measured by clinical thermometer. Early identification of sick calves makes it possible to administer treatment only to animals at risk, with less time to recovery, reducing production losses and minimizing the use of antibiotics. (Duff and Galyean, 2007; Thompson et al., 2006).

Our results showed that RT measured by a clinical thermometer can be used to develop models to predict accurately of disease and allows for early accurate detection. This demonstrates the high potential of machine learning models to recognize disease onset when

the PCV represents about 70% of the healthy normal value and the animal is in a lesser debilitated state. Therefore, prescribing early treatment based on RT data can improve treatment efficacy and reduce calf mortality from anaplasmosis, but there are other pathogens and physiological situations that can cause fever, hence, a complementary PCV and blood smear should be used to drive the treatment.

Based on RT we also found the best prediction models for d0. Although the prediction models at d0 using the microchip have shown mean ACC greater than 70% in the 5 and 7 day time series in both algorithms (RNN and LSTM), the prediction at d0 using RT was expressively better (with ACC, SEN and SPE above 95%), allowing more precise decision making.

For microchip data, the application of the prediction model at d0 or -3d, in the time series of 5d, resulted in similar ACC (about 70%), but at -3d the models had a higher SEN compared to d0, indicating a greater chance of detecting truly sick individuals (SEN 71% and 76% with RNN and LSTM, respectively vs 64%). Still, about 30% of these individuals would go undiagnosed.

Sensitivity and SPE are absolute properties of a test and do not vary with disease prevalence (Nielsen et al., 2004). The SEN and SPE values found using microchip data suggest that the models failed to correctly identify the incidences of pyrexia associated with *A. marginale* challenge, which would imply the need for periodic monitoring of all animals to identify non-diseased calves recognized by the sensor. In this way, this tool can be used as an alert to examine animals, as they may be at risk of becoming ill and need individualized attention. However, it does not exclude the use of RT as part of the diagnosis of anaplasmosis.

#### *4.5. Implications*

The RT allows for anticipation of the diagnosis of the disease, but the difficulties in measuring it remains a problem. An implantable microchip could be an easy and quick initial screening method to detect febrile calves as part of a health check protocol. In addition, it would contribute to welfare (Relić et al., 2020), reducing animal handling and possible changes in their normal behavior during RT measurement. However, the microchip did not perform the way we expected, as the temperature did not vary in a predictable manner. As it is a more variable measure than the thermometer, this high variability may have made it difficult to detect a temperature pattern associated with the challenge. Thus, despite the positive aspects of using microchips as a non-invasive tool, including ease of deployment and measurement in many animals, using less time and labor, it does not prove to be at a functional stage where it can be

used to reliably detect pyrexia and sick calves. Additionally, our results were obtained in a fully controlled experiment, in which only anaplasmosis affected the evaluated variables. In farm conditions, there are several agents that can cause health problems in a more complex manner.

## 5. CONCLUSIONS

The change in body temperature due to anaplasmosis challenge was particularly characterized by variation in RT, which was not reflected with the microchip data. Based on the performance of machine learning models to identify calves with anaplasmosis using microchip data, we conclude that using this device alone to measure body temperature is not sufficient in anaplasmosis therapy. The measurement of RT is even better suited to detecting changes in temperature that indicate illness and can guide treatment.

## 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 and support in this study. The mention of 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.

