UNIVERSIDADE DE SÃO PAULO
FACULDADE DE ZOOTECNIA E ENGENHARIA DE ALIMENTOS

VERÔNICA MADEIRA PACHECO

**Desenvolvimento de classificador de conforto térmico para bovinos
de leite utilizando modelagem computacional e termografia de
infravermelho**

Pirassununga

2019

VERÔNICA MADEIRA PACHECO

**Desenvolvimento de classificador de conforto térmico para bovinos
de leite utilizando modelagem computacional e termografia de
infravermelho**

Versão Corrigida

Dissertação apresentada à Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo, como parte dos requisitos para a obtenção do Título de Mestre em Ciências.

Área de Concentração: Qualidade e Produtividade Animal

Orientador: Prof. Dra. Luciane Silva Martello

Co-orientador: Prof. Dr. Rafael Vieira de Sousa

Pirassununga

2019

Ficha catalográfica elaborada pelo
Serviço de Biblioteca e Informação, FZEA/USP,
com os dados fornecidos pelo(a) autor(a)

M116d Madeira Pacheco, Verônica
Desenvolvimento de classificador de conforto
térmico para bovinos de leite utilizando modelagem
computacional e termografia de infravermelho /
Verônica Madeira Pacheco ; orientadora Luciane
Silva Martello ; coorientador Rafael Vieira de
Sousa. -- Pirassununga, 2019.
91 f.

Dissertação (Mestrado - Programa de Pós-Graduação
em Zootecnia) -- Faculdade de Zootecnia e
Engenharia de Alimentos, Universidade de São Paulo.

1. Aprendizagem de máquina. 2. Bem-estar animal
. 3. Estresse térmico. 4. Mineração de dados. 5.
Termografia de infravermelho. I. Silva Martello,
Luciane, orient. II. Vieira de Sousa, Rafael,
coorient. III. Título.

VERÔNICA MADEIRA PACHECO

**Desenvolvimento de classificador de conforto térmico para bovinos de leite utilizando
modelagem computacional e termografia de infravermelho**

Dissertação apresentada à Faculdade de Zootecnia
e Engenharia de Alimentos da Universidade de
São Paulo, como parte dos requisitos para a
obtenção do Título de Mestre em Ciências.

Área de Concentração: Qualidade e Produtividade
Animal

Aprovado em: ____/____/____

Banca Examinadora

Prof. Dr. _____

Instituição: _____ Assinatura: _____

Presidente da banca examinadora

Prof. Dr. _____

Instituição: _____ Assinatura: _____

Prof. Dr. _____

Instituição: _____ Assinatura: _____

Prof. Dr. _____

Instituição: _____ Assinatura: _____

Dedico este trabalho aos meus pais que, com amor incondicional e muito esforço, me ajudaram a chegar até aqui.

AGRADECIMENTOS

À Deus por estar presente nas alegrias e por me guiar nas dificuldades.

À uma família muito especial que, pelo exemplo de vida, me inspiram a ser cada dia melhor.

Aos meus pais pela compreensão nos momentos difíceis, por me incentivarem desde pequena sobre a importância dos estudos e pela educação baseada em seus exemplos de caráter, respeito e amor ao próximo.

À minha avó Jacyra, pela fortaleza, e meu avô Nino, pela sabedoria, qualidades que somente os anos de vida podem proporcionar a corações bondosos como os seus. Agradeço todo amor, orações e todas as velinhas acesas.

Ao meu irmão Toninho e meu tio Lucas pelo amor e cumplicidade e por tornarem minha vida mais leve e alegre.

Ao meu namorado Marcelo pelo amor, companheirismo e por me trazer tanta paz.

À minha cunhada Eliana, à Giselle, aos meus sobrinhos, Francisco e Sofia e aos meus primos, João Lucas e Felipe, por encherem meu coração de amor.

Ao meu amigo-irmão Rafael, um anjo na minha vida.

À minha orientadora, professora Luciane Martello e meu co-orientador, professor Rafael, por toda generosidade e paciência para me auxiliar, não somente no desenvolvimento deste trabalho, mas também no meu desenvolvimento como profissional. E ao Edson, por toda dedicação a este e tantos projetos do laboratório. Tenho a sorte de aprender com pessoas e profissionais incríveis.

Aos meus amigos do Laboratório de Zootecnia de Precisão, Emanuel, Gabriel, Jessica, Jonathan e Taisla, pela alegria e companheirismo compartilhados todos os dias. Vocês moram no meu coração.

Às minhas amigas da República Eldorado, Mariana, Mariane e Victória, minha família de Pirassununga.

Aos estagiários do Laboratório de Zootecnia de Precisão, Alex, Alexandre, Bianca e Elis, pela ajuda no desenvolvimento deste trabalho.

Aos trabalhadores do Setor de Bovinocultura de Leite da Prefeitura do Campus da USP, Pirassununga.

À professora doutora Cristiane Gonçalves Titto, à professora doutora Melissa Selayssim Di Campos e o professor doutor Adroaldo José Zanella por aceitarem participar da minha banca de defesa e contribuírem com este trabalho.

À Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo.

À Coordenação de Aperfeiçoamento Pessoal de Ensino Superior – Brasil (CAPES) pelo financiamento durante o período do meu Mestrado.

RESUMO

PACHECO, Verônica Madeira. **Desenvolvimento de classificador de conforto térmico para bovinos de leite utilizando modelagem computacional e termografia de infravermelho**. 2019. 91 f. Dissertação (Mestrado) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2019.

O estresse térmico em vacas de leite tem sido estudado como um caminho para melhorar a eficiência produtiva e o bem-estar animal. Diversos autores têm verificado o potencial da termografia de infravermelho como ferramenta não-invasiva para monitorar a temperatura de superfície dos animais. Da mesma forma, modelos computacionais têm sido estudados na área animal, com o intuito de melhorar os sistemas de processamento de dados. O objetivo desse estudo foi elaborar um classificador para estimar o nível de conforto térmico de vacas de leite (Holandesas) utilizando modelagem computacional, técnica que pode auxiliar nesta predição ao extrair informações de dados meteorológicos e fisiológicos combinados. Para isso, a temperatura retal (TR), frequência respiratória (FR) e temperatura de superfície corporal (TIV) de 26 vacas lactantes, foram monitoradas durante 40 dias não consecutivos, três vezes ao dia (5, 13 e 19 horas) em duas épocas do ano – verão e inverno. As TIVs das regiões da frente, área ocular, costela e flanco. No mesmo período, dados meteorológicos foram registrados em uma estação meteorológica e em *data loggers* (Onset HOBO) instalados no *freestall*. Dados produtivos do rebanho foram monitorados conforme realizado pelo Setor de Bovinocultura de Leite da Prefeitura do Campus da USP, Pirassununga, SP. Foi realizada análise dos dados por estatística descritiva e regressão linear para auxiliar na escolha de parâmetros dos modelos computacionais, de forma que os modelos baseados em rede neural artificial (RNA) e rede neural convolucional (CNN) foram desenvolvidos considerando variáveis climáticas e fisiológicas, definidas por tal análise. Os modelos baseados em RNA foram construídos utilizando arquitetura *Perceptron*, alimentada adiante com múltiplas camadas. Já os modelos baseados em CNN foram desenvolvidos de acordo com o modelo *Sequential*. A eficiência dos modelos baseados em RNA para predição de FR (RNA-FR) e TR (RNA-TR) foi avaliada com diagramas de dispersão entre as respostas preditas com as reais e pela comparação com as respostas de modelos estatísticos (análises de regressão) para predição da FR (REG-FR) e TR (REG-TR). A partir dos modelos RNA-FR e RNA-TR, foram elaboradas classificações em níveis de estresse térmico (Conforto, Alerta, Perigo e Emergência). A eficiência destas classificações foi avaliada por métricas extraídas de matrizes de confusão (acurácia, precisão, sensibilidade e medida F1) e comparada com os resultados de métodos tradicionais de classificação em níveis de estresse térmico, o Índice de Temperatura e Umidade (ITU) e o

Índice de Temperatura de Globo Negro e Umidade (ITGU). Para o modelo baseado em CNN, os parâmetros extraídos de matrizes de confusão foram utilizados como forma de avaliar o desempenho das classificações em níveis de estresse térmico desenvolvidos. Com relação às predições de FR e TR, observou-se que os modelos RNA apresentaram melhores resultados quando comparados com os REG, observando-se correlações de 0,83 (RNA-FR) e 0,84 (RNA-TR) para predição dos dados fisiológicos. Os classificadores baseados em RNA apresentaram melhores resultados comparados as classificações obtidas com o ITGU e o ITU. Quanto ao classificador baseado em CNN, este estudo demonstrou que se trata de uma ferramenta promissora, com potencial para identificação de padrões e classificação de imagens térmicas em níveis de estresse térmico. As acurácias obtidas com este classificador (CNN) foram 76% para FR e 71% para TR. Novos estudos devem ser feitos para minimizar o efeito do ambiente climático sobre as imagens térmicas e contribuir para a padronização da escala de cores que afetam diretamente o aprendizado do modelo CNN.

Palavras-chave: aprendizagem de máquina; bem-estar animal; estresse térmico; mineração de dados; modelagem computacional; termografia de infravermelho.

ABSTRACT

PACHECO, Veronica Madeira. **Development of thermal comfort classifier for dairy cattle using computational modeling and infrared thermography**. 2019. 91 f. M.Sc. Dissertation—Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2019.

Thermal stress in dairy cows has been studied as a way to improve productive efficiency and animal welfare. Several authors have verified the potential of infrared thermography as a noninvasive tool to monitor surface temperature of animals. Similarly, computer models have been studied in animal area in order to improve data processing systems. The objective of this study was to develop a classifier to estimate the thermal comfort level of dairy cows (Holstein) using computational modeling, a technique that can assist in this prediction by extracting information from combined meteorological and physiological data. For this, the rectal temperature (RT), respiratory rate (RR) and body surface temperature (IRT) of 26 lactating cows were monitored during 40 non-consecutive days, three times a day (5, 13 and 19 hours) in two times of year - summer and winter. IRTs of the forehead, eye area, rib and flank regions. In the same period, weather data were recorded at a weather station and data loggers (Onset HOBO) installed in the freestall. Herd production data were monitored as conducted by the USP Milk Cattle Sector, Pirassununga, SP. Data analysis was performed by descriptive statistics and linear regression to assist in the choice of parameters of computational models, so that models based on artificial neural network (ANN) and convolutional neural network (CNN) were developed considering climatic and physiological variables defined by such analysis. The ANN-based models were built using Perceptron architecture, fed with multiple layers. CNN-based models were developed according to the Sequential model. The efficiency of ANN-based models for predicting RR (ANN-RR) and RT (ANN-RT) was evaluated with scatter plots between predicted and actual responses and by comparison with statistical model responses (regression analyzes) for predicting RR (REG-RR) and RT (REG-RT). From the ANN-RR and ANN-RT models, classifications were developed for thermal stress levels (Comfort, Alert, Danger and Emergency). The efficiency of these classifications was assessed by metrics extracted from confusion matrices (accuracy, precision, sensitivity, and F1 Score) and compared with the results of traditional methods of classifications for thermal stress levels, the Temperature and Humidity Index (THI), and the Black Globe Humidity Temperature Index (BGTHI). For the CNN-based model, the parameters extracted from confusion matrices were used as a way to evaluate the performance of the classifications in developed thermal stress levels. Regarding the RR and RT estimates, it was observed that the ANN models presented

better results when compared to the REG, observing correlations of 0.83 (ANN-RR) and 0.84 (ANN-RT) to estimate the results of physiological data. The ANN-based classifiers presented better results compared to the classifications obtained with the BGTHI and the THI. In relation to the CNN-based classifier, this study demonstrated that it is a promising tool with potential for pattern identification and thermal image classification at thermal stress levels. The accuracy obtained with this classifier (CNN) was 76% for RR and 71% for RT. Further studies should be done to minimize the effect of the climate environment on thermal imagery and to contribute to color scale standardization that directly affect CNN learning.

key-words: machine learning, animal welfare; thermal stress; data mining; computational modeling; infrared thermography.

LISTA DE ILUSTRAÇÕES

Figura 1. Exemplos de imagens térmicas da região da frente e da área ocular de vacas holandesas.....	27
Figura 2. Esquema representando os três tipos de Aprendizagem de Máquina.	29
Figura 3. Aprendizagem de máquina em um sistema controlador na pecuária leiteira.....	30
Figura 4. Modelo de um neurônio artificial.....	31
Figura 5. Arquitetura de uma rede neural convolucional.	34
Figura 6. Visão geral do free-stall onde foram realizadas as coletas para o <i>experimento</i>	37
Figura 7. Baías de madeira com camas de areia para acesso livre dos animais.	38
Figura 8. Data logger e globo negro utilizados para monitoramento do ambiente interno durante o período experimental.	39
Figura 9. Captura da temperatura retal com um termômetro digital de uma das vacas do experimento.	41
Figura 10. Captura da imagem térmica da região da frente de uma das vacas do experimento.	41
Figura 11. Imagem representando as regiões corporais estudadas nos animais por meio de imagens obtidas com a câmera termográfica.....	42
Figura 12. Figura representando a imagens térmicas da região da frente, área ocular, costela e flanco de uma vaca, o histograma de temperatura e as temperaturas mínima, média e máxima da região selecionada.....	43
Figura 12. Figura representando a imagens térmicas da região da frente, área ocular, costela e flanco de uma vaca, o histograma de temperatura e as temperaturas mínima, média e máxima da região selecionada.....	Erro! Indicador não definido.
Figura 13. Camadas utilizadas na Rede Neural Convolucional.	50
Figura 14. Gráfico representando a variação da temperatura do ar (Ti-1) e da frequência respiratória (FR-1) das vacas durante o período 1 de coletas.....	56
Figura 15. Gráfico representando a variação da temperatura do ar (Ti-1) e da temperatura retal (TR-1) das vacas durante o período 1 de coletas.....	56
Figura 16. Gráfico representando a variação da temperatura do ar (Ti-2) e da frequência respiratória (FR-2) das vacas durante o período 2 de coletas.....	56
Figura 17. Gráfico representando a variação da temperatura do ar (Ti-2) e da temperatura retal (TR-2) das vacas durante o período 2 de coletas.....	56
Figura 18. Correlação entre os dados de frequência respiratória (FR) medidos e os estimados pelo RNA-FR.....	66
Figura 19. Correlação entre os dados de frequência respiratória (FR) medidos e os estimados pelo REG-FR.	66

Figura 20. Correlação entre os dados de temperatura retal (TR) medidos e os estimados pelo RNA-TR.66

Figura 21. Correlação entre os dados de temperatura retal (TR) medidos e os estimados pelo REG-TR.....66

LISTA DE TABELAS

Tabela 1. Classes de conforto térmico consideradas para interpretação dos cálculos do Índice de Temperatura e Umidade (ITU) e o Índice de Temperatura de Globo Negro e Umidade (ITGU)..	40
Tabela 2. Dados produtivos do rebanho durante os dois períodos de coletas.	44
Tabela 3. Classificação da frequência respiratória (FR), temperatura retal (TR), Índice de Temperatura e Umidade (ITU) e Índice de Temperatura de Globo Negro e Umidade (ITGU) em classes de estresse térmico.....	46
Tabela 4. Classes de frequência respiratória (FR) e temperatura retal (TR) consideradas para a distribuição do banco de dados de imagens térmicas.....	49
Tabela 5. Estatística descritiva dos dados meteorológicos registrados do ambiente interno.	52
Tabela 6. Estatística descritiva dos dados meteorológicos do ambiente externo.	88
Tabela 7. Estatística descritiva dos dados fisiológicos dos animais coletados durante o período experimental.	54
Tabela 8. Coeficiente de correlação de Pearson relacionando variáveis climáticas e fisiológicas.	58
Tabela 9. Coeficiente de correlação de Pearson relacionando variáveis fisiológicas e climáticas registradas do ambiente externo.	89
Tabela 10. Coeficiente de correlação de Pearson relacionando as variáveis fisiológicas.	60
Tabela 11. Modelos computacionais, baseados em rede neural artificial (RNA) que foram testados na segunda etapa de testes.	62
Tabela 11. Modelos computacionais, baseados em rede neural artificial (RNA) que foram testados na segunda etapa de testes.	63
Tabela 12. Equações de regressão linear desenvolvidas para estimar frequência respiratória (REG-FR) baseada na temperatura de bulbo seco (T_i), umidade relativa do ar (UR_i) e temperatura média de superfície da fronte das vacas (TIVFRONmed) e para estimar a temperatura retal (REG-TR) baseada na temperatura de bulbo seco (T_i), umidade relativa do ar (UR_i) e temperatura máxima da área ocular (TIVOLmax).	64
Tabela 13. Comparação entre os parâmetros estatísticos das equações de regressão obtidas entre os dados reais e os estimados pelos melhores modelos (RNA-FR e RNA-TR) e os obtidos das equações de regressão entre os dados reais e os estimados pelos modelos estatísticos (REG-FR e REG-TR).	65
Tabela 14. Matriz de confusão entre os dados estimados pelo modelo RNA-FR e os dados reais de FR, classificados em faixas de estresse térmico segundo a frequência respiratória. Células cinzas indicam as predições corretas em cada classe.	70
Tabela 15. Avaliação do desempenho do modelo computacional baseado em rede neural artificial (RNA) desenvolvido para predição de frequência respiratória (FR).	70
Tabela 16. Matriz de confusão entre os dados reais de FR classificados em faixas de estresse térmico segundo a frequência respiratória (Real – FR) e a classificação obtida com o Índice de Temperatura e Umidade (Predita-ITU). Células cinzas indicam as predições corretas em cada classe.	71

Tabela 17. Avaliação do desempenho do modelo computacional baseado no Índice de Temperatura e Umidade (ITU) desenvolvido para estimar a frequência respiratória (FR).	71
Tabela 18. Matriz de confusão entre os dados reais de FR classificados em faixas de estresse térmico segundo a frequência respiratória (Real - FR) e a classificação obtida com o Índice de Temperatura de Globo Negro e Umidade (Preditada – ITGU). Células cinzas indicam as predições corretas em cada classe.	72
Tabela 19. Avaliação do desempenho do modelo computacional baseado no Índice de Temperatura de Globo Negro e Umidade (ITGU) desenvolvido para estimar a frequência respiratória (FR). ..	72
Tabela 20. Matriz de confusão entre os dados estimados pelo modelo RNA-TR e os dados reais de TR, classificados em faixas de estresse térmico segundo a frequência respiratória. Células cinzas indicam as predições corretas em cada classe.	73
Tabela 21. Avaliação do desempenho do modelo computacional baseado em rede neural artificial (RNA) desenvolvido para estimar a temperatura retal (TR).	73
Tabela 22. Matriz de confusão entre os dados reais de TR classificados em faixas de estresse térmico segundo a frequência respiratória (Real – TR) e a classificação obtida com o Índice de Temperatura e Umidade (Preditada-ITU). Células cinzas indicam as predições corretas em cada classe.	73
Tabela 23. Avaliação do desempenho do modelo computacional baseado no Índice de Temperatura e Umidade (ITU) desenvolvido para estimar a temperatura retal (TR).	74
Tabela 24. Matriz de confusão entre os dados reais de TR classificados em faixas de estresse térmico segundo a frequência respiratória (Real - TR) e a classificação obtida com o Índice de Temperatura de Globo Negro e Umidade (Preditada – ITGU). Células cinzas indicam predições corretas em cada classe.	74
Tabela 25. Avaliação do desempenho do modelo computacional baseado no Índice de Temperatura de Globo Negro e Umidade (ITGU) desenvolvido para estimar a temperatura retal (TR).	74
Tabela 26. Matriz de confusão entre os dados estimados pelo modelo baseado em CNN e os dados reais de FR, classificados em faixas de estresse térmico segundo a frequência respiratória. Células cinzas indicam as predições corretas em cada classe.	77
Tabela 27. Matriz de confusão entre os dados estimados pelo modelo baseado em CNN e os dados reais de temperatura retal (TR), classificados em faixas de estresse térmico segundo a temperatura retal. Células cinzas indicam as predições corretas em cada classe.	77
Tabela 28. Avaliação do desempenho dos modelos computacionais desenvolvidos para predição de frequência respiratória (FR) e temperatura retal (TR) a partir de imagens térmicas da frente.	77
Tabela 29. Matriz de confusão entre os dados estimados pelo modelo baseado em CNN e os dados reais de FR, classificados em faixas de estresse térmico segundo a frequência respiratória. Células cinzas indicam as predições corretas em cada classe.	78
Tabela 30. Matriz de confusão entre os dados estimados pelo modelo baseado em CNN e os dados reais de FR, classificados em faixas de estresse térmico segundo a temperatura retal. Células cinzas indicam as predições corretas em cada classe.	78