## REFERENCES

- Adams, A. E., Olea-Popelka, F. J., Roman-Muniz, I. N., 2013. Using temperature-sensing reticular boluses to aid in the detection of production diseases in dairy cows. *J. Dairy Sci.* <https://doi.org/10.3168/jds.2012-5822>
- Aubry, P., Geale, D. W., 2011. A review of Bovine anaplasmosis. *Transbound. Emerg. Dis.* <https://doi.org/10.1111/j.1865-1682.2010.01173.x>
- Auclair-Ronzaud, J. M., Benoist, S., Dubois, C., Frejaville, M., Jousset, T., Jaffrézic, F., Wimel, L., Chavatte-Palmer, P., 2020. No-contact microchip monitoring of body temperature in yearling horses. *J. Equine Vet. Sci.* 86, 102892. <https://doi.org/10.1016/j.jevs.2019.102892>
- Bastos, C. V., Passos, L. M. F., Facury-Filho, E. J., Rabelo, E. M., de la Fuente, J., Ribeiro, M. F. B., 2010. Protection in the absence of exclusion between two Brazilian isolates of *Anaplasma marginale* in experimentally infected calves. *Vet. J.* <https://doi.org/10.1016/j.tvjl.2009.09.013>
- Coelho, L. C. T., 2007. Anaplasmoses 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., Ernst, S. E., Trevino, J. L., Gladney, W. J. Graham, O. H., 1973. *Boophilus annulatus* and *B. microplus*: laboratory tests of insecticides. *J. Econ. Entomol.* <https://doi.org/10.1093/jee/66.1.130>
- Duff, G. C., Galyean, M. L., 2007. Board-invited review: recent advances in management of highly stressed, newly received feedlot cattle. *J. Anim. Sci.* 85, 823-840. <https://doi.org/10.2527/jas.2006-501>
- Facury-Filho, E. J., de Carvalho, A. Ú., Ferreira, P. M., Moura, M. F., Apolinário, B. C., Santos, L. P. H., Ribeiro, M. F. B., 2012. Effectiveness of enrofloxacin for the treatment of experimentally-induced bovine anaplasmosis. *Rev. Bras. Parasitol. Vet.* <https://doi.org/10.1590/s1984-29612012000100007>
- Giro, A., Bernardi, A. C. de C., Barioni Junior, W., Lemes, A. P., Botta, D., Romanello, N., Barreto, A. do N., Garcia, A. R., 2019. Application of microchip and infrared thermography for monitoring body temperature of beef cattle kept on pasture. *J. Therm. Biol.* <https://doi.org/10.1016/j.jtherbio.2019.06.009>
- Goodwin, S. D., 1998. Comparison of body temperatures of goats, horses and sheep measured with a tympanic infrared thermometer, an implantable microchip transponder, and a rectal thermometer. *J. Am. Assoc. Lab. Anim. Sci.* 37, 51–55.
- Gordon, C., Puckett, E., Padnos., B. 2002. Rat tail skin temperature monitored noninvasively by radiotelemetry: Characterization by examination of vasomotor responses to thermomodulatory agents. *Journal of pharmacological and toxicological methods.* 47, 107-14. [https://doi.org/10.1016/S1056-8719\(02\)00219-8](https://doi.org/10.1016/S1056-8719(02)00219-8)

- Greer, R. J., Cohn, L. A., Dodam, J. R., Wagner-Mann, C. C., Mann, F. A., 2007. Comparison of 3 methods of temperature measurement in hypothermic, euthermic, and hyperthermic dogs. *J. Am. Vet. Med. Assoc.* 230, 1841–1848.
- Hochreiter, S., J. Schmidhuber. 1997. Long Short-Term Memory. *Neural Comput.* 9, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- IICA. 1987. Técnicas para el diagnóstico de babesiosis y anaplasmosis bovina. San José.
- Iwasaki, W., Ishida, S., Kondo, D., Ito, Y., Tateno, J., Tomioka, M., 2019. Monitoring of the core body temperature of cows using implantable wireless thermometers. *Comput. Electron. Agric.* <https://doi.org/10.1016/j.compag.2019.06.004>
- Kocan, K. M., de la Fuente, J. Blouin, E. F., Coetzee, J. F., Ewing, S. A., 2010. The natural history of *Anaplasma marginale*. *Vet. Parasitol.* 167, 95-107. <https://doi.org/10.1016/j.vetpar.2009.09.012>
- Kocan, K. M., De La Fuente, J. Guglielmone, A. A., Meléndez, R. D., 2003. Antigens and alternatives for control of *Anaplasma marginale* infection in cattle. *Clin. Microbiol. Rev.* 16, 698-712. <https://doi.org/10.1128/CMR.16.4.698-712.2003>
- Larson, L. L., Owen, F. G., Albright, J. L., Appleman, R. D., Lamb, R. C., Muller, L. D., 1977. Guidelines toward more uniformity in measuring and reporting calf experimental data. *J. Dairy Sci.* [https://doi.org/10.3168/jds.S0022-0302\(77\)83975-1](https://doi.org/10.3168/jds.S0022-0302(77)83975-1)
- Lee, Y., Bok, J. D., Lee, H. J., Lee, H. G., Kim, D., Lee, I., Kang, S. K., Choi, Y. J., 2016. Body temperature monitoring using subcutaneously implanted thermo-loggers from Holstein steers. *Asian-Australas. J. Anim. Sci.* 29, 299–306. <https://doi.org/10.5713/ajas.15.0353>
- Lombard, J., Urie, N., Garry, F., Godden, S., Quigley, J., Earleywine, T., McGuirk, S., Moore, D., Branan, M., Chamorro, M., Smith, G., Shivley, C., Catherman, D., Haines, D., Heinrichs, A. J., James, R., Maas, J., Sterner, K., 2020. Consensus recommendations on calf and herd-level passive immunity in dairy calves in the United States. *J. Dairy Sci.* <https://doi.org/10.3168/jds.2019-17955>
- 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.* <https://doi.org/10.1016/j.cvfa.2007.10.003>
- Mendonça, F. L. M., 2015. 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. MS thesis. Universidade Federal de Minas Gerais, Belo Horizonte, Brazil.
- Moreira, G. H. F. A., 2017. Fatores de risco e impacto da tristeza parasitária bovina. PhD dissertation. Universidade Federal de Minas Gerais, Belo Horizonte, Brazil.