Tabela 31. Avaliação do desempenho dos modelos computacionais desenvolvidos para predição de frequência respiratória (FR) e temperatura retal (TR) a partir de imagens térmicas da área ocular. 79

LISTA DE ABREVIATURAS E SIGLAS

CNN	Rede Neural Convolucional
FR	Frequência respiratória
ITGU	Índice de Temperatura de Globo Negro e Umidade
ITGU _i	Índice de Temperatura de Globo Negro e Umidade calculado com os dados meteorológicos do ambiente interno obtidos durante os dois períodos de coletas (inverno e verão).
ITGU _i -1	Índice de Temperatura de Globo Negro e Umidade calculado com os dados meteorológicos do ambiente interno obtidos durante o inverno
ITGU _i -2	Índice de Temperatura de Globo Negro e Umidade calculado com os dados meteorológicos do ambiente interno obtidos durante o verão
ITU	Índice de Temperatura e Umidade
ITU _i	Índice de Temperatura e Umidade calculado com os dados meteorológicos do ambiente interno obtidos durante os dois períodos de coletas (inverno e verão).
ITU _i -1	Índice de Temperatura e Umidade calculado com os dados meteorológicos do ambiente interno obtidos durante o inverno
ITU _i -2	Índice de Temperatura e Umidade calculado com os dados meteorológicos do ambiente interno obtidos durante o verão
ML	Aprendizagem de Máquina
R	Coefficiente de correlação de Person
R ²	Coefficiente de determinação
REG-FR	Modelo baseado em equação de regressão linear para a predição da frequência respiratória
REG-TR	Modelo baseado em equação de regressão linear para a predição da temperatura retal
RMSE	Raíz do erro quadrático médio
RNA	Rede Neural Artificial
RNA-FR	Modelo computacional baseado em rede neural artificial para predição da frequência respiratória
RNA-RT	Modelo computacional baseado em rede neural artificial para a predição da temperatura retal

TGNI	Temperatura de globo negro do ambiente interno obtida durante os dois períodos de coletas (inverno e verão).
TGNI-1	Temperatura de globo negro do ar do ambiente interno obtida durante o inverno.
TGNI-2	Temperatura de globo negro do ambiente interno obtida durante o verão.
Ti	Temperatura do ar do ambiente interno obtida durante os dois períodos de coletas (inverno e verão).
Ti-1	Temperatura de ponto de orvalho do ambiente interno obtida durante o inverno.
Ti-1	Temperatura do ar do ambiente interno obtida durante o inverno.
Ti-1	Umidade relativa do ar do ambiente interno obtida durante o inverno.
Ti-2	Temperatura de ponto de orvalho do ambiente interno obtida durante o verão.
Ti-2	Temperatura do ar do ambiente interno obtida durante o verão.
Ti-2	Umidade relativa do ar do ambiente interno obtida durante o verão.
TIV	Termografia e Infravermelho
TIVCOS	Temperatura de superfície corporal da região da costela do animal
TIVCOSmax	Temperatura máxima de superfície corporal da região da costela do animal
TIVCOSmed	Temperatura média de superfície corporal da região da costela do animal
TIVCOSmin	Temperatura mínima de superfície corporal da região da costela do animal
TIVFLAN	Temperatura de superfície corporal do flanco do animal
TIVFLANmax	Temperatura máxima de superfície corporal do flanco do animal
TIVFLANmed	Temperatura média de superfície corporal do flanco do animal
TIVFLANmin	Temperatura mínima de superfície corporal do flanco do animal
TIVFRON	Temperatura de superfície corporal da região da frente do animal
TIVFRONmax	Temperatura máxima de superfície corporal da região da frente do animal
TIVFRONmed	Temperatura média de superfície corporal da região da frente do animal
TIVFRONmin	Temperatura mínima de superfície corporal da região da frente do animal
TIVOL	Temperatura de superfície corporal da área ocular do animal
TIVOLmax	Temperatura máxima de superfície corporal da área ocular do animal

TPOi	Temperatura de ponto de orvalho do ambiente interno obtida durante os dois períodos de coletas (inverno e verão).
TR	Temperatura retal
URi	Umidade relativa ar do ambiente interno obtida durante os dois períodos de coletas (inverno e verão).

SUMÁRIO

1. INTRODUÇÃO	19
2. OBJETIVOS	21
2.1 Objetivo geral.....	21
2.2 Objetivos específicos.....	21
3. REVISÃO BIBLIOGRÁFICA.....	22
3.1 Influência do ambiente climático na produção animal.....	22
3.2 Estresse térmico e a produção animal	24
3.3 Termografia de infravermelho	26
3.4 Aprendizagem de máquina.....	28
3.4.1 Redes Neurais Artificiais	30
3.4.2 Redes Neurais Convolucionais.....	33
4. MATERIAL E MÉTODOS	36
4.1 Localização e instalações	36
4.2 Animais	38
4.3 Coleta de dados	38
4.3.1 Caracterização do ambiente climático.....	38
4.3.2 Monitoramento dos animais	40
4.4 Análise estatística.....	44
4.5 Modelos computacionais para predição de FR e TR.....	45
4.5.1 Modelo baseado em Rede Neural Artificial	45
4.5.2 Classificação e avaliação do modelo baseado em RNA.....	46
4.5.3 Modelo baseado em Rede Neural Convolucional	48
5. RESULTADOS	51
5.1 Estatística descritiva e análise de Regressão Linear	51
5.2 Rede Neural Artificial	61
5.2.1 Classificação e avaliação dos modelos.....	68
5.3 Rede Neural Convolucional	75
5.3.1 Classificação e avaliação dos modelos construídos com as imagens da região da fronte	76
5.3.2 Classificação e avaliação dos modelos construídos com as imagens da área ocular....	78
6. CONCLUSÃO	81
7. REFERÊNCIAS	82

1. INTRODUÇÃO

A influência do estresse térmico sobre os bovinos tem sido continuamente investigada uma vez que seus efeitos afetam negativamente a saúde e a produtividade desses animais. Valores de umidade relativa e temperatura do ar fora da zona termoneutra para bovinos promovem o desconforto térmico e exigem que os animais acionem mecanismos termorregulatórios para manter a homeotermia. No entanto, a manutenção do equilíbrio térmico interno promove um gasto energético extra que prevalece sobre as atividades de desenvolvimento, crescimento e reprodução.

A avaliação do conforto térmico pode ser feita pelo monitoramento do ambiente climático e das respostas termorregulatórias dos animais. O ambiente climático é tradicionalmente estudado por meio de índices climáticos que nem sempre refletem o estado de bem-estar real dos animais, já que foram desenvolvidos em diferentes condições ambientais e com diferentes raças. Além do ambiente climático, essa avaliação pode ser feita pelo monitoramento das respostas fisiológicas e comportamentais dos animais, mas além de demandar tempo e pessoas especializadas para a interpretação dos dados, estes métodos comumente utilizados podem ser invasivos e estressantes.

Uma forma de avaliação das trocas térmicas entre o animal e o ambiente é o monitoramento da emissão de calor pela superfície dos animais, um dos mecanismos de regulação da temperatura corporal. Dessa forma, técnicas que captem esta emissão de calor podem contribuir para a detecção do estresse térmico em seu estágio inicial, de forma não invasiva e antes que haja prejuízo aos animais e à produção.

A Termografia de Infravermelho é uma técnica capaz de captar o calor emitido pela superfície dos animais pelo monitoramento da radiação infravermelha. Este tipo de radiação eletromagnética está associado ao calor e é captada por meio de câmeras termográficas. Por ter potencial para automação e ser capaz de monitorar as alterações térmicas sem contato físico, esta técnica tem sido estudada como um método não invasivo para avaliação do conforto térmico nos animais.

Além de ferramentas não invasivas para auxiliar no monitoramento dos animais, o grande volume de dados e a necessidade de respostas rápidas tem impulsionado o desenvolvimento de novos sistemas de gerenciamento e análise de dados. Tais sistemas são baseados em modelos computacionais e sistemas automatizados, que geram respostas rápidas e auxiliam os produtores a tomarem decisões de forma mais precisa e em tempo real.

Neste contexto, o desenvolvimento de modelos computacionais para interpretação de dados meteorológicos e fisiológicos, associados ao uso da termografia de infravermelho, pode

viabilizar o desenvolvimento de sistemas automáticos não invasivos, visando o monitoramento do conforto térmico de vacas de leite em tempo real e, conseqüentemente, contribuindo para evitar perdas na saúde e na produtividade do rebanho.

A hipótese deste estudo indica que é possível desenvolver um classificador de estresse térmico para bovinos de leite baseado em redes neurais artificiais e redes neurais convolucionais, utilizando dados meteorológicos e Termografia de Infravermelho. Adicionalmente, espera-se trazer vantagens como: eliminar coletas invasivas aos animais e etapas de processamento de informações que demandam tempo e pessoas especializadas para interpretação de dados; melhorar a acurácia da investigação do estresse térmico com a combinação de avaliações meteorológicas e fisiológicas e; possibilidade de automação agregando as tecnologias baseadas em modelos computacionais e termografia de infravermelho.

2. OBJETIVOS

2.1 Objetivo geral

O objetivo deste estudo foi desenvolver um classificador baseado em modelagem computacional e termografia de infravermelho para estimar o conforto térmico de vacas de leite.

2.2 Objetivos específicos

- Determinar as regiões corporais monitoradas melhor correlacionadas com a frequência respiratória e a temperatura retal para serem incluídas nos modelos computacionais;
- Desenvolver diferentes modelos computacionais, baseados em rede neural artificial e para prever a frequência respiratória e a temperatura retal.
- Desenvolver classificadores de estresse térmico baseados em rede neural artificial e rede neural convolucional;
- Comparar as respostas dos diferentes modelos computacionais entre si, entre modelos estatísticos e entre os índices de conforto térmico tradicionais.

3. REVISÃO BIBLIOGRÁFICA

O conteúdo discutido nesta revisão bibliográfica teve o objetivo auxiliar na compreensão dos assuntos abordados no presente trabalho e proporcionar um embasamento para a metodologia e discussão dos resultados. Foi apresentado, inicialmente, uma breve discussão sobre a influência do ambiente climático na produção animal e a forma como interferem nas trocas térmicas entre o animal e o ambiente. Além disso, neste tópico foi discutido a dificuldade de utilização dos índices climáticos como forma de caracterizar a situação de conforto térmico dos animais.

O segundo tópico abordou a forma como o estresse térmico pode afetar o desempenho dos animais e como são as formas mais comuns de monitoramento do nível de conforto térmico das vacas de leite, a partir de respostas fisiológicas (frequência respiratória e temperatura retal) que podem ser invasivas ou exigem tempo para a obtenção de respostas. Em sequência foi desenvolvida uma revisão sobre a Termografia de Infravermelho, uma técnica de monitoramento da temperatura de superfície dos animais que tem sido estudada como método não invasivo para avaliar o conforto térmico.

Por último, foi feito um estudo sobre como a Aprendizagem de Máquina pode contribuir com o desenvolvimento de modelos computacionais para interpretação de dados captados da produção animal. Em especial, como os modelos computacionais baseados em rede neural artificial e rede neural convolucional, construídos com dados meteorológicos e a TIV podem ser úteis para prever o estado de conforto térmico dos animais de forma rápida, automática e não invasiva.

3.1 Influência do ambiente climático na produção animal

Fatores meteorológicos como temperatura, umidade, radiação solar e velocidade do vento exercem grande influência sobre os mecanismos de trocas de calor entre o ambiente e o animal. Em ambientes de clima quente, a estratégia dos animais para a manutenção do balanço térmico é emitir calor ao ambiente enquanto que, em climas frios, a estratégia é manter ou produzir calor interno (KADZERE et al., 2002). Essas trocas térmicas são realizadas por intermédio das vias evaporativas (evaporação) e não evaporativas (convecção, condução e radiação) (SCHÜLLER; BURFEIND; HEUWIESER, 2013) e são influenciadas de diferentes maneiras.

O aumento da temperatura do ar dificulta as trocas por calor sensível (vias não evaporativas) em função da diminuição do gradiente de temperatura entre o animal e o ambiente (KADZERE et al., 2002). As trocas de calor por vias evaporativas são prejudicadas pela elevada

umidade relativa, principalmente quando está associada a altas temperaturas do ar pois dificulta a evaporação de água do animal para o ambiente. Por outro lado, a elevada velocidade do vento contribui para a evaporação de água pois, ao retirar a camada de ar próxima a superfície dos animais, carrega o calor que foi emitido e permite que novas trocas ocorram. Elevados índices de radiação solar estão relacionados com a absorção de calor pelos animais que convertem esta energia radiante em energia calorífica (NÃÃS, 1989).

Muitos pesquisadores têm utilizado índices climáticos como ferramentas de análise do ambiente voltada ao conforto térmico dos animais. Entre estes índices, o Índice de Temperatura e Umidade (ITU) e o Índice de Temperatura de Globo Negro e Umidade (ITGU) são bastante utilizados. O primeiro índice considera a temperatura e umidade do ar, informações facilmente obtidas em estações meteorológicas. O segundo, além da temperatura e umidade do ar, integra em sua equação a radiação líquida e a circulação de ar pela inserção da temperatura de globo negro como uma das variáveis independentes (BUFFINGTON; CANTON; PITT, 1981), dados meteorológicos que são importantes de serem monitorados pois influenciam no processo de termorregulatório dos animais.

Jeelani et al., 2019 estudaram indicadores de estresse térmico para gado leiteiro cruzado (*Bos taurus x Bos indicus*) em clima subtropical. Para isso avaliaram diferentes valores de ITU e sua relação com os parâmetros fisiológicos e bioquímicos destes animais. O primeiro aumento significativo para frequência respiratória (FR) e temperatura retal (TR) aconteceu com ITU igual a 74. Após esse aumento, a TR permaneceu estável até ITU de 80 e depois demonstrou o valor mais alto com ITU igual a 84. Em relação à FR o próximo aumento significativo registrado foi com ITU de 80 e 82. Embora os aumentos de TR e FR terem acompanhado o aumento do ITU, os autores registraram que esta relação não foi linear.

A relação entre ITU e temperaturas máximas de superfície corporal dos animais também foi estudada por Jeelani et al. (2019), que encontraram também uma relação não-linear entre as duas variáveis. Entre as regiões corporais analisadas a cabeça foi a que demonstrou a relação mais direta com o ITU. O aumento significativo aconteceu com valores de ITU iguais a 74, 80, 82 e 84. A equação utilizada pelos autores neste experimento foi a desenvolvida por NCR (1971) que considera como variáveis independentes a temperatura e umidade relativa ar.

Peng et al., 2019 avaliaram o comportamento da temperatura de superfície corporal e da TR de vacas de leite (Holandesas), sob diferentes condições de ITU e em uma região de clima temperado. Os autores utilizaram a fórmula desenvolvida por Rowsell (1972) e encontraram que a TR foi maior quando o ITU foi considerado alto (> 78) do que o ITU moderado ($72 - 78$)

e baixo (< 72) e a temperatura de superfície corporal foi positivamente correlacionada com o ITU.

Buffington et al. (1981) desenvolveram e avaliaram o ITGU frente ao ITU como uma equação de conforto para vacas de leite (maioria Holandesas) em diferentes ambientes meteorológicos (com ou sem sombra). Os autores relataram que a temperaturas do globo negro do ambiente sem sombra foi significativamente maior ($p < 0,05$) do que a do ambiente com sombra, especialmente durante o período de estresse por calor severo (das 9 às 18 horas). Os autores relataram que, como o ITGU é uma função linear da temperatura do globo negro e do ponto de orvalho, o seu valor no ambiente sem sombra foi significativamente maior do que no com sombra. Além destas análises, os autores avaliaram a correlação entre as respostas fisiológicas (FR e TR) e os índices climáticos (ITU e ITGU). A FR e a TR foram significativamente maiores ($p < 0,05$) nas vacas do ambiente sem sombra comparadas ao ambiente com sombra e tiveram maior correlação com o ITGU do que com o ITU.

Os índices climáticos são recursos importantes para controle do estresse térmico em sistemas agropecuários por considerarem informações de fácil acesso e que não exigem contato com os animais. Apesar da sua ampla utilização na pecuária para a avaliação do conforto térmico, estes índices levam em sua equação apenas variáveis meteorológicas e não consideram os aspectos fisiológicos dos animais. Por esta razão, o desenvolvimento de ferramentas que associem estas duas informações pode melhorar a identificação do estresse térmico pois a resposta termorregulatória dos animais ao ambiente climático pode ser avaliada de forma a considerar a variação individual.

3.2 Estresse térmico e a produção animal

Os bovinos, por serem animais homeotérmicos, necessitam manter a sua temperatura corporal dentro de uma faixa ideal (zona termoneutra) para o perfeito funcionamento do organismo. Quando sua temperatura interna é afetada por fatores ambientais, os mecanismos termorregulatórios são ativados para gerar ou dissipar calor, buscando recuperar o equilíbrio térmico interno (homeotermia). O estresse térmico ocorre como resultado do desequilíbrio entre estas trocas de calor que em condições ambientais desfavoráveis exigem que os animais intensifiquem as atividades termorregulatórias. Nestas condições, os bovinos podem não expressar todo o seu potencial genético por utilizarem a energia disponível para a manutenção da homeotermia, afetando o seu desempenho produtivo e reprodutivo (ALLEN et al., 2015).

A alta produção de leite das vacas está diretamente associada ao aumento da produção de calor metabólico, gerado pelo aumento do consumo de matéria seca e pela manutenção da lactação. Vacas submetidas a altas temperaturas do ar tendem a diminuir o consumo de matéria seca, o que afeta diretamente a produção e composição do leite. Em uma visão microscópica, a qualidade do leite pode ser afetada pelo estresse por calor, especialmente reduzindo os teores de proteína e gordura (BOURAoui et al., 2002; HILL; WALL, 2014). Da mesma forma, o estresse térmico afeta a atividade reprodutiva pois influencia negativamente o comportamento natural de acasalamento, a produção hormonal e o cio (POLSKY; VON KEYSERLINGK, 2017).

Segundo Polsky e Von Keyserlingk (2017) os efeitos do estresse térmico nos animais podem afetar três vias construtivas do bem-estar animal: os estados afetivos (fome e sede, frustração, agressão), a saúde e as funções biológicas (ofego, comportamento de estro e produção de leite) e o comportamento natural (adaptações evolutivas, comportamento social e procura por sombra).

A zona termoneutra adequada para vacas em lactação se encaixa entre 5 e 25 °C, mas os limites críticos de temperatura do ar podem variar em função da raça, espécie, composição e ingestão alimentar, condições climáticas específicas, estado prévio de temperatura de aclimação, estágio de produção, adaptação e comportamento animal. (YOUSEF, 1995). Alguns autores consideram temperaturas acima de 24 °C valores críticos para estresse térmico em vacas lactantes (JOHNSON E VANJONACK, 1976; NÃÃS, 1989; MARTELLO, 2006).

Os mecanismos termorregulatórios para a manutenção da homeotermia se manifestam nas respostas fisiológicas e comportamentais dos animais mediante ao ambiente térmico. As características comportamentais são voluntárias e podem ser identificadas por alterações nas atividades diárias dos animais. Já as fisiológicas são involuntárias, controladas pelo Sistema Nervoso Autônomo e estão relacionadas à termogênese (produção de calor) e termólise (perda de calor) (TAN; KNIGHT, 2018).

Em pesquisas científicas, a maioria dos estudos monitoram as respostas fisiológicas dos animais para investigar os efeitos do estresse térmico (KADZERE et al., 2002). Nesse sentido, a frequência respiratória (FR) e a temperatura corporal interna podem fornecer informações importantes sobre a relação entre o animal e o ambiente climático (POLSKY; VON KEYSERLINGK, 2017). Valores de temperatura retal (TR) entre 38,0 a 39,3 °C e FR abaixo de 60 mov/min são adequados para bovinos de leite adultos (DUKES et al., 1996; HAHN et al., 1997).

A TR tem sido amplamente utilizada como medida representativa da temperatura corporal interna dos animais e tanto ela quanto a FR são consideradas bons indicadores do nível de estresse térmico (BROWN-BRANDL et al., 2003). Entretanto, essas medidas são feitas de forma invasiva ou são impraticáveis para produções de larga escala. Assim, a utilização de ferramentas que avaliem as alterações fisiológicas de forma não invasiva, como a técnica da Termografia de Infravermelho, por exemplo, pode agregar informações sobre a resposta dos animais ao ambiente e auxiliar na detecção do estresse térmico de forma mais precisa, já que se trata de uma técnica que capta dados de forma rápida, segura e não gera desconforto aos animais (SOUSA et al., 2018).

3.3 Termografia de infravermelho

O desenvolvimento de equipamentos capazes de captar a radiação infravermelha, viabilizaram o monitoramento da temperatura dos objetos pois todos eles, com temperatura acima do zero absoluto (0 K ou -273 °C), emitem radiação infravermelha devido à agitação de seus átomos e moléculas. A Termografia de Infravermelho é uma destas técnicas, capaz de captar o calor emitido através da superfície corporal dos animais de forma não invasiva (KNIZKOVA et al., 2007).

As câmeras termográficas captam a radiação infravermelha e a transforma em imagem capaz de ser visualizada pelo olho humano. A imagem é formada por um padrão de cores de acordo com a distribuição da temperatura de superfície e a emissividade do objeto analisado (Figura 1). Sua vantagem em relação aos outros métodos de monitoramento das respostas fisiológicas é a facilidade de utilização, rapidez para geração de dados e, em relação aos animais, por ser uma ferramenta sem necessidade de contenção ou contato físico.

Como a temperatura de superfície corporal reflete o estado do metabolismo do tecido do animal e da circulação sanguínea, alterações nos padrões dessa temperatura podem significar a presença de inflamações ou alterações circulatórias (STELLETTA et al., 2012). Por ser capaz de detectar estas alterações, a Termografia de Infravermelho pode ser utilizada para avaliar a temperatura de superfície corporal e indicar a situação fisiológica dos animais (CANATA et al., 2014; MOURA et al., 2011).

Figura 1. Exemplos de imagens térmicas da região da frente e da área ocular de vacas holandesas.

Escala de cores e temperatura (A); Imagem em formato BMT da região da frente da vaca (B); Imagem em formato JPG da região da frente da vaca (C); Imagem em formato BMT área ocular da vaca (D); Imagem em formato JPG da área ocular da vaca (E).

Fonte: Própria autoria.

O monitoramento da temperatura de superfície corporal por meio da Termografia de Infravermelho (TIV) tem sido estudado em bovinos. Martello et al. (2010) estudaram o padrão diurno da TIV região dorsal de bovinos de leite (vacas Holandesas) e de corte (Nelore) como indicador de estresse térmico. A TIV apresentou valores de correlação (r) moderados a altos em relação a temperatura auricular (0,72), temperatura de vulva (0,72), temperatura caudal (0,66), TR (0,64) e a FR (0,54).

Para estudar as relações entre a TIV com outras características fisiológicas, Church et al. (2014) avaliaram a TIV da região ocular e a TR de bovinos cruzados. Tanto os valores de temperatura da região ocular quanto a TR apresentaram distribuição normal, sendo os valores de temperatura da região ocular mais baixos (cerca de 2 °C) em relação à TR.

Salles et al. (2016) avaliaram a TIV de vacas de leite (Jersey) em um ambiente termoneutro com o intuito de identificar um padrão da raça em situação de conforto térmico. Diferentes sítios corporais foram analisados e os que se mostraram melhores correlacionados com o ITU foram os flancos direito (0,85) e esquerdo (0,81) e a frente (0,81). A região da frente foi a melhor correlacionada com a TR (0,85) e o flanco esquerdo melhor correlacionado com a FR (0,48).

Martello et al. (2016) estudaram o uso da TIV em bovinos de corte (Nelore). Diferentes regiões corporais foram analisadas (frente, face, olho, área ocular, costela, flanco, garupa e

patas). A região que apresentou melhor correlação com a TR e FR foi a frente com valores de 0,60 e 0,47, respectivamente.

Os resultados relacionando dados de Termografia de Infravermelho, com medidas fisiológicas e climáticas investigados por Martello et al. (2010;2016) Church et al. (2014) e Salles et al. (2016) demonstram o potencial da técnica para o monitoramento das trocas de calor nos animais. O desenvolvimento de novas pesquisas com a Termografia de Infravermelho em vacas de leite pode contribuir com a padronização de metodologias e melhorar a precisão da técnica, tornando-a cada vez mais promissora para a detecção do estresse térmico.

3.4 Aprendizagem de máquina

Tecnologias recentes provocaram grandes avanços na pecuária de precisão ao permitir que o setor monitore e colete informações de forma contínua e com abordagens menos invasivas aos animais e menos intensivas em mão-de-obra. O uso de plataformas de fenotipagem, sensores, gravações automatizadas de imagens digitais e sons, sistemas não tripulados e visão computacional tem ganhado força com grande potencial para melhorar a qualidade do produto, práticas de gestão e desenvolvimento sustentável. Apesar disso, o aumento da capacidade de armazenagem de dados providas destas tecnologias vêm gerando novos desafios para análise e interpretação destes dados (MOROTA et al., 2018).

Aprendizagem de Máquina (*Machine Learning* - ML) é um ramo Inteligência Artificial que busca o desenvolvimento de modelos computacionais que possam aprender a partir de um conjunto de dados. Atualmente a aplicação da ML está fortemente relacionada à busca por ferramentas capazes de analisar um grande volume de dados (*Big Data*) de forma rápida, automática e precisa. Todos estes modelos computacionais, assim como os métodos tradicionais de modelagem, representam um mapeamento baseado em informações conhecidas de um conjunto de entradas para um conjunto de saídas (BROWN-BRANDL; JONES; WOLDT, 2005).

A ML é uma das ferramentas utilizadas para o processo denominado Mineração de Dados (Data Mining) que trata da construção de modelos computacionais automáticos ou semi-automáticos capazes de investigar analiticamente uma base de dados desorganizada e complexa e extrair padrões e tendências importantes para a geração de conhecimento (SILVA; PERES; BOSCAROIOLI, 2016). Entre estas técnicas estão aquelas utilizadas para a construção de modelos preditivos através da aprendizagem supervisionada (Figura 2), para gerar algoritmos para identificar padrões e identificar atributos numéricos ou categóricos, ou seja, capazes de

prever possíveis saídas para novos dados de entrada (GRUS, 2016). Além disso, a ML fornece uma alternativa à utilização de modelos estatísticos clássicos pois relações não-lineares entre as variáveis dificultam a modelagem matemática a partir destas técnicas (VALLETTA et al., 2017).

Existem três tipos de ML que podem ser aplicados à mineração de dados: a aprendizagem supervisionada, aprendizagem não supervisionada e a aprendizagem por reforço (Figura 2). A primeira está relacionada à previsão de uma variável dependente a partir de variáveis independentes e, para que o modelo computacional possa aprender, os dados utilizados para previsão (variáveis independentes), vêm acompanhados das respostas reais (variáveis dependente), como pares de entrada e saída. A aprendizagem, não supervisionada, é utilizada quando não é possível obter os pares de variáveis dependentes e independentes. A estratégia neste caso, é que o modelo computacional encontre uma associação entre os dados de entrada disponíveis e desenvolva um padrão para a previsão das respostas. O último tipo de aprendizagem é a denominada aprendizagem por reforço em que a máquina toma decisões com os dados de entrada disponíveis e recebe recompensas positivas ou negativas da saída que a auxiliam a construir o melhor modelo.

Figura 2. Esquema representando os três tipos de Aprendizagem de Máquina.

A escolha do tipo de ML utilizada depende do tipo de problema e da disponibilidade de dados para construção dos modelos computacionais. Na produção animal a ML supervisionada tem sido amplamente utilizada para predição de características físicas, fisiológicas e comportamentais como forma de acessar de forma antecipada o estado de saúde e a performance dos animais. Para vacas de leite, alguns exemplos destes estudos são algoritmos para detecção de laminitite (ABDUL JABBAR et al., 2017), predição da condição corporal de vacas (RODRÍGUEZ ALVAREZ et al., 2018), previsão de parto (BORCHERS et al., 2017) e detecção do nível de bem-estar (KRUG et al., 2015).

As redes neurais artificiais e convolucionais são exemplos dessas ferramentas de ML supervisionada para desenvolvimento de modelos computacionais de predição ou classificação, que mapeam e agrupam conjuntos de dados e geram informações para tomada de decisão. No caso do processamento de dados fisiológicos e meteorológicos obtidos de sistemas de produção animal, este tipo de modelagem pode auxiliar na predição indireta de variáveis fisiológicas (FR e TR) ou na classificação dos animais em categorias de conforto térmico. Em uma visão mais ampla a ML pode participar de sistemas controladores onde, de forma automática ou não e com auxílio de sensores e atuadores, informações como estas podem auxiliar os produtores a gerenciar o ambiente climático e a dieta dos animais e consequentemente melhorar a saúde e a produtividade do rebanho leiteiro (Figura 3).

Figura 3. Aprendizagem de máquina em um sistema controlador na pecuária leiteira.

3.4.1 Redes Neurais Artificiais

As redes neurais artificiais (RNA) são algoritmos desenvolvidos para processamento de informações que surgiram da necessidade de soluções de problemas complexos e com grande quantidade de variáveis. A capacidade de mapeamento não-linear, alta precisão para aprendizagem e robustez são características que motivam sua aplicação em diversas áreas de estudo (SHEELA; DEEPA, 2013). Sua inspiração se deu a partir da observação dos neurônios biológicos que transportam uma enorme quantidade de informações por impulsos eletroquímicos (sinapses), possibilitando a aprendizagem e tomada de decisões.

A arquitetura de uma RNA (Figura 4) pode ser compreendida por uma analogia com os neurônios biológicos: os dendritos são representados pelas variáveis de entrada que serão analisadas; o núcleo celular combina as informações da entrada por uma função somatória; o resultado do somatório é aplicado a função de ativação, que de forma análoga ao axônio, extrai (DE SOUSA et al., 2016) informações das variáveis de entrada para gerar um valor de saída. As ‘m’ variáveis de entrada (x_m) estão associadas a ‘km’ pesos iniciais (w_{km}) que conferem a importância de cada variável para a resposta final (y_k) (SILVA; PERES; BOSCARIOLI, 2016).

Opcionalmente o neurônio artificial pode ter uma entrada extra, denominada bias (b_k) que tem a função de ajustar o valor de saída da soma ponderada de forma de forma que se adapte melhor ao conjunto de dados na entrada. A função de ativação é responsável por converter combinações de informações da entrada em um valor finito na saída. Além disso, possui um papel importante para a aprendizagem da RNA pois garante que o processo de atualização dos pesos e bias não gere mudanças drásticas na saída (HAYKIN, 2003).

Figura 4. Modelo de um neurônio artificial.

Parâmetros: x: entrada; w: pesos sinápticos ou iniciais; b: bias; Σ : função somatória; $\phi(v)$: função de ativação.
Fonte: Adaptado de Haykin (2003).

Aumentando-se a complexidade dos sistemas, torna-se necessária a associação de mais neurônios para processar as informações. Os modelos computacionais construídos a partir das RNAs seguem os princípios básicos da aprendizagem de máquina e os processos de treinamento podem ser resumidos em dois tipos principais: o supervisionado, quando o ajuste dos pesos ocorre com a comparação entre a saída real e a predita e o tipo não supervisionada onde a rede não conhece a saída e as regras que determinam a atualização dos pesos, baseiam-se na correlação dos dados de entrada. (DING et al., 2013; SVOZIL; KVASNICKA; POSPICHAL, 1997). De qualquer forma, espera-se que um modelo baseado em RNA seja capaz de utilizar a aprendizagem sobre conjuntos desconhecidos.

Cada RNA possui uma configuração específica que se adapta a cada tipo de problema e deve ser modelada para que não se limite ao conjunto de dados utilizados na construção da rede. Por outro lado, não deve ser tão flexível a ponto de replicar os erros aprendidos a outros conjuntos de dados. Assim, o tipo de RNA, a arquitetura da rede, a quantidade de neurônios na camada escondida, a função de ativação e as regras de treinamento (algoritmos de aprendizagem) são configurações determinantes para o desempenho da RNA (SHEELA; DEEPA, 2013).

Alguns destes parâmetros são definidos empiricamente, mas conhecer como afetam o desempenho do modelo pode contribuir para essas escolhas. O número de neurônios, por exemplo, não pode ser um valor alto demais para não levar à memorização dos dados pela rede (excesso de adaptação). Por outro lado, um número elevado de camadas escondidas pode prejudicar o treinamento, pois como a estabilidade da rede é calculada pelo erro entre os dados estimados e os reais, isso pode gerar muitas previsões sobre os erros das camadas anteriores (SHEELA; DEEPA, 2013).

O treinamento da RNA busca extrair padrões dos dados de entrada e faz diversos ciclos de aprendizagem em que a rede compara a resposta predita com a real. Em cada ciclo os pesos e bias são atualizados com a intenção de melhorar a resposta da rede. Estes ciclos são realizados até atingir o critério de parada, que é determinada na última etapa de configuração da rede. Um possível critério de parada pode ser o número de ciclos, ou seja, quantas vezes a rede deve processar os dados para a aprendizagem. Outro critério pode ser a definição de um erro máximo atingido, o que indica que a rede foi capaz de aprender com os dados.

As RNA têm sido estudadas em pesquisas na área animal como ferramenta de análise de dados para previsão de medidas fisiológicas. Sousa et al. (2018) desenvolveram um modelo, baseado em RNA para estimar o nível de estresse térmico em bovinos de corte (Nelore). Dados ambientais e de temperatura de superfície dos animais foram utilizados como parâmetros de entrada da rede e, como saída, a TR. A etapa de teste do melhor modelo indicou um coeficiente de correlação de 0,85 entre os dados reais e preditos.

Brown-Brandl; Jones; Woldt (2005) desenvolveram e avaliaram cinco modelos para estimar a FR de bovinos de corte (dois modelos estatísticos, dois baseados em lógica difusa (*Fuzzy*) e um em RNA). Como variáveis de entrada dos modelos utilizaram dados meteorológicos (temperatura de bulbo seco, temperatura de ponto de orvalho, radiação solar e velocidade do vento) e a TIV. Os melhores modelos, apesar de similares, foram em ordem decrescente: rede neural artificial, os baseados lógica difusa e os estatísticos. Apesar da TIV ter

sido utilizada, sua contribuição nos modelos foi apenas para qualificar as raças e não para indicar as variações de temperatura dentro delas.

Hernández-Julio et al. (2014) estudaram diferentes modelos para prever a FR e a TR de vacas Holandesas. Para a predição dos parâmetros fisiológicos os autores utilizaram a temperatura e a umidade relativa do ar. Os modelos baseados em RNA apresentaram desempenho superior em relação aos modelos estatísticos e neurofuzzy estudados pelos autores no mesmo trabalho.

Há um vasto campo de aplicações para RNA em diversas áreas de conhecimento e que podem ser utilizadas para interpretação de diferentes tipos de dados. Dados fisiológicos e meteorológicos comumente monitorados dos rebanhos leiteiros podem ser submetidos a modelos computacionais baseados em RNA para estimar variáveis fisiológicas (FR e TR) de vacas Holandesas.

3.4.2 Redes Neurais Convolucionais

As redes neurais convolucionais (*Convolutional Neural Network* - CNN), assim como as RNA, são algoritmos baseados no neurônio biológico humano, capaz de processar e analisar informações do ambiente externo. No caso da CNN, a rede é projetada para interpretar os dados de entrada por meio de uma composição de funções. Em cada camada um determinado tipo de função opera sobre os dados para extrair informações que serão atribuídas às próximas funções. A aplicação deste tipo de rede neural se intensificou com o desenvolvimento das técnicas computacionais e sistemas de armazenagem de dados que ocorreram nos últimos anos.

As CNN fazem parte da técnica de Aprendizagem Profunda (*Deep Learning*). O termo profundo é utilizado porque o processo de aprendizagem deve extrair padrões de dados mais complexos como, por exemplo, imagens e áudios. Segundo LeCun, Bengio e Hinton (2015), a técnica da Aprendizagem Profunda superou barreiras da inteligência artificial na solução de problemas como reconhecimento de imagens e vozes e tem fornecido resultados promissores em análises de perguntas e sentimentos, reconstrução de circuitos cerebrais e outros domínios da ciência que lidam com dados em alta dimensão.

A arquitetura básica de uma CNN é composta de dois estágios principais: o primeiro estágio é composto por camadas convolucionais e de agrupamento e o segundo consiste no processo de classificação, composto por camadas ocultas e completamente conectadas, como em uma rede neural convencional (LECUN; BENGIO; HINTON, 2015).

As camadas convolucionais são responsáveis pela extração de padrões (*feature maps*) em que os filtros (*kernel*) com diferentes operações matemáticas são aplicados em subregiões

da matriz principal. Cada tipo de filtro pode extrair um tipo diferente de padrão e gera uma saída para a próxima camada que corresponde a um elemento visual capturado da imagem original. Todas as unidades das matrizes recebem o mesmo banco de filtros em cada etapa de convolução (RODRÍGUEZ ALVAREZ et al., 2018). Assim como na RNA, a aprendizagem da CNN ocorre com a atualização dos pesos sinápticos. Neste caso, os pesos sinápticos são os próprios filtros.

Em sequência às camadas de convolução, existem as camadas de agrupamento (*pooling/subsampling*). A função desta etapa é reduzir a dimensão das matrizes ao mesclar características semelhantes que foram extraídas na etapa anterior. Este processo pode eliminar dados redundantes, o que facilita a aprendizagem e aumenta a rapidez do treinamento. (LECUN; BENGIO; HINTON, 2015; RODRÍGUEZ ALVAREZ et al., 2018).

Após as camadas de convolução e agrupamento, as informações extraídas são organizadas em uma camada de classificação completamente conectada. Nesta camada, os resultados obtidos das camadas anteriores são classificados em categorias pré-definidas na construção da CNN. Assim, diferente de uma RNA que pode oferecer dados finitos na saída, a CNN oferece como resposta a atribuição de um dado em um nível de classificação. Adicionalmente uma camada final com uma função *softmax* é frequentemente utilizada na saída do classificador como forma de distribuir os valores em probabilidades de estarem em cada uma das classes. (RODRÍGUEZ ALVAREZ et al., 2018)

A Figura 5 exemplifica o processo de aprendizagem de uma CNN que recebe como entrada uma imagem digital com três canais RGB (vermelho, verde e azul). Camadas de convolução e agrupamento são responsáveis pela extração de padrões. Dependendo do tipo de problema analisado, mais etapas de convolução e agrupamento podem ser aplicadas sobre as matrizes. As informações extraídas na primeira etapa serão utilizadas como entradas na etapa de classificação.

Figura 5. Arquitetura de uma rede neural convolucional.

O crescente interesse em CNN tem estimulado a utilização da técnica em pesquisas na pecuária para buscar soluções de problemas que envolvem classificação de imagens de bovinos. Rodriguez Alvarez et al. (2018) desenvolveram e avaliaram um sistema baseado em CNN para predição do escore da condição corporal (ECC) de vacas de leite (Holandesas). Os autores utilizaram 1661 imagens profundas obtidas com sensor kinect (Microsoft Kinect v2 Tof) que foram divididas em 12 classes de ECC. Do total de imagens, 70% foram utilizadas para treinamento, 15% para validação e 15% para teste do modelo. As análises de performance do modelo foram feitas considerando 0,0, 0,25 ou 0,50 unidades de ECC como margens de erro, calculadas pela diferença entre o valor real de ECC com o predito pelo modelo. As acurácias obtidas em cada um dos casos foram 0,39, 0,77 e 0,94, respectivamente.

A CNN pode ser aplicada em diferentes tipos de problemas e tem se mostrado eficiente no reconhecimento de padrões de cor e forma em imagens (MISIMI et al., 2017). Por esta razão tem sido estudada em diversos setores da produção animal. Alguns exemplos são: sistema de reconhecimento individual de suínos (HANSEN et al., 2018); predição de gordura intramuscular em suínos vivos, por meio de análise de imagens de ultrassom (KVAM; KONGSRO, 2017) e; sistema de reconhecimento de posturas em imagens de infravermelho (Kinect) de porcas em lactação (ZHENG et al., 2018).

Por outro lado, a CNN ainda não foi utilizada para a interpretação de imagens térmicas, comumente utilizadas para monitoramento das trocas de calor entre os animais e o ambiente. A utilização da CNN pode ser útil se conseguir extrair padrões de cor e distribuição da cor (temperatura e distribuição da temperatura) que permitam predizer a situação de conforto térmico de vacas de leite com a vantagem de evitar a análise por especialistas e etapas prévias de processamento de imagens, por permitir operar com imagens mais brutas e menos padronizadas em relação aos métodos clássicos de processamento de imagens.