- Nielsen, S. S., Houe, H., Ersbøll, A. K., Toft, N., 2004. Evaluating diagnostic tests. In: Houe, H., Ersbøll, A.K., Toft, N. (Eds.), Introduction to Veterinary Epidemiology. Biofolia, Frederiksberg, pp. 133-151.
- OIE. 2019. Introduction to the recommendations for animal welfare. Terr. Anim. Heal. Code.
- Oliveira Júnior, B. R., Silper, B. F., Ribas, M. N., Machado, F. S., Lima, J. A. M., Cavalcanti, L. F. L., Coelho, S. G., 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. <https://doi.org/10.3168/jds.2018-14637>
- Radostits, O., Gay, C., Gay, C., Hinchcliff, K., Constable, P., 2007. A textbook of the diseases of cattle, horses, sheep, pigs and goats: veterinary medicine. *Vet. Med.*
- Reid, E. D., Fried, K., Velasco, J. M., Dahl, G. E., 2012. Correlation of rectal temperature and peripheral temperature from implantable radio-frequency microchips in Holstein steers challenged with lipopolysaccharide under thermoneutral and high ambient temperatures. *J. Anim. Sci.* <https://doi.org/10.2527/jas.2011-4705>
- Relić, R., J. Starič, and J. Ježek. 2020. Management practices that influence the welfare of calves on small family farms. *J. Dairy Res.* <https://doi.org/10.1017/S0022029920000539>
- Robinson, T. R., Hussey, S. B., Hill, A. E., Heckendorf, C. C., Stricklin, J. B., Traub-Dargatz, J. L., 2008. Comparison of temperature readings from a percutaneous thermal sensing microchip with temperature readings from a digital rectal thermometer in equids. *J. Am. Vet. Med. Assoc.* 233, 613-617. <https://doi.org/10.2460/javma.233.4.613>
- Romanovsky, A. A., Shido, O., Sakurada, S., Sugimoto, N., Nagasaka T., 1996. Endotoxin shock: thermoregulatory mechanisms. *Am. J. Physiol. Regulatory Integrative Comp. Physiol.* 270, R693-R703. <https://doi.org/10.1152/ajpregu.1996.270.4.R693>
- Santos, G. B., Gomes, I. M. M., Silveira, J. A. G., Pires, L. C. S. R., Azevedo, S. S., Antonelli, A. C., Ribeiro, M. F. B., Horta, M. C., 2017. Tristeza parasitária em bovinos do semiárido pernambucano. *Pesqui. Vet. Bras.* <https://doi.org/10.1590/S0100-736X2017000100001>
- Schalm, O. W., Jain, N. C., Carroll, E. J., 1975. Veterinary hematology. *Vet. Hematol.*
- Silveira, J. A. G. da., Rabelo, É. M. L., Lima, P. C. S., Chaves, B. N., Ribeiro, M. F. B., 2014. Post-mortem hemoparasite detection in free-living Brazilian brown brocket deer (*Mazama gouazoubira*, Fischer 1814). *Rev. Bras. Parasitol. Veterinária.* <https://doi.org/10.1590/s1984-29612014035>
- Silvestre, B. T., Silveira, J. A. G., Meneses, R. M., Facury-Filho, E. J., Carvalho, A. U., Ribeiro, M. F. B., 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. <https://doi.org/10.1016/j.ttbdis.2015.09.001>