4. MATERIAL E MÉTODOS

Este estudo contou com três etapas de desenvolvimento (Figura 6): a primeira etapa contou com o processo de aquisição e análise de dados. Com a análise estatística nós conseguimos os primeiros objetivos do estudo que foi definir quais regiões corporais estiveram melhor correlacionadas com a FR e TR e observou-se a correlação entre os dados fisiológicos e climáticos. Estes primeiros resultados foram fundamentais para que fossem definidas as entradas dos modelos computacionais, desenvolvidos na segunda etapa do presente trabalho. No caso da RNA nós conseguimos uma primeira avaliação do melhor modelo baseando-se nas análises de regressão linear entre os valores fisiológicos preditos e medidos obtidos com os modelos computacionais e com equações de regressão linear utilizadas como método de comparação dos resultados. A última etapa foi o processo de classificação dos dados de FR e TR obtidos com a RNA e das imagens térmicas classificadas com a CNN onde foram definidos os melhores modelos classificadores.

Figura 6. Resumo da metodologia.

4.1 Localização e instalações

O projeto foi realizado na Faculdade de Zootecnia e Engenharia de Alimentos (FZEA), em Pirassununga (PUSP) – SP, localizada a 21° 59' 46" S 47° 25' 33" W e altitude aproximada de 627 metros. O clima da região é do tipo Cwa de Köppen com duas estações bem definidas (verão chuvoso e inverno seco), com raras ocorrências de geadas. A cidade possui temperatura do ar e pluviosidade média anual de 21,5 °C e 1395,1 mm, respectivamente.

A coleta de dados foi realizada no Setor de Bovinocultura de Leite da Prefeitura do Campus Administrativo Fernando Costa (PCAPS) da USP. A instalação é um galpão do tipo

estabulação livre (*free-stall*), com cobertura de telha ondulada de fibrocimento, estruturas de madeira, pé direito de 3,2 m, área coberta total de 200 m² (16 x 13 metros, orientação sudeste-noroeste) e com piso de cimento rugoso e declividade 10 % (Figura 7).

Figura 7. Visão geral do free-stall onde foram realizadas as coletas para o *experimento*.

A construção possui 20 baias de concreto com divisões de madeira para camas de areia com livre acesso dos animais (Figura 8). Os cochos de alimentação estão dispostos na faixa sul da extensão do *free-stall* sendo destinados 80 cm por animal. Os bebedouros estão localizados nas extremidades e no centro da construção, sendo dois de concreto e um de plástico. A construção conta com quatro ventiladores sendo dois localizados em uma das extremidades e dois na região central. Tanto a alimentação, quanto a água são fornecidas livremente aos animais. A distribuição da alimentação, composta por forragens e concentrado, e a ordenha é realizada duas vezes ao dia, no período da manhã (7 h) e à tarde (14 h).

Figura 8. Baías de madeira com camas de areia para acesso livre dos animais.

4.2 Animais

O experimento foi conduzido em dois períodos de coletas de 20 dias: 30 de julho a 18 de agosto de 2018 (inverno) e 15 de janeiro a 3 de fevereiro de 2019 (verão), totalizando 40 dias. Foram utilizadas 26 vacas da raça Holandesa (preta e branca) com produção média de 20 kg de leite/dia. A quantidade de animais utilizadas para cada período foram, 21 e 14, respectivamente, sendo que alguns animais se repetiam nos diferentes períodos.

4.3 Coleta de dados

4.3.1 Caracterização do ambiente climático

Os dados meteorológicos do ambiente externo foram obtidos através da Estação Meteorológica da Usina Solar do Campus USP de Pirassununga (coordenadas: 21°57'0" S, 47°27'11" O). A estação coleta dados de temperatura de bulbo seco, umidade relativa do ar a cada minuto, durante 24 horas, todos os dias. As variáveis e parâmetros meteorológicos do ambiente externo, foram avaliados considerando o período total (inverno e verão) e os resultados podem ser vistos no Apêndice A.

Para o monitoramento do microclima da instalação (ambiente interno) foram utilizados dois coletores de dados (Onset HOBO) com termômetros de globo negro (Figura 9) instalados no *free-stall*. Estes equipamentos coletam automaticamente dados meteorológicos durante todo o experimento, 24 horas por dia, registrando dados a cada meia hora.

A análise dos dados do ambiente interno, foi feita considerando o período total, sendo:

- (1) Temperatura e umidade relativa do ar (T_i e UR_i);
- (2) Temperatura de globo negro (TGN_i).

A partir destes dados, o *software* (Onset HOBOT) forneceu:

- (3) Temperatura de ponto de orvalho (TPO_i), que é calculada considerando a temperatura e umidade relativa do ar e indica a temperatura na qual o ar deve ser resfriado para que haja a condensação da água.

Com os dados meteorológicos do ambiente interno, também foram monitoradas a temperatura e umidade relativa do ar para cada período:

- (4) Temperatura e umidade relativa do ar do período 1 (T_{i-1} e UR_{i-1});
- (5) Temperatura e umidade relativa do ar do período 2 (T_{i-2} e UR_{i-2});
- (6) Temperatura de globo negro do período 1 e 2 (TGN_{i-1} e TGN_{i-2});
- (7) Temperatura de ponto de orvalho do período 1 e 2 (TPO_{i-1} e TPO_{i-2}).

Figura 9. Data logger e globo negro utilizados para monitoramento do ambiente interno durante o período experimental.

4.3.1.1 Índices climáticos

A equação escolhida para o cálculo do ITU foi a apresentada por Thom (1959), de acordo com a eq. (1) e para o ITGU a desenvolvida por Buffington et al. (1981), representada pela eq. (2). Para relacionar os valores de ITU e ITGU com o conforto térmico dos animais foram consideradas as classes definidas de acordo com o Eigenberg et al. (2007) e o *National Weather Service – USA* (1976) (Tabela 1).

$$ITU = 0,72 * (TBS + TBU) + 40,6 \quad (1)$$

Onde:

TBS = Temperatura de bulbo seco, °C;

TBU = Temperatura de bulbo úmido, °C.

$$ITGU = TG + 0,36 * TPO + 41,5 \quad (2)$$

Onde:

TG = Temperatura do termômetro de globo negro, °C;

TPO = Temperatura do ponto de orvalho, °C.

Tabela 1. Classes de conforto térmico consideradas para interpretação dos cálculos do Índice de Temperatura e Umidade (ITU) e o Índice de Temperatura de Globo Negro e Umidade (ITGU).

Referências	Classes	Intervalo
<i>Eigenberg et al. (2007)</i>	Conforto	$ITU \leq 74$
	Alerta	$74 < ITU \leq 78$
	Perigo	$78 < ITU \leq 83$
	Emergência	$ITU > 83$
<i>National Weather Service – USA (1976)</i>	Conforto	$ITGU < 74$
	Alerta	$74 \leq ITGU \leq 78$
	Perigo	$78 < ITGU \leq 84$
	Emergência	$ITGU > 84$

Fonte: própria autoria.

O Índice de Temperatura e Umidade, Índice de Temperatura de Globo Negro e Umidade foram calculados com os dados obtidos dos coletores de dados (*data loggers*) instalados no interior da instalação e foram chamados: Índice de Temperatura e Umidade do ambiente interno (ITUi) e Índice de Temperatura de Globo Negro e Umidade do ambiente interno (ITGUi).

4.3.2 Monitoramento dos animais

Foram coletados dados fisiológicos TR, FR e TIV. A TR foi medida com um termômetro clínico digital (*TechLine*) inserido no reto das vacas (Figura 10) e a FR pela contagem de tempo a cada dez movimentos do flanco, sendo calculado posteriormente o número de movimentos por minuto. Para a obtenção da TIV, imagens de térmicas foram tomadas em diferentes regiões corporais: frente, região ocular, costela e flanco, respeitando um ângulo 90° e uma distância de 2 metros, aproximadamente. Tais medidas foram realizadas em todos os animais (n=26) durante 40 dias, três vezes ao dia (5, 13 e 19 h).

As TIVs foram coletadas com a câmera termográfica TESTO 875-2 (Figura 11) e transmitidas ao software TESTO IRsoft que forneceu os perfis termográficos dos animais estudados. O programa utiliza a temperatura de reflexão (mesmo valor da temperatura de bulbo

seco) para ajuste da temperatura da superfície corporal e a temperatura de bulbo seco e umidade relativa do ar para o cálculo da umidade de superfície corporal dos animais.

Figura 10. Captura da temperatura retal com um termômetro digital de uma das vacas do experimento.

Figura 11. Captura da imagem térmica da região da frente de uma das vacas do experimento.

No software foram analisadas as temperaturas de superfície corporais da região da frente (TIVFRON), área ocular (TIVOL), costela (TIVCOS) e flanco (TIVFLAN) (Figura 12). As regiões foram escolhidas por se tratarem de áreas corporais que favorecem as trocas térmicas e, em estudos anteriores (MARTELLO et al., 2010; 2016; SALLES et al.; 2016; SOUSA et al. 2018), demonstraram potencial para esse tipo de investigação. A frente e a área ocular, por serem regiões próximas ao hipotálamo, centro controlador das atividades de termorregulação

nos animais e o flanco, por se tratar do vazio do animal o que permite contato direto com ambiente corporal interno do animal.

Figura 12. Imagem representando as regiões corporais estudadas nos animais por meio de imagens obtidas com a câmera termográfica.

*Regiões corporais analisadas no software IIRSoft: frente (branco); área ocular (amarelo); costela (azul); flanco (vermelho).

Fonte: Própria autoria.

Para a análise da TIVFRON, TIVCOS e TIVFLAN foi utilizado no software IIRSoft a ferramenta de histograma que forneceu valores de temperatura de superfície corporal mínima, máxima e média de cada região selecionada. Para TIVOL foi anotada apenas a temperatura de superfície corporal máxima. Exemplos dessas análises estão registrados na Figura 13.

Figura 13. Figura representando a imagens térmicas da região da frente, área ocular, costela e flanco de uma vaca, o histograma de temperatura e as temperaturas mínima, média e máxima da região selecionada.

Fonte: Própria autoria.

Os dados produtivos do rebanho indicando a produção média diária de leite de cada vaca em kg/dia, o número de partos de cada vaca e estágio de lactação foram monitorados conforme procedimento operacional realizado pelo Setor de Bovinocultura de Leite da Prefeitura do Campus Fernando Costa da USP (Tabela 2).

Tabela 2. Dados produtivos do rebanho durante os dois períodos de coletas.

Período	Paridade (nºpartos/vaca)	Lactação (dias)	Produção de leite (kg/dia)
1	2,07	233,92	22,52
2	2,38	361,95	15,93

4.4 Análise estatística

Todos os dados coletados foram organizados em planilha eletrônica e analisados estatisticamente por meio do software SAS® 9.4 (SAS Institute Inc., Cary, NC, USA). No software o procedimento Mixed forneceu as médias e demais parâmetros estatísticos. A correlação de Pearson foi utilizada para avaliar a associação entre as variáveis climáticas, fisiológicas e produtivas e também determinar quais dados de TIV (regiões corporais e parâmetros) estiveram melhor correlacionados com as demais variáveis. O propósito desta análise estatística foi determinar características e parâmetros viáveis para o desenvolvimento dos modelos computacionais, ou seja, quais variáveis seriam utilizadas na entrada dos classificadores (“inputs”).

Os melhores modelos selecionados baseados em RNA foram comparados com modelos de regressão, utilizando o procedimento Stepwise no software SAS 9.4 (SAS Institute Inc., Cary, NC, EUA). Este procedimento permite que sejam inseridas todas as variáveis de interesse para o modelo estatístico que, baseando-se no efeito de cada variável, insere ou tira as mais adequadas para a predição da variável dependente.

A construção destes modelos estatísticos foi feita com o mesmo conjunto de dados que foram usados construir e testar os modelos baseados em RNA, ou seja, de forma que para a construção dos modelos 60% dos dados foram utilizados para treinamento, 20% para validação e 20% para teste; no caso dos modelos estatísticos, 80% dos dados (dados de treinamentos somados aos de validação) foram utilizados para sua construção e a equação que foi testada com os 20% restantes. Assim os dois tipos de modelos puderam ser comparados baseando-se no mesmo conjunto de dados.

A forma de avaliação dos resultados e comparação dos modelos foi feita com parâmetros obtidos da equação de regressão entre o valor real e o predito: a inclinação, o intercepto, o erro médio, a raiz do erro quadrático médio (RMSE) e o coeficiente de determinação (R^2). A inclinação da reta da equação de regressão indica quanto o a variável dependente, representada no eixo “y” varia em função da variável independente, representada no eixo “x”. O intercepto indica o valor em que a equação cruza o eixo “y” quando “x” é igual a zero. O valor ideal da

inclinação e do intercepto variam conforme o tipo e as variáveis que compõem o problema, mas em equações de regressão para comparação de valores reais e preditos, um modelo perfeito apresentaria inclinação igual a 1 e intercepto igual a zero. O erro médio é calculado pela média das diferenças entre os valores preditos e reais e a RMSE é obtida pela raiz do erro médio quadrático. Ambos os valores devem ser o mais próximo de zero possível. A vantagem do RMSE é que ele apresenta o valor do erro na mesma dimensão das variáveis analisadas. Por último, o coeficiente de determinação indica quanto a equação de regressão se ajustou aos dados analisados, ou seja, quanto ele foi capaz de explicar a relação entre os dados. Um valor ideal R^2 seria 1.

4.5 Modelos computacionais para predição de FR e TR

Foram desenvolvidos dois modelos computacionais, um baseado em RNA e outro em CNN. As variáveis FR e TR, foram escolhidas como saídas do modelo (variáveis a serem preditas) pois conforme previsto entre os objetivos deste estudo a FR e TR se tratam de variáveis fisiológicas importantes para caracterizar o estado de conforto térmico dos animais. Para a modelagem baseada em CNN, a FR e a TR foram utilizadas para categorizar e separar as imagens térmicas (*labeling*)

As variáveis escolhidas para comporem a entrada dos modelos foram definidas com base na análise estatística que permitiu identificar as associações mais favoráveis ao aprendizado dos modelos computacionais.

4.5.1 Modelo baseado em Rede Neural Artificial

A RNA foi construída utilizando o software MATLAB® 7.14 (The MathWorks Inc.) e a metodologia utilizada para o seu desenvolvimento foi a *fitting tool*. A arquitetura da RNA utilizada foi a *Perceptron* alimentada adiante (*feed-forward*) com múltiplas camadas (*multi-layered*).

Os dados fornecidos para a rede foram divididos entre as etapas de treinamento (60%), validação (60%) e teste (20%) e número de neurônios na camada escondida foi escolhido empiricamente, de acordo com o desempenho da rede. A função de ativação escolhida foi a sigmóide que, de acordo com testes anteriores apresentou os melhores resultados para este tipo de modelagem. O tipo de treinamento foi o *Levenberg-Marquardt back propagation*, baseado na aprendizagem por correção de erros.

Os últimos parâmetros escolhidos foram os critérios de parada, definindo-se o número de épocas com 50 iterações e a correlação do teste de 0,95 considerado como estabilidade da

rede. O desempenho da rede foi definido de acordo com a comparação entre os dados medidos e os preditos pelo modelo observando o coeficiente de correlação de person (R), a inclinação, o intercepto, o erro médio, a raiz do erro quadrático médio (RMSE) e o coeficiente de determinação (R^2), parâmetros obtidos das equações de regressão. Estes resultados foram comparados com os obtidos com os modelos estatísticos desenvolvidos para estimar a FR e TR.

4.5.2 Classificação e avaliação do modelo baseado em RNA

Os valores preditos pelos melhores modelos na etapa de teste foram classificados em 4 níveis (classes) de estresse térmico (normal, alerta, perigo e emergência), assim como os valores reais de FR e TR, o ITU e o ITGU. Os limites das classes foram baseados em literatura (DUKES et al., 1996; HAHN et al., 1997) (Tabela 3).

Tabela 3. Classificação da frequência respiratória (FR), temperatura retal (TR), Índice de Temperatura e Umidade (ITU) e Índice de Temperatura de Globo Negro e Umidade (ITGU) em classes de estresse térmico.

Classes de estresse térmico	FR (mov/min)	TR (°C)	ITU	ITGU
Normal	$FR \leq 60$	$TR \leq 39,3$	$ITU \leq 74$	$ITGU < 74$
Alerta	$60 < FR \leq 80$	$39,3 < TR \leq 39,7$	$74 < ITU \leq 78$	$74 \leq ITGU \leq 78$
Perigo	$80 < FR \leq 120$	$39,7 < TR \leq 40,5$	$78 < ITU \leq 83$	$78 < ITGU \leq 84$
Emergência	$FR > 120$	$TR > 40,5$	$ITU > 83$	$ITGU > 84$

As comparações entre as classificações dos modelos baseados em RNA, ITU, ITGU e as classificações reais baseadas em FR e TR foram feitas por meio de matriz de confusão, utilizadas para avaliar a eficiência dos classificadores baseados em RNA, ITU e ITGU.

Matrizes de confusão são tabelas que comparam as classificações reais e as preditas por modelos de classificação. Com ela é possível extrair informações úteis para avaliar a qualidade das respostas, pois permite verificar a quantidade ou porcentagem de acertos e erros do classificador em relação a um conjunto de dados de teste. A acurácia, eq. (3), a precisão, eq. (4), sensibilidade, eq. (5) e medida F1, eq. (6) foram os parâmetros calculados a partir de dados extraídos das matrizes de confusão. Tais métricas foram observadas de acordo com Sokolova e Lapalme (2009), conforme descrito a seguir:

Acurácia: valor que indica a eficácia geral do classificador.

$$Acurácia = \frac{Classificações\ corretas}{Total\ de\ predições} \quad (3)$$

Precisão: dos dados que o modelo indicou para determinada classe, quantos foram classificados corretamente. A precisão indica a capacidade do classificador não classificar dados incorretos como positivos.

$$Precisão = \frac{Classificações\ corretas/classe}{Total\ de\ predições/classe\ estimada} \quad (4)$$

Sensibilidade: em relação aos dados corretos, quanto o classificador conseguiu encontrar. A sensibilidade mostra a habilidade do classificador de encontrar todos os exemplos corretos para cada classe.

$$Sensibilidade = \frac{Classificações\ corretas / classe}{Total\ de\ predições / classe\ real} \quad (5)$$

Medida F1: é uma combinação dos resultados de precisão e sensibilidade (média harmônica) e reflete o quão eficiente é o classificador para prever os dados na presença de classes desbalanceadas, ou seja, quando existem classes com quantidades de exemplos menores que as outras.

$$Medida\ F1 = \frac{2*Precisão*Sensibilidade}{Precisão+Sensibilidade} \quad (6)$$

4.5.3 Modelo baseado em Rede Neural Convolucional

O banco de dados utilizados o desenvolvimento dos modelos classificadores baseados em CNN foi obtido a partir das imagens térmicas das vacas, associadas aos seus respectivos dados de FR e TR. Dessa forma, o tipo de aprendizagem escolhido para o desenvolvimento do modelo CNN foi o supervisionado.

A partir da análise estatística, as imagens escolhidas para participarem do modelo CNN (fronte e área ocular) passaram por um pré-processamento, com o intuito de padronizar e organizar o banco de dados com as seguintes etapas:

- (1) No software TESTO IIRSoft foram inseridos dados de temperatura de reflexão (temperatura do ar), umidade do ar de cada período coletado (5, 12 e 19 horas) e a emissividade (0,95), parâmetros importantes para o cálculo da temperatura de superfície corporal da região analisada; as imagens foram salvas em matrizes de temperatura (arquivos xlsx) que possuíam 120x160 pixels, refletindo temperatura de superfície corporal de cada ponto estudado;
- (2) As imagens térmicas foram reconstruídas para que fossem recortadas regiões específicas de cada imagem, gerando novas matrizes de temperaturas (arquivo xlxs).
- (3) Novas imagens térmicas foram obtidas a partir das matrizes de temperaturas dos recortes.
- (4) A fim de aumentar o banco de dados para participarem dos modelos, técnicas de translações e espelhamento foram utilizadas sobre as imagens originais. A translação (Figura 14), consiste em aplicar um filtro de recorte, de tamanho menor que a imagem original em posições diferentes da imagem, de forma que novas imagens sejam formadas a partir de pedaços recortados da imagem original. A técnica de espelhamento (Figura 15) consiste em fazer uma rotação de 180° na imagem original em que uma segunda imagem é formada com o inverso da imagem original. Dessa forma, 4 imagens foram transladas de cada imagem original e, para cada uma das 5 imagens construídas (1 original + 4 transladas) foi feito um espelhamento, totalizando 10 imagens para cada imagem térmica original (Figuras 14 e 15).

Figura 14. Representação da técnica de translação utilizada sobre as imagens originais para aumentar o banco de dados de treinamento da rede neural convolucional (CNN).

Figura 15. Representação da técnica de translação utilizada sobre as imagens originais para aumentar o banco de dados de treinamento da rede neural convolucional (CNN).

(5) O banco de dados total foi formado com 18480 imagens térmicas da frente e 18510 da área ocular que foram separadas conforme faixas de FR e TR (*labeling*), respectivamente (Tabela 4). A escolha das faixas de conforto térmico para a CNN foi feita de forma que houvesse uma distribuição balanceada de imagens entre as classes.

Tabela 4. Classes de frequência respiratória (FR) e temperatura retal (TR) consideradas para a distribuição do banco de dados de imagens térmicas.

Variáveis		Classes	
FR (mov/min)	≥ 40	41 - 60	≥ 61
	$\geq 38,4$	38,5 – 39,0	$\geq 39,1$

A arquitetura da CNN foi construída de acordo com o modelo *Sequential* e a biblioteca *Keras 2.0.6* no software *Python 3.5.4 rc1*. De acordo com o protocolo de validação cruzada as imagens utilizadas foram divididas em 80% para a etapa de treinamento, 10% para validação e 10% para teste. O tipo (convolução e agrupamento), tamanho e quantidade de núcleos (9) (Figura 16), o passo, a função de ativação e quantidade de camadas foram definidos empiricamente, assim como o número de épocas e o erro mínimo atingido.

Figure 16. Camadas utilizadas na Rede Neural Convolucional (CNN) .

```
Conv2D(64, kernel_size = (5, 5), activation = 'relu')  
MaxPooling2D(pool_size = (2, 2))  
BatchNormalization()  
Conv2D(32, kernel_size = (3, 3), activation = 'relu')  
MaxPooling2D(pool_size = (2, 2))  
BatchNormalization()  
Flatten()  
Dense(1000, activation = 'relu')  
Dense(n_classes, activation = 'softmax')
```

O desempenho do modelo foi avaliado comparando-se as classificações dos modelos e as classificações reais de acordo com matrizes de confusão. A acurácia, precisão, sensibilidade e medida F1 foram as métricas calculadas das matrizes de confusão para serem consideradas na avaliação do desempenho dos modelos.

5. RESULTADOS E DISCUSSÃO

Os resultados são apresentados na seguinte sequência: estatística dos dados coletados nos dois períodos; construção e avaliação do modelo baseada em RNA; e construção e avaliação do modelo baseado em CNN.

5.1 Estatística descritiva e análise de Regressão Linear

A variáveis do ambiente interno (Tabela 5) registraram a T_i abaixo de 24 °C, valor considerado por alguns autores (JOHNSON E VANJONACK, 1976; NÃÃS, 1989; MARTELLO, 2006) como limite crítico para estresse térmico em vacas lactantes. A UR_i apresentou média igual a 67,31 %. Por outro lado, os parâmetros foram observados por período, a T_{i-1} apresentou valor de 19,17°C e a T_{i-2} de 29,21°C e os valores máximos foram 31,11°C (T_{i-1}) e 37,65 °C (T_{i-2}). Estes valores demonstram que as vacas experimentaram condições climáticas críticas, especialmente no verão.

A média de UR_i apresentou valor de 67,31%, sendo 70,81% para UR_{i-1} e 62,59% para UR_{i-2} . Apesar de um dos períodos de coleta ter ocorrido no inverno, que costuma ser uma estação seca, a estação de 2018 foi atípica, com momentos de chuvas intensas. A alta umidade relativa do ar contribui negativamente para o conforto térmico, já que a alta concentração de água na atmosfera dificulta a evapotranspiração dos animais para o ambiente, um dos principais mecanismos utilizados pelos ruminantes para controle de temperatura corporal (TITTO et al., 2013).

Tabela 5. Estatística descritiva dos dados meteorológicos registrados do ambiente interno.

Período	Variável	N	Média	Desvio Padrão	Mínimo	Máximo
Geral	Ti	1882	23,45	7,43	7,71	37,65
	URi	1882	67,31	19,92	27,90	95,41
	TBUi	1882	18,36	4,46	6,60	25,70
	TGNi	1849	23,55	7,72	7,16	38,31
	TPOi	1882	16,18	4,40	5,60	23,04
	ITU	1882	77,10	8,33	57,31	92,48
	ITGU	1862	70,83	8,98	49,22	87,59
Inverno	Ti-1	1080	19,17	4,97	7,71	31,11
	URi-1	1080	70,81	18,73	27,90	95,41
	TBUi-1	1080	15,20	2,83	6,60	20,70
	TGNi-1	1060	19,49	5,70	7,16	32,04
	TPOi-1	1080	13,04	3,05	5,60	18,40
	ITU-1	1080	71,75	5,29	57,31	82,21
	ITGU-1	1060	65,80	6,16	50,78	77,39
Verão	Ti-2	802	29,21	6,20	18,66	37,65
	URi-2	802	62,59	20,51	35,54	95,27
	TBUi-2	802	22,62	2,08	18,10	25,70
	TGNi-2	789	29,00	6,64	18,52	38,31
	TPOi-2	802	20,40	1,41	17,20	23,04
	ITUi-2	802	84,32	5,87	73,47	92,48
	ITGUi-2	802	77,47	7,73	49,22	87,59

Temperatura de bulbo seco (Ti); umidade relativa do ar (URi); temperatura de bulbo úmido (TBUi) temperatura de ponto de orvalho (TPOi); e temperatura de globo negro (TGNi). Índice de Temperatura e Umidade (ITU); Índice de Temperatura de Globo Negro e Umidade (ITGU).

Número de amostras analisadas (N). Siglas sem sufixo representam as médias de todas as variáveis registradas durante todo o experimento (40 dias); Siglas com o sufixo “-1” representam as médias das variáveis durante inverno; Siglas com o sufixo “-2” representam as médias das variáveis durante verão.

A estatística descritiva dos dados fisiológicos (Tabela 6) indica que o valor médio de FR registrado durante todo o experimento foi 52,83 mov/min. Este valor está abaixo de 60 mov/min, que é considerado crítico para o conforto térmico em bovinos de leite (HAHN et al., 1997). Em relação a média de TR, o valor 38,74 °C está dentro da faixa de conforto térmico indicado por alguns autores (HOUSTON E RADOSTIS, 2000; PEREIRA et al., 2013). Com relação a estes valores de FR e TR, duas das três coletas diárias aconteceram em horários de clima mais ameno (5 e 19 horas) e um dos períodos experimentais ocorreu no inverno (período 2), o que pode ter contribuído para estes valores dentro da faixa de conforto. No entanto, a os valores máximos de FR (126,05 mov/min) e TR (41,1 °C), e as médias de FR-2 (69,69 mov/min) e TR-2 (39,3°C), no período mais quente, indicam que os animais apresentaram algum nível de estresse térmico.

A TIVOLmax, apresentou média de 36,65 °C que é maior que as médias de temperaturas máximas registradas para as outras regiões corporais: TIVFRONmax (32,05°C), TIVCOSmax (33,67°C) e TIVFLANmax (33,41°C). Uma possível explicação para essa diferença de temperatura pode ser a quantidade de pelos, que é maior na outras regiões em comparação com área ocular. Os pêlos podem favorecer o acúmulo de sujeira e umidade o que pode interferir nas trocas de calor entre os animais e o ambiente e impedir que a câmera capte medidas mais próximas da pele do animal. A área ocular também é uma região que apresenta maior irrigação sanguínea superficial e, não sendo coberta por pelos, favorece a obtenção mais precisa da temperatura da pele nessa região. Neste sentido, as imagens de TIVOLmax ofereceram medidas mais estáveis de temperatura, com menor desvio padrão (0,94) comparada com as demais regiões corporais.

Tabela 6. Estatística descritiva dos dados fisiológicos dos animais coletados durante o período experimental.

Período	Variável	N	Média	Desvio Padrão	Mínimo	Máximo
Geral	FR	1856	52,83	20,55	14,19	126,05
	TR	1856	38,74	0,74	36,40	41,10
Inverno	FR-1	1056	40,06	10,39	14,19	85,47
	TR-1	1056	38,32	0,46	36,40	40,50
Verão	FR-2	800	69,69	18,39	25,59	126,05
	TR-2	800	39,30	0,66	37,30	41,10
Geral	TIVFRONmin	1866	24,81	6,40	7,00	39,70
	TIVFRONmax	1866	32,05	3,66	20,40	43,00
	TIVFRONmed	1866	27,85	5,48	12,70	41,10
	TIVOLmax	1866	36,65	0,94	33,60	39,60
	TIVCOSmin	1817	30,22	3,78	15,10	38,10
	TIVCOSmax	1817	33,67	3,07	19,20	40,00
	TIVCOSmed	1817	32,14	3,43	17,50	38,80
	TIVFLANmin	1816	30,40	4,07	12,40	37,70
	TIVFLANmax	1816	33,41	3,16	18,90	39,90
	TIVFLANmed	1816	32,01	3,58	15,50	38,90

Frequência respiratória (FR); temperatura retal (TR); TIVFRONmin: temperatura mínima de superfície da frente dos animais obtidas com técnica de termografia e infravermelho; TIVFRONmax: temperatura máxima de superfície da frente dos animais obtidas com técnica de termografia e infravermelho; TIVFRONmed: temperatura média de superfície da frente dos animais obtidas com técnica de termografia e infravermelho; TIVOLmax: temperatura máxima de superfície da área ocular dos animais obtidas com técnica de termografia e infravermelho. TIVCOSmin: temperatura mínima de superfície da costela dos animais obtidas com técnica de termografia e infravermelho; TIVCOSmax: temperatura máxima de superfície da costela dos animais obtidas com técnica de termografia e infravermelho; TIVCOSmed: temperatura média de superfície da costela dos animais obtidas com técnica de termografia e infravermelho; TIVFLANmin: temperatura mínima de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho; TIVFLANmax: temperatura máxima de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho; TIVFLANmed: temperatura média de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho; Número de amostras analisadas (N). Siglas com o sufixo “-1” representam as médias das variáveis durante o inverno; Siglas com o sufixo “-2” representam as médias das variáveis durante o verão.

Os comportamentos diários dos dados fisiológicos e da temperatura do ar (ambiente interno) em cada período de coleta foram analisados através dos diagramas apresentados nas Figuras 17 a 20. A FR-1 e FR-2 apresentaram comportamentos similares a Ti-1 e Ti-2, respectivamente, sendo que, os valores subiram entre os horários das 5 até 12 horas e depois decresceram até as 19 horas (Figuras 17 e 19). Por outro lado, a TR-2 se comportou de forma diferente a Ti-2 (Figura 20). Enquanto a Ti-2 apresentou seu valor máximo próximo as 12 horas e depois decresceu, a TR-2 subiu até as 12 horas e depois continuou subindo com mais intensidade até as 19 horas, quando atingiu o seu valor máximo.

Titto et al. (2013) avaliaram o efeito da temperatura do ar nas respostas fisiológicas de vacas Holandesas lactantes durante as estações do ano em dois tipos de ambientes (resfriados e não resfriados). Somente durante o verão chuvoso, a FR foi maior para animais em ambientes não resfriados. Os autores justificaram que associação de alta temperatura do ar ($23,16^{\circ}\text{C}$) e alta umidade relativa (77%) pode ter comprometido a perda de calor por evaporação, tornando difícil para as vacas resfriarem-se. No presente estudo, o mesmo foi observado durante o verão, quando a média de Ti-2 foi $29,21^{\circ}\text{C}$ e a UR-2 atingiu um valor máximo de 95,27% (Tabela 5) e a FR-2 as 12 e 19 horas permaneceram acima de 70 mov/min (Figura 11).

Estes altos valores de FR-2 podem explicar a diferença de comportamento da TR-2 (Figura 20) em comparação com a TR-1 (Figura 18). De modo geral, quando os animais são submetidos a altas temperaturas do ar e os sistemas de dissipação de calor (vias evaporativas e não evaporativas) não são suficientes para regularizar a homeotermia e a TR pôde continuar crescendo por um período maior, pela energia acumulada durante os horários mais quentes do dia.

De Andrade Ferrazza et al. (2017) estudaram como os parâmetros fisiológicos de vacas Holandesas foram afetados em condições de estresse térmico. Quando as vacas foram submetidas a estresse térmico constante, o aumento da FR precedeu o aumento da TR em 12 horas. No presente estudo, a média de Ti-2 ($29,21^{\circ}\text{C}$) indica que as vacas foram submetidas a dias consecutivos de altas temperaturas do ar, explicando o comportamento da TR-2 (Figura 20). Enquanto a FR-2 indicou uma resposta mais imediata à variação climática, alcançando seu valor máximo próximo as 12 horas (Figura 19), a TR-2 continuou aumentando até as 19 horas (Figura 20).

Figura 17. Gráfico representando a variação da temperatura do ar (Ti-1) e da frequência respiratória (FR-1) das vacas durante o período 1 de coletas.

Figura 18. Gráfico representando a variação da temperatura do ar (Ti-1) e da temperatura retal (TR-1) das vacas durante o período 1 de coletas.

Figura 19. Gráfico representando a variação da temperatura do ar (Ti-2) e da frequência respiratória (FR-2) das vacas durante o período 2 de coletas.

Figura 20. Gráfico representando a variação da temperatura do ar (Ti-2) e da temperatura retal (TR-2) das vacas durante o período 2 de coletas.

A análise dos coeficientes de correlação de Pearson entre os dados coletados foi feita considerando o período total (inverno e verão). Esta etapa é importante para identificar as variáveis mais indicadas para participarem dos modelos computacionais pois, ao considerar os dois períodos, é possível obter uma variação maior do ambiente climático e das respostas dos animais e isso pode contribuir com o aprendizado dos modelos e facilitar sua automatização.

Os coeficientes de correlação entre as variáveis meteorológicas, os índices climáticos do ambiente interno e as variáveis e fisiológicas (Tabela 7) demonstraram valores de correlações moderados a altos. Os maiores valores correlacionados com FR foram Ti (0,77) e TBUi (0,77) e ITUi (0,79). O mesmo aconteceu para os valores de TR em que os maiores valores apresentados foram correlacionados com a Ti (0,68), TBUi (0,68) e ITU (0,70). De

modo geral, todas as variáveis climáticas e os índices climáticos estiveram melhores correlacionados com a FR do que com a TR.

Com relação aos dados de TIV, a região corporal que melhor se correlacionou com as variáveis climáticas foi a frente, sendo que a TIVFRONmin e TIVFRONmed apresentaram valores de correlações nas mesmas magnitudes com as variáveis climáticas. Estas correlações variaram de 0,63 (com TPOi) até 0,93 (com TGNi), sendo que as maiores correlações foram com Ti (0,92), TGNi (0,93) e ITUi (0,90). Salles et al. (2016) comparou a temperatura de superfície de diversas regiões corporais de vacas Jersey e, da mesma forma que o presente estudo encontrou altos índices de correlação com o ITU, sendo que os maiores valores encontrados foram com os flancos direito (0,85) e esquerdo (0,81) e a frente (0,81).

Titto et al. (2013) avaliaram o efeito da temperatura do ar nas respostas fisiológicas de vacas Holandesas e encontraram valores de correlação moderados entre a TR e a temperatura do ar (0,50), umidade relativa do ar (-0,39) e temperatura de superfície corporal (TS) da região dorsal (0,46). Já para a FR, encontraram valores de 0,43, -0,29 e 0,39 com a temperatura do ar, umidade relativa do ar e TS, respectivamente. Em relação ao ITU observaram correlações de 0,49 (TR), 0,43 (FR) e 0,69 (TS), respectivamente.

Uma possível explicação para as altas correlações obtidas neste estudo é o fato de se ter avaliado animais em diferentes períodos do ano (verão e inverno) submetidos a uma mesma instalação. Dessa forma, as associações entre as características fisiológicas e climáticas tornaram-se bastante evidentes pois as vacas puderam expressar suas respostas fisiológicas em função das diferenças dos períodos meteorológicos.

Tabela 7. Coeficiente de correlação de Pearson relacionando variáveis meteorológicas, Índices climáticos e variáveis fisiológicas.

Variáveis	Variáveis climáticas					Índices climáticos	
	Ti	URi	TBUi	TGNi	TPOi	ITUi	ITGUi
FR	0,77	-0,49	0,77	0,75	0,67	0,79	0,73
TR	0,68	-0,42	0,68	0,64	0,59	0,70	0,61
TIVFRONmin	0,92	-0,73	0,80	0,93	0,63	0,90	0,88
TIVFRONmax	0,85	-0,70	0,71	0,86	0,55	0,82	0,82
TIVFRONmed	0,92	-0,73	0,80	0,93	0,63	0,90	0,88
TIVOLmax	0,70	-0,46	0,67	0,69	0,58	0,71	0,66
TIVCOSmin	0,84	-0,63	0,77	0,84	0,61	0,83	0,81
TIVCOSmax	0,86	-0,66	0,78	0,87	0,62	0,85	0,83
TIVCOSmed	0,86	-0,65	0,79	0,87	0,63	0,86	0,83
TIVFLANmin	0,84	-0,62	0,78	0,84	0,63	0,84	0,81
TIVFLANmed	0,85	-0,63	0,78	0,86	0,63	0,85	0,82
TIVFLANmax	0,85	-0,64	0,78	0,86	0,63	0,85	0,83

Frequência respiratória (FR); temperatura retal (TR); TIVFRONmin: temperatura mínima de superfície da frente dos animais obtidas com técnica de termografia e infravermelho; TIVFRONmax: temperatura máxima de superfície da frente dos animais obtidas com técnica de termografia e infravermelho; TIVFRONmed: temperatura média de superfície da frente dos animais obtidas com técnica de termografia e infravermelho; TIVOLmax: temperatura máxima de superfície da área ocular dos animais obtidas com técnica de termografia e infravermelho. TIVCOSmin: temperatura mínima de superfície da costela dos animais obtidas com técnica de termografia e infravermelho; TIVCOSmax: temperatura máxima de superfície da costela dos animais obtidas com técnica de termografia e infravermelho; TIVCOSmed: temperatura média de superfície da costela dos animais obtidas com técnica de termografia e infravermelho; TIVFLANmin: temperatura mínima de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho; TIVFLANmax: temperatura máxima de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho; TIVFLANmed: temperatura média de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho.

A análise dos dados meteorológicos do ambiente externo (APÊNDICE A) demonstrou, em sua maioria, valores de coeficientes de correlação menores que os dados registrados do ambiente interno, indicando que os dados do ambiente interno indicaram maior relação com as condições de estresse ou conforto das vacas. Nesse sentido, os *data loggers* instalados no *free-stall*, permitiram representar de forma mais fidedigna o microclima da instalação em que as vacas permaneciam a maior parte do tempo.

Em relação aos coeficientes de correlação de Pearson entre as variáveis fisiológicas (FR, TR e TIV) (Tabela 8), as correlações entre FR e TIV foram maiores do que TR e TIV sendo que todos os valores entre FR e TIV estiveram acima de 0,66 e o maior valor registrado foi com TIVFRONmed (0,70). Os coeficientes de correlação entre os dados de TIV e a TR apresentaram valores acima de 0,50 e o maior valor de correlação foi obtido com TIVOLmax (0,61).

Martello et al. (2010) avaliaram a correlação entre a TIV da região dorsal de vacas Holandesas com a FR e TR e encontraram valores de 0,54 e 0,64, respectivamente. Os valores

encontrados são similares aos valores de TIV encontrados no presente estudo. No entanto, no presente estudo, a FR foi melhor correlacionada com os dados de TIV que a TR, ao contrário do encontrado pelos autores citados. Salles et al (2016) encontraram que a TIV da região da frente de vacas Jersey foi a melhor correlacionada com a TR (0,35) e o flanco esquerdo melhor correlacionado com a FR (0,48), apesar disso as correlações estiveram abaixo das encontradas no presente estudo.

Tabela 8. Coeficiente de correlação de Pearson relacionando as variáveis fisiológicas.