- Souza, J. C. P. de., Soares, C. O., Madruga, C. R., Massard, C. L., 2001. Prevalência de anticorpos anti *Anaplasma marginale* (Rickettsiales: Anaplasmataceae) em bovinos na mesorregião do médio Paraíba. Ciência Rural. <https://doi.org/10.1590/s0103-84782001000200019>
- Souza, R. S., Resende, M. F. S., Ferreira, L. C. A., Ferraz, R. S., Araújo, M. V. V., Bastos, C. V., Silveira, J. A. G., Moreira, T. F., Meneses, R. M., Carvalho, A. U., Leme, F. O. P., Facury-Filho, E. J., 2021. Monitoring bovine tick fever on a dairy farm: An economic proposal for rational use of medications. J. Dairy Sci. <https://doi.org/10.3168/jds.2020-19504>
- Taylor, N. A. S., Tipton, M. J., Kenny, G. P., 2014. Considerations for the measurement of core, skin and mean body temperatures. J. Therm. Biol. <https://doi.org/10.1016/j.jtherbio.2014.10.006>
- Thompson, P. N., Stone, A., Schultheiss, W. A., 2006. Use of treatment records and lung lesion scoring to estimate the effect of respiratory disease on growth during early and late finishing periods in South Africa feedlot cattle. J. Anim. Sci. 84, 488-498. <https://doi.org/10.2527/2006.842488x>
- Ueti, M. W., Tan, Y., Broschat, S. L., Ortiz, E. J. C., Camacho-Nuez, M., Mosqueda, J. J., Scoles, G. A., Grimes, M., Brayton, K. A., Palmerc, G. H., 2012. Expansion of variant diversity associated with a high prevalence of pathogen strain superinfection under conditions of natural transmission. Infect. Immun. <https://doi.org/10.1128/IAI.00341-12>
- Vieira, E. A., Belli, A. L., Campolina, J. P., Rodrigues, J. P. P., Coelho, S. G., Campos, M. M., Tomich, T. R., Pereira, L. G. R., 2021. Screening microchip sites to predict body temperature in young calves. J. Therm. Biol. 100, 103052. <https://doi.org/10.1016/j.jtherbio.2021.103052>
- Weiss, J. D., Wardrop, K. J., 2010. Schalm's Veterinary Hematology 6th Ed.
- Woodrum Setser, M. M., Cantor, M. C., Costa, J. H. C., 2020. A comprehensive evaluation of microchips to measure temperature in dairy calves. J. Dairy Sci. <https://doi.org/10.3168/jds.2019-17999>

Figure 1. Correlation between temperature data measured by Bio-Thermo microchip and rectal temperature measured by digital clinical thermometer during 66 days of observations, including an anaplasmosis challenge, in Holstein dairy calves.

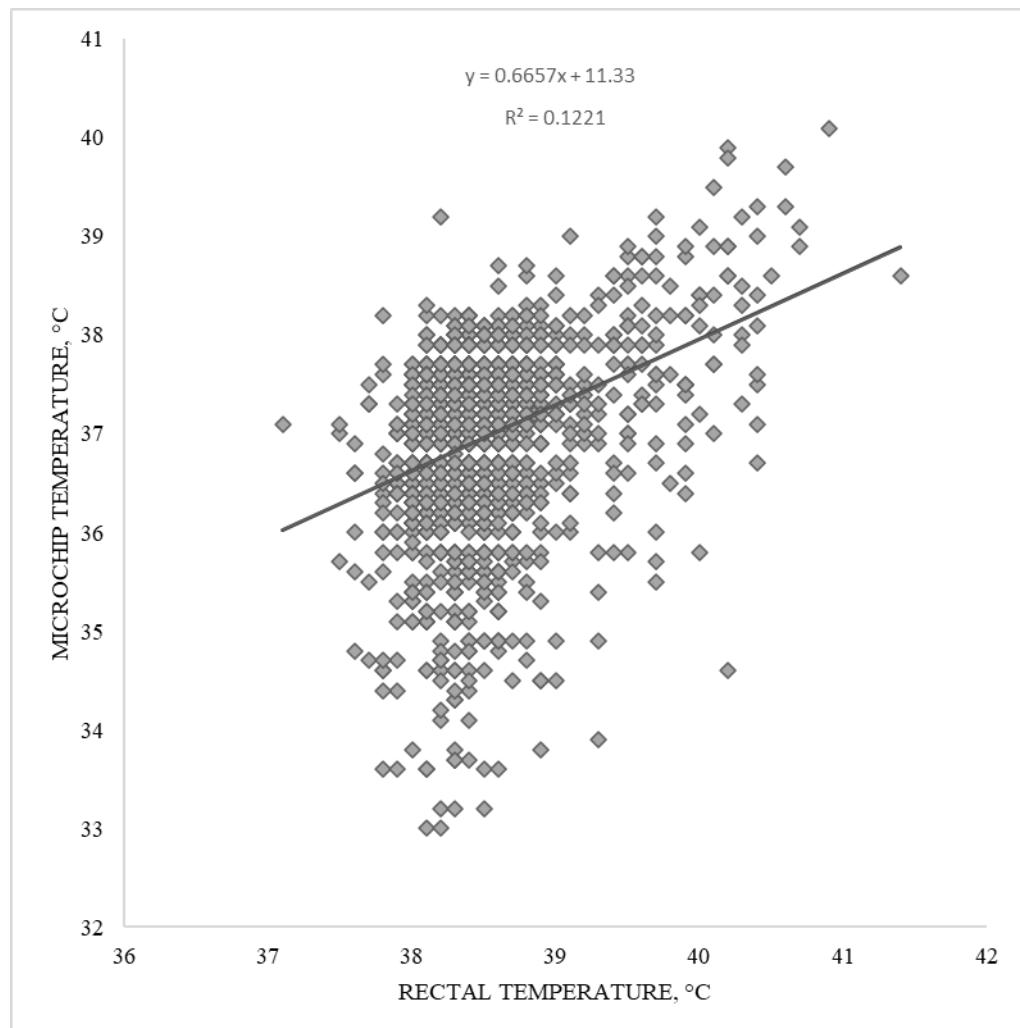


Figure 2. Effects of *Anaplasma marginale* inoculation on rectal temperature (A), microchip temperature (B), packed cell volume (C) and rickettsemia (D) and in Holstein dairy calves according to days relative to sickness (DRS).