Variáveis	TR	TIVFRON min	TIVFRON max	TIVFRON med	TIVOL max	TIVCOS min	TIVCOS max	TIVCOS med	TIVFLAN max	TIVFLAN min	TIVFLAN med
FR	0,72	0,68	0,64	0,70	0,66	0,66	0,66	0,68	0,66	0,67	0,66
TR	-	0,54	0,50	0,55	0,61	0,55	0,55	0,56	0,55	0,56	0,55
TIVFRONmin		-	0,91	0,98	0,72	0,87	0,90	0,90	0,89	0,87	0,88
TIVFRONmax			-	0,94	0,71	0,82	0,86	0,86	0,86	0,82	0,84
TIVFRONmed				-	0,73	0,88	0,92	0,91	0,91	0,88	0,90
TIVOLmax					-	0,69	0,72	0,72	0,71	0,68	0,70
TIVCOSmin						-	0,95	0,97	0,95	0,95	0,95
TIVCOSmax							-	0,99	0,98	0,95	0,97
TIVCOSmed								-	0,98	0,96	0,98
TIVFLANmax									-	0,96	0,99
TIVFLANmin										-	0,98
TIVFLANmed											-

Frequência respiratória (FR); Temperatura retal (TR); TIVFRONmin: temperatura mínima de superfície da fronte dos animais obtidas com técnica de termografia e infravermelho; TIVFRONmax: temperatura máxima de superfície da fronte dos animais obtidas com técnica de termografia e infravermelho; TIVFRONmed: temperatura média de superfície da fronte dos animais obtidas com técnica de termografia e infravermelho; TIVOLmax: temperatura máxima de superfície da área ocular dos animais obtidas com técnica de termografia e infravermelho. TIVCOSmin: temperatura mínima de superfície da costela dos animais obtidas com técnica de termografia e infravermelho; TIVCOSmax: temperatura máxima de superfície da costela dos animais obtidas com técnica de termografia e infravermelho; TIVCOSmed: temperatura média de superfície da costela dos animais obtidas com técnica de termografia e infravermelho; TIVFLANmin: temperatura mínima de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho; TIVFLANmax: temperatura máxima de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho; TIVFLANmed: temperatura média de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho.

5.2 Rede Neural Artificial

Os resultados da seção anterior serviram de base para determinar quais as variáveis deveriam fazer parte dos modelos computacionais. Foram desenvolvidos dois tipos de modelos baseados em RNA, um para predição da FR e outro para a predição da TR, que se tratam de variáveis importantes para acessar o estado de conforto térmico das vacas, mas que são inviáveis de serem monitoradas em grande escala.

A construção destes modelos foi feita utilizando dados meteorológicos e de TIV como entradas e as variáveis FR e TR como saídas. A proposta é que estes modelos computacionais como estes possam encontrar um padrão para associar entre estas entradas e saídas para prever a FR e TR de forma precisa, ao ponto de que essas variáveis não necessitassem mais ser medidas. Dessa forma, com um modelo eficaz, será possível determinar o estado de conforto térmico dos animais em tempo real e de modo não invasivo, auxiliando a gestão dos sistemas de produção de leite.

Conforme citado anteriormente, a FR e TR foram utilizadas como saídas a serem preditas, além disso, variáveis meteorológicas e de TIV foram escolhidas para comporem as entradas dos modelos computacionais. O primeiro critério de escolha foi determinar a partir da análise estatística quais variáveis de TIV estavam melhores correlacionadas com as saídas (FR e TR). O segundo critério foi verificar quais variáveis meteorológicas estiveram melhores correlacionadas com as TIVs pré-selecionadas no primeiro critério. Como as correlações observadas com os dados do ambiente interno foram melhores que as observadas do ambiente externo, os dados internos foram escolhidos para serem utilizados nos modelos.

A análise estatística indicou que a TIVFRONmed esteve melhor correlacionada com a FR (0,70) (Tabela 10) e, portanto, foi uma das variáveis de entrada escolhida para predizer a FR. Com as variáveis meteorológicas do ambiente interno a TIVFRONmed apresentou correlações de 0,92 com a T_i , -0,73 com U_{Ri} , 0,80 com TBU_i , 0,93 com TGN_i e 0,63 com TPO_i (Tabela 8). Por outro lado TIVOLmax apresentou a melhor correlação com a TR (0,61) (Tabela 10). As correlações entre as variáveis meteorológicas do ambiente interno e a TIVOLmax foram 0,70 com T_i , -0,46 com U_{Ri} , 0,67 com TBU_i , 0,69 com TGN_i e 0,58 com TPO_i (Tabela 8). De forma geral, estas variáveis meteorológicas do ambiente interno apresentaram correlações moderadas a altas, por esta razão, todas estas variáveis foram testadas como entradas dos dois modelos.

A escolha do melhor modelo para predizer a TR e FR contou com duas etapas, a primeira que testou conjuntos com diferentes combinações para as variáveis de entrada (primeira etapa) e a segunda que testou os 6 melhores modelos da primeira etapa, 3 para cada variável predita.

Utilizando os resultados da análise estatística descrita anteriormente, foram escolhidas associações de 1 até 5 variáveis meteorológicas com a TIVFRONmed para estimar a FR e 1 até 5 variáveis meteorológicas com TIVOLmax para estimar a TR. No total, na primeira etapa de testes foram desenvolvidos 62 modelos (31 modelos para a FR e 31 para a TR) fixando-se 30 neurônios na camada escondida. A tabela com esta primeira etapa de avaliação preliminar dos modelos pode ser vista no APÊNDICE B.

Após a primeira etapa, foram escolhidos os 6 melhores modelos para participarem de uma segunda etapa de avaliação dos modelos de predição de FR e TR pela análise do coeficiente de correlação da análise de regressão e do RMSE entre os valores reais e os preditos (variáveis dependentes). Em caso de empate entre dois modelos, o terceiro critério observado foi a inclinação e o intercepto da equação de regressão entre os valores reais e os preditos. Na segunda etapa de avaliação, os 6 modelos escolhidos foram submetidos a novos testes, com 7, 15, 30, 60 e 90 neurônios na camada escondida (Tabela 9).

Tabela 9. Modelos computacionais, baseados em rede neural artificial (RNA) que foram testados na segunda etapa de testes.

Modelos	Neurônios	R Teste	Inclinação	Intercepto	Erro médio	RMSE	R ²
Modelos computacionais testados para estimar a FR							
TIVFRONmed-Ti-URi	7	0,86	0,73	13,73	8,28	10,41	0,74
	15	0,87	0,70	15,42	8,45	10,73	0,76
	30	0,86	0,77	12,12	8,00	10,01	0,74
	60	0,85	0,71	14,83	8,71	11,15	0,73
	90	0,85	0,73	15,13	8,54	10,99	0,73
TIVFRONmed-Ti-URi-TBUi	7	0,87	0,71	15,62	8,06	10,18	0,76
	15	0,87	0,64	18,01	9,18	11,54	0,76
	30	0,87	0,72	15,68	8,42	10,50	0,75
	60	0,85	0,71	14,52	8,60	11,18	0,73
	90	0,86	0,75	12,15	8,68	10,94	0,74
TIVFRONmed-Ti-URi-TPOi	7	0,85	0,73	14,32	8,10	10,33	0,73
	15	0,86	0,72	14,89	8,63	10,86	0,74
	30	0,86	0,74	13,95	8,37	10,41	0,75
	60	0,86	0,75	13,50	8,06	10,29	0,74
	90	0,86	0,74	13,57	8,52	10,72	0,74

continua

conclusão

Tabela 9. Modelos computacionais, baseados em rede neural artificial (RNA) que foram testados na segunda etapa de testes.

Modelos computacionais testados para estimar a TR							
TIVOLmax-Ti- URi-TPOi	7	0,84	0,72	10,85	0,31	0,40	0,70
	15	0,83	0,69	11,93	0,32	0,42	0,69
	30	0,84	0,77	8,68	0,31	0,40	0,71
	60	0,84	0,72	10,81	0,32	0,42	0,70
	90	0,85	0,70	11,75	0,32	0,42	0,72
TIVOLmax-URi- TBUi-TGNi-TPOi	7	0,84	0,68	12,37	0,30	0,39	0,70
	15	0,84	0,76	9,38	0,31	0,39	0,71
	30	0,85	0,73	10,33	0,29	0,38	0,72
	60	0,83	0,72	10,80	0,31	0,41	0,69
	90	0,84	0,74	10,12	0,33	0,42	0,70
TIVOLmax-Ti- URi-TBUi-TGNi- TPOi	7	0,84	13,72	0,65	0,31	0,40	0,70
	15	0,84	0,69	12,13	0,33	0,43	0,70
	30	0,85	0,75	9,60	0,30	0,38	0,73
	60	0,84	0,69	11,97	0,32	0,41	0,69
	90	0,84	0,72	10,75	0,31	0,40	0,71

Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; TIVFRONmed: temperatura média de superfície da fronte dos animais obtidas com técnica de termografia e infravermelho; TIVOLmax: temperatura máxima de superfície da área ocular dos animais

Dados registrados com *data loggers* instalados no free-stall: temperatura de bulbo seco(Ti); umidade relativa do ar (URi); temperatura de ponto de orvalho (TPOi); temperatura de globo negro (TGNi).

Parâmetros obtidos da equação de regressão na fase de teste da rede neural artificial: coeficiente de correlação de person (R); raiz do erro quadrático médio (RMSE); Coeficiente de determinação (R²).

Após a segunda etapa de testes (Tabela 11), foram selecionados os melhores modelos computacionais baseados em RNA, um para a predição da FR (RNA-FR) e outro para predição da TR (RNA-TR). Além da alta correlação entre os dados reais e os estimados e o RMSE, outro critério de escolha dos melhores modelos foi considerar aqueles com o menor número de variáveis de entrada e a facilidade de obtenção destes dados para uma possível automatização destes modelos futuramente. Dessa forma, as melhores arquiteturas de RNA contaram como entradas as variáveis Ti, URi e TIVFRONmed para o RNA-FR e as entradas Ti, URi, TPOi e TIVOLmax para o RNA-TR, ambos com 30 neurônios na camada escondida. A correlação obtida entre os dados reais de FR e TR e os preditos pelos modelos RNA-FR e RNA-TR na fase de teste foi 0,86 e 0,84, respectivamente (Tabela 13).

Também foram realizadas análises de regressão linear para gerar modelos de predição para a FR (REG-FR) e a TR (REG-TR) (Tabela 12), sendo que estes modelos foram utilizados em método de comparação com resultados obtidos dos modelos RNA. As correlações obtidas nas equações REG-FR e REG-TR foram 0,83 e 0,74, respectivamente (Tabela 10). O procedimento utilizado nessa regressão foi o método *Stepwise* (SAS® 9.4), onde usou-se o

critério de $p < 0,15$ para a variável entrar no modelo e $p < 0,20$ para manter a variável no modelo. No caso do modelo REG-FR, de acordo com estes critérios, as variáveis selecionadas para essa equação foram as mesmas variáveis utilizadas pelo RNA-FR. Por outro lado, diferente do que aconteceu com RNA-TR, a melhor equação de regressão para a REG-TR retirou a variável TPOi do modelo.

Brown-brandl; Jones; Woldt (2005) desenvolveram, entre outros modelos, um que utilizou regressão linear para estimar a FR. A equação representou 60,4% da variação total dos dados e contou como variáveis independentes a temperatura do ar, temperatura de ponto de orvalho, radiação solar e velocidade do vento. Todas as variáveis, com exceção da temperatura de ponto de orvalho foram significativas, como aconteceu no presente estudo para a REG-TR.

O ponto de orvalho oferece uma relação entre temperatura, umidade e pressão do ar e pode ser utilizado para indicar a situação de conforto térmico sentida pelos animais. Os modelos desenvolvidos para estimar a FR neste estudo contaram como entradas as variáveis T_i , UR_i e TIVFRONmed e esta associação entre variável climática e fisiológica pode ter sido suficiente para que os modelos encontrassem o efeito na FR sem que a TPOi contribuísse de forma significativa nesta resposta. Por outro lado, a TPOi foi importante na construção do modelo RNA-TR e esteve presente em todos os modelos escolhidos para a segunda etapa de testes, demonstrando que a RNA encontrou uma relação importante entre TPOi e TR.

Tabela 10. Equações de regressão linear desenvolvidas para estimar frequência respiratória (REG-FR) baseada na temperatura de bulbo seco (T_i), umidade relativa do ar (UR_i) e temperatura média de superfície da fronte das vacas (TIVFRONmed) e para estimar a temperatura retal (REG-TR) baseada na temperatura de bulbo seco (T_i), umidade relativa do ar (UR_i) e temperatura máxima da área ocular (TIVOLmax).

Modelo	Variáveis	Parâmetro do modelo	R ² parcial	R ²
REG-FR	Intercepto	-34,71	-	-
	T_i	3,14	0,59	0,59
	UR_i	0,36	0,04	0,63
	TIVFRONmed	-0,35	0,00	0,63
REG-TR	Intercepto	30,21	-	-
	T_i	0,07	0,46	0,46
	UR_i	0,01	0,02	0,51
	TIVOLmax	0,17	0,46	0,46

Coeficiente de determinação (R^2).

Os demais parâmetros estatísticos da equação de regressão entre os resultados reais e os estimados pelos modelos RNA e REG podem ser vistos na Tabela 11 e nas Figuras 21 a 24. O RMSE apresentou valores mais baixos nos modelos RNA quando comparados com os modelos REG. Os valores de inclinação também estiveram melhores para os modelos RNA.

Tabela 11. Comparação entre os parâmetros estatísticos das equações de regressão obtidas entre os dados reais e os estimados pelos melhores modelos (RNA-FR e RNA-TR) e os obtidos das equações de regressão entre os dados reais e os estimados pelos modelos estatísticos (REG-FR e REG-TR).

Parâmetros	RNA-FR	REG-FR	RNA-TR	REG-TR
Inclinação	0,77	0,73	0,77	0,53
Intercepto	12,12	14,17	8,68	18,18
Erro médio	8,00	8,82	0,31	0,38
RMSE	10,01	11,04	0,40	0,49
R ²	0,74	0,69	0,71	0,55

Modelos baseados em equações de regressão: para estimar a FR (REG-FR); para estimar a TR (REG-TR);
 Modelo baseados em redes neurais artificiais: para estimar a FR (RNA-FR); para estimar a TR (RNA-TR);
 Coeficiente de determinação (R²); raiz do erro quadrático médio (RMSE).

Figura 21. Correlação entre os dados de frequência respiratória (FR) medidos e os estimados pelo RNA-FR.

Frequência respiratória (FR).

Figura 22. Correlação entre os dados de frequência respiratória (FR) medidos e os estimados pelo REG-FR.

Frequência respiratória (FR).

Figura 23. Correlação entre os dados de temperatura retal (TR) medidos e os estimados pelo RNA-TR.

Temperatura retal (TR).

Figura 24. Correlação entre os dados de temperatura retal (TR) medidos e os estimados pelo REG-TR.

Temperatura retal (TR).

Sousa et al. (2018) desenvolveram um modelo computacional, baseado em RNA, para a predição da TR de bovinos Nelore a partir da TIV da fronte, temperatura de bulbo seco e temperatura de bulbo úmido. Os autores observaram coeficiente de correlação entre os dados preditos pelo modelo e os dados reais de 0,85, próximo ao encontrado no presente estudo, que foi de 0,84. Pequenas variações nos resultados de correlação podem acontecer, para mais ou para menos, em cada treinamento da RNA mesmo que sejam considerados o mesmo conjunto de dados pois, em cada iteração, a RNA pode escolher novos dados para treinamento, validação e teste. Por outro lado, a inclinação da reta da equação de regressão e o RMSE encontrados pelos autores foram de 0,88 e 0,28, respectivamente, valores melhores que os encontrados no presente estudo que foi de 0,77 (inclinação) e 0,40 (RMSE).

O valor mais próximo da inclinação ideal (1) e o menor RMSE encontrados por Sousa et al. (2018) podem ser reflexo do grupo de dados analisados que contou com animais mais uniformes (mesma idade e grupo genético com desempenho semelhante) na unidade experimental, diferente do que aconteceu no presente estudo em que foram avaliadas vacas em diferentes estágios de parição e lactação, que podem apresentar diferentes respostas termorregulatórias. Mesmo submetidos às mesmas condições ambientais a resposta dos animais são bastante variadas. Características como raça, cor de pele, espessura ou tipo do pelo, quantidade de cobertura de gordura e temperamento pode influenciar na resposta do animal ao estresse térmico (BROWN-BRANDL e JONES, 2016). Estas variações também influenciam na captação da TIV pela câmera termográfica e consequentemente nos dados de TIV que são inseridos nos modelos. Dessa forma, podem ter sido responsáveis pelas diferenças de resultados para predição de TR entre o presente estudo e Sousa et al. (2018).

Os valores de correlação encontrado por Sousa et al. (2018) entre a temperatura da fronte com a temperatura de bulbo seco, a temperatura de bulbo úmido e a TR foram, respectivamente 0,97, 0,86 e 0,79. Já no presente estudo, as correlações entre TIVFRONmed com T_i , U_{Ri} e TR foram, 0,92, -0,73 e 0,55. As correlações entre as variáveis meteorológicas e a TIV no trabalho de Sousa et al. (2018) foram maiores que as encontradas no presente estudo o que pode ter favorecido os modelos desenvolvidos pelos autores a encontrarem melhores associações entre as variáveis para estimar a TR.

Hernández-Julio et al. (2014) estudaram a modelos de regressão linear, RNA e neurofuzzy para prever a FR e a TR de vacas Holandesas, múltiparas, em diferentes estágios de lactação. Como entradas para os três modelos, utilizaram a temperatura e a umidade relativa do ar. A correlação entre os dados reais de TR e os preditos pelo modelo de regressão, RNA e neurofuzzy foram, respectivamente, 0,68, 0,89 e 0,70. As correlações entre os dados reais de FR e os mesmos modelos foram, 0,63, 0,93 e 0,67, respectivamente. Os autores observaram que os modelos baseados em RNAs foram melhores estimadores que os demais. O estudo desenvolvido contou com dados obtidos de diferentes experimentos, conduzidos em um período de 6 anos, totalizando 5884 dados experimentais. Um banco de dados maior provavelmente contribuiu para a aprendizagem da RNA, refletindo no melhor desempenho dos modelos desenvolvidos pelos autores em comparação com os do presente estudo.

No presente estudo quando foram utilizadas como entradas apenas os dados meteorológicos, os valores de correlações obtidos foram inferiores aos modelos que utilizaram, além destes dados, a TIV. A combinação desta variável com um banco de dados maior pode ser positiva para a obtenção de modelos mais eficazes, além disso, a associar a TIV com dados

meteorológicos tem a vantagem considerar um parâmetro fisiológico, o que favorece a individualização da resposta do animal. Um modelo que utiliza apenas variáveis meteorológicas como o desenvolvido por Hernández-Julio et al. (2014), generaliza as respostas para todo o rebanho.

5.2.1 Classificação e avaliação dos modelos

Os valores preditos pelos melhores modelos na etapa de teste foram classificados em 4 níveis (categorias) de estresse térmico (normal, alerta, perigo e emergência), assim como os valores reais de FR e TR, o ITU e o ITGU. Existem as classificações baseadas nas variáveis fisiológicas (FR: referência; TR: referência) e nos índices climáticos (referências para ITU e ITGU), os quais são utilizadas na literatura e que simplificam a interpretação das medições aos produtores sob o ponto de vista de como podem afetar a performance dos animais.

As classificações baseadas nos índices climáticos nem sempre refletem de forma precisa a sensação de conforto térmico dos animais. Por outro lado, apesar das classificações baseadas nas variáveis fisiológicas indicarem de forma mais fiel o estado de conforto térmico dos animais, a obtenção destes dados são dependentes de medidas invasivas ou que demandam tempo para aferição. Assim, classificar as respostas dos modelos RNA-FR e RNA-TR nas mesmas faixas que as variáveis fisiológicas (conforto, alerta, perigo e emergência) e compará-las com as classificações baseadas nos índices climáticos, pode indicar quais métodos mais se aproximam dos resultados baseados nas medidas fisiológicas dos animais. A comparação dos resultados no presente estudo foi feita por meio de matrizes de confusão como outra forma de medir a qualidade dos modelos gerados.

As matrizes de confusão permitem que os resultados entre dois modelos classificadores sejam comparados. Os números indicam a quantidade de dados classificados em cada nível em relação a classificação real e a predita pelo classificador. Por exemplo, na Tabela 14 estão apresentados os dados de classificação em níveis de conforto térmico pela FR (classificações indicadas nas linhas) em comparação com os dados de classificação obtidos com o modelo RNA-FR (classificações indicadas nas colunas). Os resultados da diagonal da matriz indicam quando as classificações coincidiram, ou seja, quanto o classificador baseado em RNA-FR acertou o resultado em relação a classificação baseada nos dados reais de FR. Nas matrizes de confusão, a razão, em porcentagem, entre o valor de uma célula da diagonal pela quantidade total dos dados indica a quantidade de acertos em cada categoria. A acurácia total é obtida somando-se acertos percentuais de cada categoria da diagonal da matriz.

Portanto, as classificações entre os dados reais de FR e os preditos pelo modelo RNA-FR (Tabela 14) evidenciaram acurácia de 83% obtida pelo modelo RNA-FR, sendo que ele classificou 66% dos dados como “Conforto”, 10% como “Alerta” e 6% como “Perigo”. A classe com maior porcentagem de acertos foi a “Conforto”, com 93% de acertos, seguida pela classe “Perigo” (59%) e “Alerta” (58%). A classe “Emergência” não apresentou nenhum acerto.

A sensibilidade, a precisão e a medida F1 são outros parâmetros avaliados nas matrizes de confusão. A sensibilidade indica a porcentagem dados que classificador acertou em cada classe em relação aos dados reais (observada nas linhas). Este valor é a razão entre o valor do acerto pela quantidade total de dados da categoria real. Por exemplo, na Tabela 14 os valores de sensibilidade estão indicados na última coluna. O valor de 93% é o valor, em porcentagem, da razão entre 245 e 263, que é o total de dados encontrados na classificação “Conforto” de acordo com FR. Portanto, o classificador RNA-FR acertou 93% dos valores disponíveis na categoria “Conforto” de acordo com a classificação por FR.

A precisão indica a capacidade do classificador não classificar dados de outras categorias em uma categoria incorreta, ou seja, dos dados classificados em determinada categoria, quantos realmente pertenciam a ela. Na Tabela 15, os valores de precisão estão indicados na última linha e são calculados para cada coluna. A precisão de 94% para a categoria “Conforto” é a razão entre o valor 245 e 260, que é o total da categoria “Conforto” predita., ou seja, dos dados que o classificador RNA-FR classificou como “Conforto”, 94% dos dados realmente estavam nesta categoria.

A distribuição dos acertos entre as classes é um parâmetro importante de ser discutido e que reflete a qualidade das classificações. Por exemplo, um classificador pode ter 100% de acertos como acurácia total, mas esse acerto pode estar concentrado em apenas uma das classes. Em alguns casos, o classificador pode selecionar dados que deveriam ser de outras e classificá-los em apenas uma categoria, assim, a quantidade de exemplos preditos e reais podem ser similares, indicando uma alta acurácia total, mas com classificações incorretas. Com a avaliação da precisão e da sensibilidade, estas distribuições de acertos entre as classes ficam mais evidentes.

O último parâmetro utilizado para avaliar os classificadores foi a medida F1. Seu valor é obtido pela média harmônica da precisão com a sensibilidade e com ele é possível avaliar a qualidade do modelo baseando-se na distribuição das classificações entre as categorias. O valor da medida F1 para o modelo RNA-FR (Tabela 13) foi 52%. Como o classificador baseado em RNA não foi treinado com as categorias separadas, o intuito destas métricas (precisão,

sensibilidade e medida F1) foi auxiliar na comparação entre os classificadores baseados em RNA, ITU e ITGU.

Tabela 12. Matriz de confusão entre os dados estimados pelo modelo RNA-FR e os dados reais de FR, classificados em faixas de estresse térmico segundo a frequência respiratória. Células cinzas indicam as predições corretas em cada classe.

Real - FR	Predita – RNA-FR				Sensibilidade
	Conforto	Alerta	Perigo	Emergência	
Conforto	245	17	1	0	0,93
Alerta	15	38	13	0	0,58
Perigo	0	16	24	1	0,59
Emergência	0	0	0	0	0,00
Precisão	0,94	0,54	0,63	0,00	0,83

Tabela 13. Avaliação do desempenho do modelo computacional baseado em rede neural artificial (RNA) desenvolvido para predição de frequência respiratória (FR).

Classe FR	Conforto	Alerta	Perigo	Emergência	Média
Precisão	0,94	0,54	0,63	0,00	0,53
Sensibilidade	0,93	0,58	0,59	0,00	0,52
Medida F1	0,93	0,56	0,60	0,00	0,52

Quando foram comparadas as classificações entre os dados reais de FR e as classificações obtidas com o ITU (Tabela 14) a acurácia total foi de 50%, sendo que os acertos foram distribuídos em 45% na classe “Conforto”, 4% na “Alerta” e menos de 1% na “Perigo”. Da mesma forma que aconteceu com a classificação por RNA-FR, a classe com maior porcentagem de acertos foi a “Conforto”, com 64%, seguida pela “Alerta” com 24% de acertos. Apesar disso, tanto estes resultados nas classes quanto a acurácia total do ITU (50%) foi menor que a encontrada para RNA-FR, que foi de 83%.

Em relação a medida F1 (Tabela 15), o valor encontrado para o classificador baseado em ITU foi 25%, abaixo da medida F1 obtida para o classificador RNA-FR.

Tabela 14. Matriz de confusão entre os dados reais de FR classificados em faixas de estresse térmico segundo a frequência respiratória (Real – FR) e a classificação obtida com o Índice de Temperatura e Umidade (Predita-ITU). Células cinzas indicam as predições corretas em cada classe.

Real – FR	Predita - ITU				Sensibilidade
	Conforto	Alerta	Perigo	Emergência	
Conforto	168	65	20	10	0,64
Alerta	1	16	9	40	0,24
Perigo	0	0	1	40	0,02
Emergência	0	0	0	0	0,00
Precisão	0,99	0,20	0,03	0,00	0,50

Tabela 15. Avaliação do desempenho do modelo computacional baseado no Índice de Temperatura e Umidade (ITU) desenvolvido para estimar a frequência respiratória (FR).

Classe FR	Conforto	Alerta	Perigo	Emergência	Média
Precisão	0,99	0,20	0,03	0,00	0,31
Sensibilidade	0,64	0,24	0,02	0,00	0,22
Medida F1	0,77	0,21	0,02	0,00	0,25

A Tabela 16 demonstra a classificação entre os dados reais de FR e os dados estimados pelo ITGU. A acurácia total obtida entre as classificações foi de 68%, maior que a obtida com o ITU (50%) e menor que a obtida com a RNA-FR. O ITGU classificou 63% dos dados como “Conforto”, 2% como “Alerta” e 3% como “Perigo”. Da mesma forma que as classificações feitas com o ITU e o RNA-FR, a maior porcentagem de acertos aconteceu para a classe “Conforto” (89%), seguida pela classe “Perigo” (24%) .

Esta maior porcentagem de acertos obtidas na classe “Conforto” para todos os classificadores, pode estar relacionada com a maior quantidade de dados (exemplos) obtidos nesta classe, o que aumenta a possibilidade de acertos em comparação às classes com poucos dados. Em relação à medida F1 (Tabela 17), o valor encontrado para o classificador baseado em ITGU foi 32%, abaixo do RNA-FR;

O classificador que mais se aproximou da classificações reais de FR em termos de acurácia total foi o RNA-FR (86%), seguido pela classificação baseada em ITGU (68%) e depois ITU (50%). Em termos de medida F1 os melhores classificadores mantiveram esta sequência, RNA-FR (0,52), ITGU (0,32) e ITU (0,25).

Tabela 16. Matriz de confusão entre os dados reais de FR classificados em faixas de estresse térmico segundo a frequência respiratória (Real - FR) e a classificação obtida com o Índice de Temperatura de Globo Negro e Umidade (Predita – ITGU). Células cinzas indicam as predições corretas em cada classe.

Real - FR	Predita - ITGU				Sensibilidade
	Conforto	Alerta	Perigo	Emergência	
Conforto	230	17	9	1	0,89
Alerta	27	6	22	11	0,09
Perigo	2	0	10	29	0,24
Emergência	0	0	0	0	0,00
Precisão	0,89	0,26	0,24	0,00	0,68

Tabela 17. Avaliação do desempenho do modelo computacional baseado no Índice de Temperatura de Globo Negro e Umidade (ITGU) desenvolvido para estimar a frequência respiratória (FR).

Classe FR	Conforto	Alerta	Perigo	Emergência	Média
Precisão	0,89	0,26	0,24	0,00	0,34
Sensibilidade	0,89	0,09	0,24	0,00	0,30
Medida F1	0,89	0,13	0,24	0,00	0,32

O classificador baseado em RNA-TR também foi avaliado por meio de uma matriz de confusão entre suas classificações e as obtidas com os dados reais de TR (Tabela 18). A acurácia total obtida foi de 84% com acertos distribuídos 77% na classe Conforto”, 2% na “Alerta”, 5% na “Perigo” e menos de 1% na classe “Emergência”. O maior acerto obtido pelo RNA-TR foi na classe “Conforto” (96%), seguido pela classe “Alerta” (41%) e “Perigo” (13%).

Apesar da acurácia total do RNA-TR (84%) ter sido um pouco maior que a do RNA-FR (83%), quando foi obtida a medida F1 (Tabela 19) o desempenho do modelo RNA-TR foi de 42%, menor que o RNA-FR que apresentou valor de 52%, o que indica que as classificações entre os níveis de conforto térmico do RNA-TR foram menos eficientes que as encontradas para o RNA-FR. As melhores distribuições de acerto encontradas para RNA-FR pode ser reflexo da FR ser uma resposta mais associada às mudanças na temperatura de superfície corporal e as variações meteorológicas do que a TR (conforme observado pelos maiores valores de correlação de Pearson entre as variáveis meteorológicas e a FR em comparação com a TR), o que pode ter influenciado nos resultados encontrados por este classificador.

Tabela 18. Matriz de confusão entre os dados estimados pelo modelo RNA-TR e os dados reais de TR, classificados em faixas de estresse térmico segundo a frequência respiratória. Células cinzas indicam as predições corretas em cada classe.

Real – TR	Predita – RNA-TR				Sensibilidade
	Conforto	Alerta	Perigo	Emergência	
Conforto	284	11	1	0	0,96
Alerta	12	8	9	0	0,41
Perigo	5	12	18	3	0,13
Emergência	0	0	6	1	0,00
Precisão	0,94	0,26	0,53	0,25	0,84

Tabela 19. Avaliação do desempenho do modelo computacional baseado em rede neural artificial (RNA) desenvolvido para estimar a temperatura retal (TR).

Classe TR	Conforto	Alerta	Perigo	Emergência	Média
Precisão	0,94	0,26	0,53	0,25	0,49
Sensibilidade	0,96	0,41	0,13	0,00	0,37
Medida F1	0,95	0,32	0,21	0,00	0,42

Os dados reais de TR, quando comparados com a classificação obtida pelo ITU (Tabela 20) demonstram acurácia total de 44%, sendo 39% na classe Conforto”, 13% na “Alerta”, 1% na classe “Perigo” e 2% na “Emergência”. Os acertos nas classes foram, 49% para “Conforto”, 17% para “Alerta”, menos de 1% para “Perigo” e 1% para “Emergência”.

A medida F1 entre os resultados do classificador baseado em ITU e as classificações reais de TR (Tabela 21) foi de 35%. Da mesma forma que aconteceu com as classificações comparadas com FR, o ITU demonstrou menor capacidade de predição da TR quando comparado com a classificação por RNA-TR. Quando observada apenas as classificações com o ITU, o índice foi melhor para prever a TR que a FR.

Tabela 20. Matriz de confusão entre os dados reais de TR classificados em faixas de estresse térmico segundo a frequência respiratória (Real – TR) e a classificação obtida com o Índice de Temperatura e Umidade (Predita-ITU). Células cinzas indicam as predições corretas em cada classe.

Real - TR	Predita - ITU				Sensibilidade
	Conforto	Alerta	Perigo	Emergência	
Conforto	146	87	29	34	0,49
Alerta	1	5	5	18	0,17
Perigo	0	2	3	33	0,08
Emergência	0	0	0	7	1,00
Precisão	0,99	0,05	0,08	0,08	0,44

Tabela 21. Avaliação do desempenho do modelo computacional baseado no Índice de Temperatura e Umidade (ITU) desenvolvido para estimar a temperatura retal (TR).

Classe TR	Conforto	Alerta	Perigo	Emergência	Média
Precisão	0,99	0,05	0,08	0,08	0,30
Sensibilidade	0,49	0,17	0,08	1,00	0,43
Medida F1	0,65	0,00	0,08	0,15	0,35

O ITGU também apresentou melhor acurácia (69%) que o ITU, quando comparado com a classificação real de TR (Tabela 22). Os acertos foram divididos em 63% para “Conforto”, 5% como “Perigo” e menos de 1% em “Emergência”. E os acertos, quando observados por classes foram maiores para a classe “Conforto” (79%), seguida pela classe “Perigo” (50%) e “Emergência” (43%). O valor da medida F1 comparando os resultados do classificador ITGU e as categorias reais de TR (Tabela 23) foi 39%, próximo ao valor encontrado para o classificador ITU (35%) e menor que o valor de F1 encontrado para o RNA-TR (42%).

No geral, em termos de acurácias totais, as melhores classificações para níveis de conforto térmicos quando comparados com as classificações de TR reais foram, em ordem, RNA-TR (84%), ITGU (69%) e ITU (44%). Apesar disso, quando avaliada a medida F1, os valores encontrados estiveram mais próximos, sendo 42% (RNA-TR), 39% (ITGU) e 35% (ITU).

Tabela 22. Matriz de confusão entre os dados reais de TR classificados em faixas de estresse térmico segundo a frequência respiratória (Real - TR) e a classificação obtida com o Índice de Temperatura de Globo Negro e Umidade (Predita – ITGU). Células cinzas indicam predições corretas em cada classe.

Real – TR	Predita - ITGU				Sensibilidade
	Conforto	Alerta	Perigo	Emergência	
Conforto	232	28	13	21	0,79
Alerta	12	0	7	10	0,00
Perigo	6	1	19	12	0,50
Emergência	0	0	4	3	0,43
Precisão	0,93	0,00	0,44	0,07	0.69

Tabela 23. Avaliação do desempenho do modelo computacional baseado no Índice de Temperatura de Globo Negro e Umidade (ITGU) desenvolvido para estimar a temperatura retal (TR).

Classe TR	Conforto	Alerta	Perigo	Emergência	Média
Precisão	0,93	0,00	0,44	0,07	0,36
Sensibilidade	0,79	0,00	0,50	0,43	0,43
Medida F1	0,85	0,00	0,47	0,12	0,39

As acurácias totais obtidas pelos dois modelos desenvolvidos, RNA-FR (83%) e RNA-TR (84%) foram superiores às acurácias obtidas com os índices climáticos e, entre o ITU e o ITGU, o segundo índice demonstrou melhor capacidade de prever o conforto térmico entre as classes de FR e TR. Se um produtor tivesse a intenção de emitir alertas baseados em classes de estresse térmico para modificar o manejo ao enfrentar condições climáticas estressoras, os modelos baseados em RNA, em termos de acurácia total, seriam mais eficientes para evitar perdas em produtividade e gastos desnecessários. Além disso, por considerarem a TIV como uma das variáveis de entrada, estes modelos individualizam a resposta dos animais os quais poderiam ser remanejados de acordo com sua capacidade de reação às condições térmicas.

Quando considerados os acertos conforme a distribuição entre as classes, observando os valores da medida F1, a RNA-FR seria melhor para estimar a FR, seguida pelo ITGU e o ITU. O mesmo aconteceu para a RNA-TR, que foi melhor para estimar a TR seguida pelo ITGU e ITU. Como mencionado anteriormente, a menor quantidade de dados nas classes pode ter influenciado os resultados de acertos obtidos em cada uma das classes e também a aprendizagem dos modelos baseados em RNA. Um banco de dados maior e com mais exemplos em cada classe, pode contribuir para a aprendizagem da RNA, melhorando a acurácia total e a medida F1.

5.3 Rede Neural Convolucional

Os modelos baseados em CNN foram desenvolvidos de forma diferente dos modelos baseados em RNA. A primeira diferença foi a escolha dos dados de entrada. Nos modelos baseados em RNA foram utilizadas variáveis meteorológicas e a TIV. No caso dos modelos CNN a construção foi feita diretamente com imagens térmicas pois a CNN permite a inserção de dados mais complexos, como é o caso das imagens. Outra diferença em relação às RNAs é que a construção destes modelos é comumente feita de forma que a resposta na saída seja classificada em alguma categoria pré-definida, ou seja, estes modelos são originalmente classificadores e não preditores de um valor.

A intenção de estudar modelos como estes foi explorar o potencial dessa ferramenta da aprendizagem profunda e da visão computacional que pode auxiliar na interpretação de imagens de forma automática e rápida. No caso das imagens térmicas uma ferramenta como esta poderia substituir as análises comumente analisadas por operadores treinados. No presente estudo, as imagens térmicas foram submetidas aos modelos classificadores que deveriam classificá-las em categorias de FR e TR (Tabela 4). As categorias de FR e TR escolhidas foram determinadas de forma que a quantidade de imagens térmicas em cada uma delas estivesse o mais equilibrada

possível pois, como os modelos CNN aprendem com estas categorias, classes com quantidades muito superiores que as outras podem induzir o modelo a classificar a maioria das imagens nesta classe.

Como foram registradas imagens térmicas de diferentes regiões corporais, a escolha das imagens que deveriam ser utilizadas nos modelos CNN foi feita baseando-se na análise estatística. Dessa forma, a frente e a área ocular foram as regiões escolhidas para participarem dos modelos computacionais baseados em CNN. Apesar da frente ter apresentado melhor correlação com a FR e a área ocular com a TR, as duas regiões foram testadas como entradas dos modelos para a FR e TR, separadamente, pois este tipo de modelo permite que apenas uma entrada seja inserida. A CNN considera as cores e os contornos para encontrar padrões nas imagens e baseando-se nisso, o intuito de testar as duas regiões foi verificar se alguma delas favoreceria a aprendizagem dos classificadores.

5.3.1 Classificação e avaliação dos modelos construídos com as imagens da região da frente

O modelo construído a partir das imagens da frente para predição de FR (Tabela 24), apresentou classificações com acurácia de 76% e os acertos foram distribuídos em 27% para a classe ≥ 40 mov/min, 24% para 41 – 60 mov/min e 26% para a ≥ 61 mov/min. A acurácia do modelo para predição de TR (Tabela 25) foi de 71% e os acertos distribuídos em 28% na classe $\geq 38,4^{\circ}\text{C}$, 21% na 38,5 – 39,0 $^{\circ}\text{C}$ e 22% na $\geq 39,1$ $^{\circ}\text{C}$.

Ao analisar os outros parâmetros de desempenho dos modelos (Tabela 26), para a predição de FR tanto a precisão, quanto a sensibilidade e medida F1 apresentaram valores de 77%, e para a predição de TR, 71%, valores próximos as acurácias dos modelos. Estes resultados indicam que, mesmo com classes desbalanceadas (diferentes quantidades de exemplos em cada categoria), os classificadores conseguiram estimar de forma eficiente as variáveis fisiológicas, quando os dados foram submetidos aos modelos nas etapas de testes.

Tabela 24. Matriz de confusão entre os dados estimados pelo modelo baseado em CNN e os dados reais de FR, classificados em faixas de estresse térmico segundo a frequência respiratória. Células cinzas indicam as predições corretas em cada classe.

Real – FR (mov/min)	Predita – FR (mov/min)			Sensibilidade
	≤ 40	41 - 60	≥ 61	
≤ 40	496	136	18	0,74
41 - 60	117	438	82	0,66
≥ 61	7	77	477	0,93
Precisão	0,80	0,67	0,83	0,76

Tabela 25. Matriz de confusão entre os dados estimados pelo modelo baseado em CNN e os dados reais de temperatura retal (TR), classificados em faixas de estresse térmico segundo a temperatura retal. Células cinzas indicam as predições corretas em cada classe.

Real – TR (°C)	Predita – TR (°C)			Sensibilidade
	≤ 38,4	38,5 – 39,0	≥ 39,1	
≤ 38,4	514	132	28	0,76
38,5 – 39,0	188	385	91	0,58
≥ 39,1	38	69	406	0,79
Precisão	0,69	0,66	0,77	0,71

Tabela 26. Avaliação do desempenho dos modelos computacionais desenvolvidos para predição de frequência respiratória (FR) e temperatura retal (TR) a partir de imagens térmicas da frente.