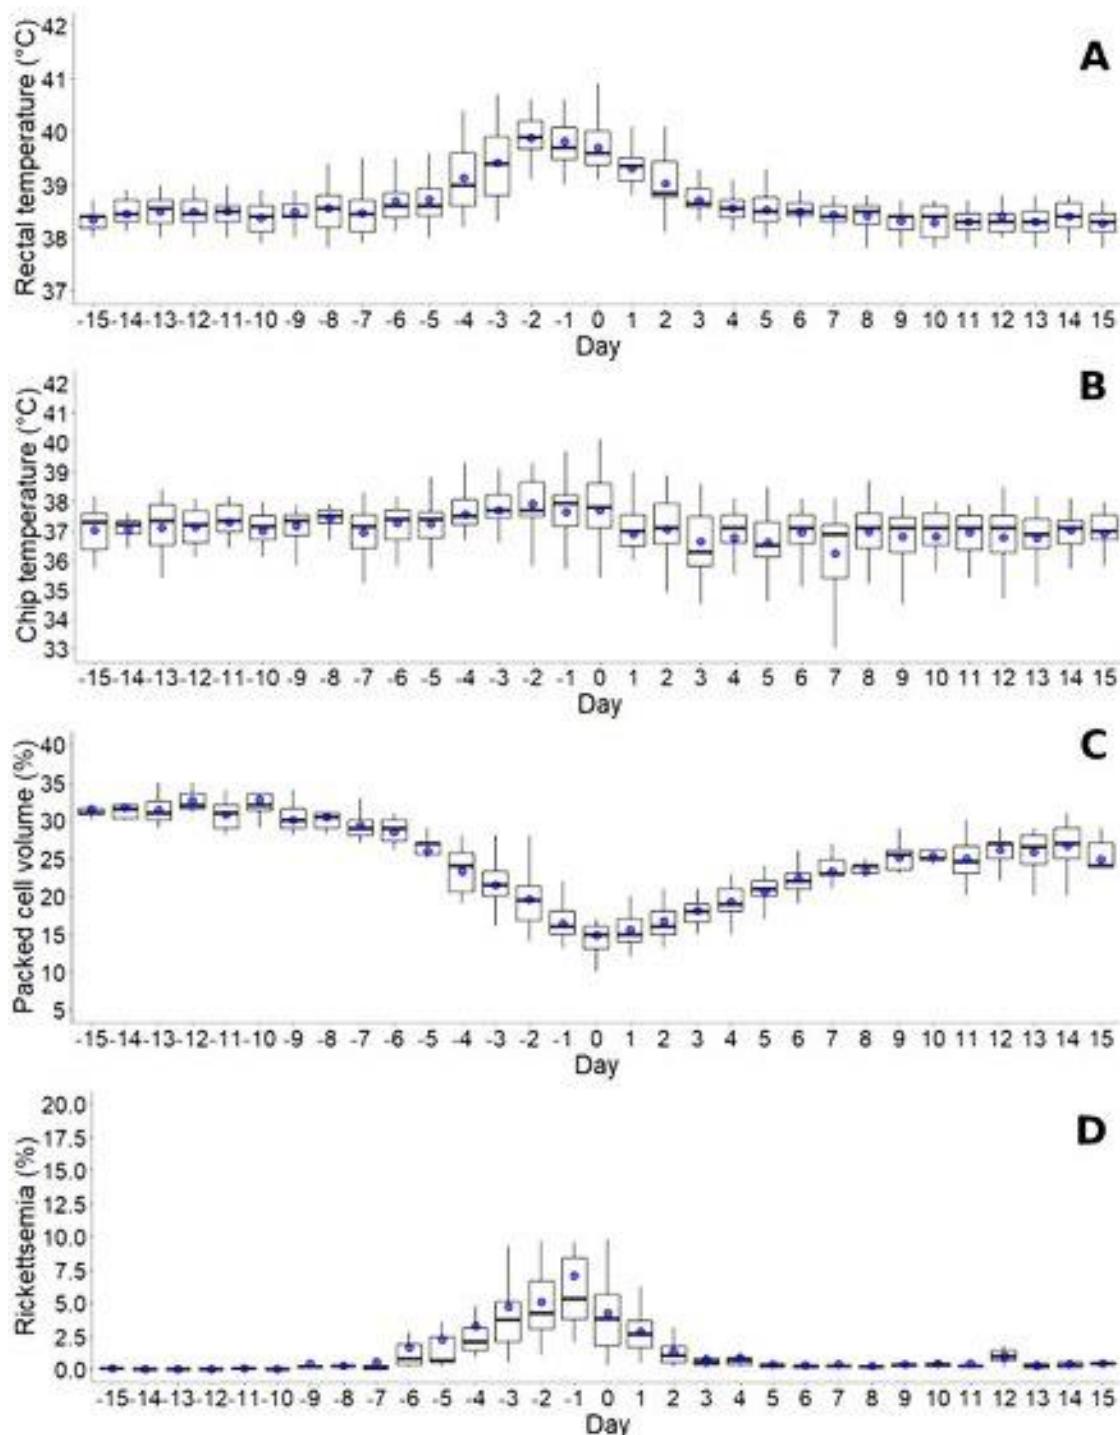


Table 1. Performance of different models of RNN and LSTM based on temperature data measured by the BioThermo microchip to detect anaplasmosis using different time series length in relation to the d0 and -3 d of the disease (DRS) in Holstein dairy calves.

Time series	DRS	Model reference	RNN					LSTM				
			ACC	SEN	SPE	PPV	NPV	ACC	SEN	SPE	PPV	NPV
5 days	0	1	73	67	79	76	70	75	67	83	80	71
	0	2	71	62	79	75	68	73	62	83	79	69
	0	3	71	67	75	73	69	73	62	83	79	69
	0	4	69	62	75	71	67	71	67	75	73	69
	0	5	69	62	75	71	67	71	62	79	75	68
	-3	1	69	71	67	68	70	73	75	71	72	74
	-3	2	69	71	67	68	70	73	75	71	72	74
	-3	3	69	71	67	68	70	73	79	67	70	76
	-3	4	69	71	67	68	70	73	75	71	72	74
	-3	5	69	71	67	68	70	73	75	71	72	74
7 days	0	1	75	71	79	77	73	77	67	88	84	72
	0	2	71	58	83	78	67	75	62	88	83	70
	0	3	71	62	79	75	68	75	62	88	83	70
	0	4	71	62	79	75	68	75	67	83	80	71
	0	5	67	54	79	72	63	75	62	88	83	70
	-3	1	65	62	67	65	64	69	71	67	68	70
	-3	2	62	62	62	62	62	67	71	62	65	68
	-3	3	60	58	62	61	60	67	71	62	65	68
	-3	4	60	54	67	62	59	65	71	58	63	67
	-3	5	56	54	58	57	56	62	71	54	61	65
10 days	0	1	71	67	75	73	69	75	67	83	80	71
	0	2	69	62	75	71	67	75	67	83	80	71
	0	3	67	67	67	67	67	75	62	88	83	70
	0	4	67	57.9	75	70	64	73	62	83	79	69
	0	5	62	54	71	65	61	71	58	83	78	67
	-3	1	60	67	54	59	62	69	71	67	68	70
	-3	2	60	71	50	59	63	69	71	67	68	70
	-3	3	58	67	50	57	60	67	71	62	65	68
	-3	4	58	71	46	57	61	65	67	62	64	65
	-3	5	56	62	50	56	56.9	65	67	62	64	65

Table 2. Performance of different models of RNN and LSTM based on rectal temperature data measured by clinical thermometer to detect anaplasmosis using different duration of time series in relation to disease d0 and -3 d (DRS) in Holstein dairy calves.

Time series	DRS	Model reference	RNN					LSTM				
			ACC	SEN	SPE	PPV	NPV	ACC	SEN	SPE	PPV	NPV
5 days	0	1	96	96	96	96	96	98	100	96	96	100
	0	2	96	96	96	96	96	96	100	92	92	100
	0	3	96	96	96	96	96	96	96	96	96	96
	0	4	96	96	96	96	96	96	96	96	96	96
	0	5	94	96	92	92	96	96	96	96	96	96
	-3	1	88	83	92	91	85	83	75	92	90	79
	-3	2	88	83	92	91	85	81	67	96	94	74
	-3	3	85	79	92	90	81	81	71	92	89	76
	-3	4	85	83	88	87	84	79	71	88	85	75
	-3	5	83	79	88	86	81	79	71	88	85	75
7 days	0	1	98	96	100	100	96	98	100	96	96	100
	0	2	96	96	96	96	96	98	100	96	96	100
	0	3	96	96	96	96	96	98	100	96	96	100
	0	4	94	96	92	92	96	96	100	92	92	100
	0	5	94	96	92	92	96	96	100	92	92	100
	-3	1	85	88	83	84	87	77	67	88	84	72
	-3	2	83	83	83	83	83	75	58	92	88	69
	-3	3	83	79	88	86	81	75	58	92	88	69
	-3	4	81	79	83	83	80	73	62	83	79	69
	-3	5	81	75	88	86	78	71	54	88	81	66
10 days	0	1	98	100	96	96	100	98	100	96	96	100
	0	2	98	100	96	96	100	98	100	96	96	100
	0	3	96	100	92	92	100	98	100	96	96	100
	0	4	94	96	92	92	96	96	96	96	96	96
	0	5	92	88	96	95	88	96	96	96	96	96
	-3	1	83	83	83	83	83	77	71	83	81	74
	-3	2	83	79	88	86	81	75	71	79	77	73
	-3	3	83	83	83	83	83	75	67	83	80	71
	-3	4	79	79	79	79	79	75	71	79	77	73
	-3	5	77	71	83	81	74	71	67	75	73	69

Table 3. Hyperparameters of different models of RNN and LSTM based on temperature data measured by the BioThermo microchip to detect anaplasmosis using different time series length in relation to the d0 and -3d of the disease (DRS) in Holstein dairy calves.

Time series	DRS	Model reference	RNN			LSTM		
			Neurons	Dropout	Recurrent dropout	Neurons	Dropout	Recurrent dropout
5 days	0	1	20	0.01	0.05	8080	0.01	0.001
	0	2	20	0.005	0.05	8080	0.001	0.01
	0	3	20	0.001	0.05	100100	0.01	0.001
	0	4	20	0	0.05	8080	0	0.001
	0	5	20	0.005	0.01	8080	0.01	0.01
	-3	1	100	0.005	0.001	20	0.001	0.01
	-3	2	200	0.01	0	20	0.005	0.005
	-3	3	200	0.01	0.001	20	0.01	0.005
	-3	4	8080	0.001	0.001	20	0.01	0.01
	-3	5	200200	0	0.05	20	0.001	0
7 days	0	1	20	0.005	0.01	80	0.005	0.005
	0	2	20	0.001	0.01	100	0.001	0.005
	0	3	20	0	0.01	80	0.005	0.001
	0	4	20	0.005	0	80	0.01	0
	0	5	20	0.005	0.005	100	0.005	0.001
	-3	1	200	0	0	40	0.005	0.05
	-3	2	4040	0.001	0	40	0	0.05
	-3	3	200	0	0.05	40	0.001	0.01
	-3	4	80	0.001	0.005	40	0.005	0
	-3	5	4040	0.01	0	40	0.01	0.001
10 days	0	1	20	0	0.01	40	0.005	0
	0	2	20	0.001	0.05	40	0.01	0.01
	0	3	20	0.001	0.005	80	0.005	0.01
	0	4	20	0.001	0.001	80	0.01	0.01
	0	5	20	0.01	0	100100	0.01	0.005
	-3	1	20	0.001	0.01	40	0.005	0.001
	-3	2	20	0.001	0	40	0	0.001
	-3	3	20	0.005	0.01	40	0	0
	-3	4	20	0.001	0.05	40	0.005	0.05
	-3	5	20	0.005	0	40	0.01	0.05

Table 4. Hyperparameters of different models of RNN and LSTM based on rectal temperature data measured by clinical thermometer to detect anaplasmosis using different duration of time series in relation to disease d0 and -3 d (DRS) in dairy calves.

Time series	DRS	Model reference	RNN			LSTM		
			Neurons	Dropout	Recurrent dropout	Neurons	Dropout	Recurrent dropout
5 days	0	1	20	0.01	0.05	100100	0.001	0.01
	0	2	20	0	0.01	200200	0	0.005
	0	3	20	0.001	0	8080	0.01	0.01
	0	4	20	0.01	0	100100	0.01	0.001
	0	5	20	0.01	0.01	100100	0.01	0
	-3	1	8080	0.001	0.005	200	0	0.005
	-3	2	8080	0	0.01	40	0	0.01
	-3	3	200200	0.01	0.005	100	0.01	0.01
	-3	4	100100	0.001	0.005	200	0	0.05
	-3	5	200200	0	0.001	200	0.01	0.05
7 days	0	1	2020	0	0.05	200200	0.01	0.001
	0	2	2020	0	0	200200	0.005	0.005
	0	3	200200	0.005	0.001	100100	0.005	0.05
	0	4	2020	0.001	0	100100	0.001	0.001
	0	5	2020	0.005	0.01	200200	0	0
	-3	1	8080	0.001	0.01	20	0.001	0.05
	-3	2	100100	0.01	0.05	20	0.01	0.05
	-3	3	200200	0.001	0.05	20	0.005	0
	-3	4	100100	0	0.01	20	0	0
	-3	5	100100	0.005	0.05	20	0.01	0.001
10 days	0	1	200200	0	0.005	200200	0.01	0.05
	0	2	20	0.001	0	200200	0.005	0.05
	0	3	20	0	0.005	200200	0.005	0.01
	0	4	2020	0.01	0.05	200200	0	0.005
	0	5	20	0.01	0.005	200200	0.01	0
	-3	1	100100	0	0	20	0	0.005
	-3	2	100100	0.001	0.001	20	0.01	0
	-3	3	100100	0.001	0.01	20	0	0.01
	-3	4	200200	0.005	0.005	20	0.01	0.005
	-3	5	100100	0.01	0.001	20	0.001	0.005