Classe FR (mov/min)	≤ 40	41 - 60	≥ 61	Média
Precisão	0,80	0,67	0,83	0,77
Sensibilidade	0,76	0,69	0,85	0,77
Medida F1	0,78	0,68	0,84	0,77
Classe TR (°C)	≤ 38,4	38,5 - 39,0	≥ 39,1	Média
Precisão	0,69	0,66	0,77	0,71
Sensibilidade	0,76	0,58	0,79	0,71
Medida F1	0,73	0,62	0,78	0,71

5.3.2 Classificação e avaliação dos modelos construídos com as imagens da área ocular

A matriz de confusão representativa do modelo para a predição de FR a partir das imagens da área ocular (Tabela 27) apresentou classificações com acurácia de 64%. Os acertos foram distribuídos em 24% para a classe ≤ 40 mov/min, 17% para 41 – 60 mov/min e 22% para ≥ 61 mov/min. A acurácia do modelo para predição de TR (Tabela 28) foi de 0,60 e os acertos distribuídos em 27% na classe $\leq 38,4^{\circ}\text{C}$, 17% na 38,5 – 39,0 $^{\circ}\text{C}$ e 22% na $\geq 39,1^{\circ}\text{C}$.

As demais métricas calculadas para avaliação do desempenho dos modelos (Tabela 29) registraram valores de 65% para precisão, 65% para sensibilidade e 65% para medida F1 e quando o classificador estimou a FR e valores de 60%, 61% e 60% quando estimou a TR. O desbalanceamento das classes também não foi um problema para os modelos que utilizaram como entrada as imagens da área ocular pois os valores obtidos com a Medida F1 ficaram próximos ao valores de acurácias calculados para os modelos.

Tabela 27. Matriz de confusão entre os dados estimados pelo modelo baseado em CNN e os dados reais de FR, classificados em faixas de estresse térmico segundo a frequência respiratória. Células cinzas indicam as predições corretas em cada classe.

Real – FR (mov/min)	Predita – FR (mov/min)			Sensibilidade
	≤ 40	41 - 60	≥ 61	
≤ 40	449	171	29	0,67
41 - 60	210	325	103	0,49
≥ 61	24	128	409	0,80
Precisão	0,66	0,52	0,76	0,64

Tabela 28. Matriz de confusão entre os dados estimados pelo modelo baseado em CNN e os dados reais de FR, classificados em faixas de estresse térmico segundo a temperatura retal. Células cinzas indicam as predições corretas em cada classe.

Real – TR ($^{\circ}\text{C}$)	Predita – TR ($^{\circ}\text{C}$)			Sensibilidade
	$\leq 38,4$	38,5 - 39,0	$\geq 39,1$	
$\leq 38,4$	492	141	40	0,73
38,5 – 39,0	299	238	128	0,36
$\geq 39,1$	56	75	382	0,74
Precisão	0,58	0,52	0,69	0,60

Tabela 29. Avaliação do desempenho dos modelos computacionais desenvolvidos para predição de frequência respiratória (FR) e temperatura retal (TR) a partir de imagens térmicas da área ocular.

Classe FR (mov/min)	≤ 40	41 - 60	≥ 61	Média ponderada
Precisão	0,66	0,52	0,76	0,65
Sensibilidade	0,67	0,49	0,8	0,65
Medida F1	0,66	0,50	0,78	0,65
Classe TR (°C)	≤ 38,4	38,5 - 39,0	≥ 39,1	Média aritmética
Precisão	0,58	0,52	0,69	0,60
Sensibilidade	0,73	0,36	0,74	0,61
Medida F1	0,65	0,43	0,71	0,60

De modo geral, os modelos classificadores desenvolvidos a partir das imagens térmicas da fronte das vacas apresentaram melhores resultados quando comparados aos desenvolvidos com as imagens térmicas da área ocular. As acurácias máximas encontradas nos modelos baseados em CNN foram 76% (FR) e 71%(TR).

Apesar de diversos autores terem verificado o potencial da TIV como ferramenta não invasiva para monitorar a temperatura de superfície dos animais (BROWN-BRANDL; EIGENBERG; PURSWELL, 2013; CHURCH et al., 2014; SALLES et al., 2016), há um consenso entre os pesquisadores sobre a dificuldade de padronização das metodologias, tanto da utilização dos equipamentos, quanto da melhor região corporal para captação das imagens (CHURCH et al., 2014; SCHAEFER et al., 2004). Fatores meteorológicos e diferenças entre os animais estudados devem ser levados em consideração na calibração dos equipamentos pois influenciam os padrões de radiação detectados pela câmera termográfica (MONTANHOLI et al., 2015).

Church et al. (2014) investigaram a influência da carga solar, a velocidade do vento e da distância entre a câmera e o objeto nas medições de temperatura de infravermelho. Os resultados demonstraram diferença de 0,56 °C ($p < 0,05$) entre os dados de temperatura do olho quando exposto ou não à luz solar direta. Em relação à velocidade do vento, quando as medidas foram feitas sob condições de velocidade de vento baixa (7 km/h) e alta (12 km/h) a redução da temperatura foi de 0,43 °C e 0,78 °C respectivamente ($p < 0,001$). Church et al. (2014) também citaram que a carga solar direta sobre as vacas da raça Holandesa exerce grande influência sobre a temperatura de superfície corporal, indicando, nas partes escuras (pretas), uma diferença de até 15 °C acima em relação às partes claras (brancas).

O trabalho de Church et al. (2014) reforça as dificuldades encontradas na padronização das metodologias e a necessidade de adotar algumas medidas para diminuir as variações no processo de captação e análise das imagens, tais como: captar as imagens com a menor variação possível na distância entre a câmera e o objeto estudado; não fazer medições com luz solar direta incidente sobre o objeto; monitorar a velocidade do vento, a umidade relativa, a temperatura do ar e a umidade de superfície do objeto.

Apesar de todas estas medidas terem sido tomadas no presente estudo, algumas fontes de variação, como luminosidade e velocidade do vento, não foram controladas pois a captação das imagens térmicas foi feita a campo. Ressalta-se que a luminosidade e velocidade do vento foram fontes de variação neste estudo, uma vez que as coletas foram realizadas em diferentes horários (5, 12 e 17 horas) e diferentes períodos sazonais (verão e inverno). Dessa forma, estudar como estas fontes de variação influenciam na qualidade das imagens poderá contribuir ainda mais para melhorar as acurácias destes modelos baseados em CNN.

Além destas fontes de variação, os limites de temperatura do ar são importantes influenciadores das cores nas imagens térmicas que, neste estudo, variou do azul (frio) ao vermelho (quente). Por exemplo, no inverno, a temperatura do ar variou de 4 e 32°C e como inevitavelmente o ambiente é capturado nas imagens dos animais, a escala de cores foi distribuída entre estes valores pois. Por outro lado, no verão, as temperaturas variaram de 17 a 38°C apresentando outras cores características nas imagens térmicas. Assim, a cor de uma temperatura de 20°C no inverno pode ser representada por outra cor no verão. O mesmo pode acontecer com os diferentes horários de coletas.

Para contornar este problema, os limites de temperatura foram fixados no momento da padronização das imagens na formação do banco de dados mas alguns contornos importantes das imagens foram perdidos. Estas variações podem ter influenciado os resultados da CNN, que observa o padrão de cores e contornos como referências para o seu aprendizado.

6. CONCLUSÃO

O estresse térmico em vacas de leite tem sido estudado como um caminho para melhorar a eficiência produtiva e o bem-estar animal. Diversos autores têm verificado o potencial da termografia de infravermelho como ferramenta não-invasiva para monitorar a temperatura de superfície dos animais. Da mesma forma, modelos computacionais têm sido estudados na área animal, com o intuito de melhorar os sistemas de processamento de dados.

Neste estudo, a TIV foi utilizada como ferramenta para monitorar a temperatura de superfície dos animais. Entre as regiões estudadas, as que estiveram melhor correlacionadas com os dados de FR e TR foram a frente e a área ocular. Por esta razão foram as regiões escolhidas para participarem dos modelos computacionais.

Os modelos computacionais foram desenvolvidos para predição de estresse térmico de vacas de leite. De modo geral, observou-se que a RNA foi mais efetiva para estimar as respostas fisiológicas (FR e TR) quando comparada com o modelo estatístico tradicional que utilizou equação de regressão linear. Com relação às classificações em níveis de estresse térmico, quando os classificadores (RNA-FR e RNA-TR) foram comparados com os índices de conforto térmico tradicionais (TU e ITGU), também observou-se um melhor resultado para os classificadores com RNA. Entre os índices climáticos avaliados, o ITGU foi mais representativo da resposta dos animais uma vez que sua acurácia ficou acima da acurácia obtida com ITU.

Ao usar CNN como ferramenta para classificar o estresse térmico, observou-se que ela apresentou acurácias moderadas. No entanto os modelos baseados em CNN demonstraram potencial para identificação de padrões em imagens térmicas e classificação em faixas de estresse térmico. Além disso, este é um estudo pioneiro sobre a utilização da Aprendizagem de Máquina para avaliação e classificação de imagens térmicas. De acordo com a revisão de literatura feita até o momento, não foi encontrado nenhum estudo que submetesse as imagens térmicas a uma avaliação automática como a feita neste trabalho.

Estudos adicionais devem ser feitos para minimizar o efeito do ambiente climático sobre as imagens térmicas, já que afeta diretamente no cálculo da temperatura de superfície corporal e a escala de cores das imagens térmicas. Além disso um banco de dados maior e mais variável sempre pode contribuir para a aprendizagem dos modelos e aumentar a sua capacidade de generalização. Tais medidas podem contribuir para melhorar ainda mais a eficácia dos modelos.

7. REFERÊNCIAS

- ABDUL JABBAR, K. et al. Early and non-intrusive lameness detection in dairy cows using 3-dimensional video. **Biosystems Engineering**, v. 153, p. 63–69, 2017.
- ALLEN, J. D. et al. Effect of core body temperature, time of day, and climate conditions on behavioral patterns of lactating dairy cows experiencing mild to moderate heat stress. **Journal of Dairy Science**, v. 98, n. 1, p. 118–127, 2015.
- BERNABUCCI, U. et al. Effect of summer season on milk protein fractions in Holstein cows. *Journal of Dairy Science*, v. 98, n. 3, p. 1815–1827, 2015. doi:10.3168/jds.2014-8788
- 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, n. 7, p. 5664–5674, 2017.
- BOURAOUI, Rachid et al. The relationship of temperature-humidity index with milk production of dairy cows in a Mediterranean climate. **Animal Research**, [s.l.], v. 51, n. 6, p.479-491, nov. 2002. EDP Sciences. <http://dx.doi.org/10.1051/animres:2002036>.
- BROWN-BRANDL, T. et al. Thermoregulatory responses of feeder cattle.pdf. **Journal of Thermal Biology**, v. 28, n. June 2002, p. 149–157, 2003.
- BROWN-BRANDL, T. M.; EIGENBERG, R. A.; PURSWELL, J. L. Using thermal imaging as a method of investigating thermal thresholds in finishing pigs. **Biosystems Engineering**, v. 114, n. 3, p. 327–333, 2013.
- BROWN-BRANDL, T. M.; JONES, D. D.; WOLDT, W. E. Evaluating modelling techniques for cattle heat stress prediction. **Biosystems Engineering**, v. 91, n. 4, p. 513–524, 2005.
- BROWN-BRANDL, T. M.; JONES, D. D.; Characterizing Feedlot Heifer Response to Environmental Temperature. **Transactions Of The Asabe**, [s.l.], v. 59, n. 2, p.673-680, 21 abr. 2016. American Society of Agricultural and Biological Engineers (ASABE). <http://dx.doi.org/10.13031/trans.59.10855>.
- BUFFINGTON, D. E.; CANTON, G. H.; PITT, D. as Comfort Equation for Dairy Cows. **Trans. ASAE**, v. 24, p. 711–714, 1981.
- CANATA, T. F.; SOUSA, F. V.; MARTELLO, L.S., Classificador baseado em lógica fuzzy para avaliação de conforto de bovinos de corte utilizando a termografia de infravermelho, Congresso Brasileiro de Agricultura de Precisão – ConBAP, 14 a 17 de setembro de 2014, São Pedro - SP, Brasil, 2014.
- CHURCH, J. S. et al. Influence of environmental factors on infrared eye temperature measurements in cattle. **Research in Veterinary Science**, v. 96, n. 1, p. 220–226, 2014.
- DE ANDRADE FERRAZZA, R. et al. Thermoregulatory responses of Holstein cows exposed to experimentally induced heat stress. **Journal of Thermal Biology**, v. 66, n. September 2016, p. 68–80, 2017.

DE SOUSA, R. V. DE et al. Development and evaluation of a fuzzy logic classifier for assessing beef cattle thermal stress using weather and physiological variables. **Computers and Electronics in Agriculture**, v. 127, p. 176–183, 2016.

DIKMEN, S., HANSEN, P. J. Is the temperature-humidity index the best indicator of heat stress in lactating dairy cows in a subtropical environment? *Journal of Dairy Science*, V. 92, p. 109–116, 2009. <http://doi.org/10.3168/jds.2008-1370>

DING, S. et al. Evolutionary artificial neural networks: A review. **Artificial Intelligence Review**, v. 39, n. 3, p. 251–260, 2013.

DUKES, H. H. *Fisiologia dos animais domésticos*. 11. ed. Rio de Janeiro: Guanabara Koogan, 1996.

GRUS, Joel. **Data Science do Zero**. Rio: Alta Books, 2016. 336 p.

HAHN, G.L.; MADER, T.L. Heat waves in relation on thermoregulation, feeding behavior, and mortality of feedlot cattle. In : *International Livestock 42 Environment Symposium*, 5., Mennnesota, 1997. Proceedings. ST. Joseph: ASAE, 1997. p.125-129.

EIGENBERG, R.A., BROWN-BRANDL, T. M., NIENABER, J. A. Development of a livestock weather safety monitor for feedlot cattle. **Applied Engineering In Agriculture**, Minneapolis, v. 23, n. 5, p.657-660, fev. 2007.

HANSEN, M. F. et al. Towards on-farm pig face recognition using convolutional neural networks. **Computers in Industry**, v. 98, p. 145–152, 2018.

HERNÁNDEZ-JULIO, Y. F. et al. Models for prediction of physiological responses of holstein dairy cows. **Applied Artificial Intelligence**, v. 28, n. 8, p. 766–792, 2014.

HILL, D. L.; WALL, E.. Dairy cattle in a temperate climate: the effects of weather on milk yield and composition depend on management. **Animal**, [s.l.], v. 9, n. 1, p.138-149, 15 out. 2014. Cambridge University Press (CUP). <http://dx.doi.org/10.1017/s1751731114002456>.

HOUSTON, D.M., RADOSTIS, O.M. *Exame clínico e diagnóstico em veterinária*. Rio de Janeiro: Guanabara Koogan, 2002. p. 83-86.

HUANG, Y., et al. vDevelopment of soft computing and applications in agricultural and biological engineering. *Computers and Electronics in Agriculture*, v. 71(2), p. 107–127, 2010. <http://doi.org/10.1016/j.compag.2010.01.00>

JOHNSON, H.D.; VANJONACK, W.J. Effects of environmental and other stressors on blood hormone patterns in lactating animals. *Journal of Dairy Science*, Champaign, v.59, n.9, p.1603-17, 1976

JEELANI, R. et al. Reassessment of temperature-humidity index for measuring heat stress in crossbred dairy cattle of a sub-tropical region. **Journal of Thermal Biology**, v. 82, p. 99–106, 2019.

KADZERE, C. T. et al. Heat stress in lactating dairy cows: A review. **Livestock Production Science**, v. 77, n. 1, p. 59–91, 2002.

KNIZKOVA, I. et al. Applications of Infrared Thermography in Animal Productions. **Anadolu Journal of Agricultural Sciences (Turkey)**, v. 22, n. 3, p. 329–336, 2007.

KRUG, C. et al. Creating a model to detect dairy cattle farms with poor welfare using a national database. **Preventive Veterinary Medicine**, v. 122, n. 3, p. 280–286, 2015.

KVAM, J.; KONGSRO, J. In vivo prediction of intramuscular fat using ultrasound and deep learning. **Computers and Electronics in Agriculture**, v. 142, n. September, p. 521–523, 2017.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 2015.

MARTELLO, L. S. Interação animal-ambiente: efeito do ambiente climático sobre as respostas fisiológicas e produtivas de vacas holandesas em free-stall. **Thesis Ph. D.**, p. 113, 2006.

MARTELLO, L. S. et al. Alternative body sites for heat stress measurement in milking cows under tropical conditions and their relationship to the thermal discomfort of the animals. **International Journal of Biometeorology**, v. 54, n. 6, p. 647–652, 2010.

MARTELLO, L. S. et al. Infrared thermography as a tool to evaluate body surface temperature and its relationship with feed efficiency in *Bos indicus* cattle in tropical conditions. **International Journal of Biometeorology**, v. 60, n. 1, p. 173–181, 2016.

MONTANHOLI, Y. R. et al. Technological, environmental and biological factors: Referent variance values for infrared imaging of the bovine. **Journal of Animal Science and Biotechnology**, v. 6, n. 1, p. 1–16, 2015.

MOURA, D.J.; MAIA, A.P.; VERCELLINO, RA.; MEDEIROS, A.B.L.; SARUBBI, J. GRISKA, P.R. Uso da termografia infravermelha na análise da termorregulação de cavalo em treinamento. *Engenharia Agrícola*, v.31, n.1, p.23-32, 2011.

MOROTA, Gota et al. BIG DATA ANALYTICS AND PRECISION ANIMAL AGRICULTURE SYMPOSIUM: Machine learning and data mining advance predictive big data analysis in precision animal agriculture1. **Journal Of Animal Science**, [s.l.], v. 96, n. 4, p.1540-1550, 16 mar. 2018. Oxford University Press (OUP).
<http://dx.doi.org/10.1093/jas/sky014>.

MISIMI, Ekrem et al. Robust classification approach for segmentation of blood defects in cod fillets based on deep convolutional neural networks and support vector machines and calculation of gripper vectors for robotic processing. **Computers And Electronics In Agriculture**, [s.l.], v. 139, p.138-152, jun. 2017. Elsevier BV.
<http://dx.doi.org/10.1016/j.compag.2017.05.021>.

NCR, 1971. A Guide to Environmental Research on Animals. Natl. Acad. Sci., Washington, DC.

Nääs, I. de A. Princípios de conforto térmico na produção animal. 1 ed. São Paulo: Icone Editora Ltda., 1989, 183p.

PENG, D. et al. Infrared thermography measured body surface temperature and its relationship with rectal temperature in dairy cows under different temperature-humidity indexes. **International Journal of Biometeorology**, v. 63, n. 3, p. 327–336, 2019.

POLSKY, L.; VON KEYSERLINGK, M. A. G. Invited review: Effects of heat stress on dairy cattle welfare. **Journal of Dairy Science**, v. 100, n. 11, p. 8645–8657, 2017.

RODRÍGUEZ ALVAREZ, J. et al. Body condition estimation on cows from depth images using Convolutional Neural Networks. **Computers and Electronics in Agriculture**, v. 155, n. December 2017, p. 12–22, 2018.

SALLES, M. S. V. et al. Mapping the body surface temperature of cattle by infrared thermography. **Journal of Thermal Biology**, v. 62, n. October, p. 63–69, 2016.

SCHAEFER, A. L. et al. Early detection and prediction of infection using infrared thermography 1. 2004.

SCHÜLLER, L. K.; BURFEIND, O.; HEUWIESER, W. Short communication: Comparison of ambient temperature, relative humidity, and temperature-humidity index between on-farm measurements and official meteorological data. **Journal of Dairy Science**, v. 96, n. 12, p. 7731–7738, 2013.

SHEELA, K. G.; DEEPA, S. N. Review on methods to fix number of hidden neurons in neural networks. **Mathematical Problems in Engineering**, v. 2013, 2013.

SILVA, L. A.; PERES, S. M.; BOSCARIOLI, C. Introdução à mineração de dados: com aplicações em R. Rio de Janeiro: Elsevier, 2016.

SOUSA, R. V. DE et al. Predictive model based on artificial neural network for assessing beef cattle thermal stress using weather and physiological variables. **Computers and Electronics in Agriculture**, v. 144, n. August 2017, p. 37–43, 2018.

STELLETTA, C. et al. Thermographic Applications in Veterinary Medicine. **Infrared Thermography**, p. 117–140, 2012.

SVOZIL, D.; KVASNICKA, V.; POSPICHAL, J. Introduction to multi-layer feed-forward neural networks. **Chemometrics and Intelligent Laboratory Systems**, v. 39, n. 1, p. 43–62, 1997.

TAN, C. L.; KNIGHT, Z. A. Regulation of Body Temperature by the Nervous System. **Neuron**, v. 98, n. 1, p. 31–48, 2018.

TITTO, C. G. et al. Effects of an evaporative cooling system on plasma cortisol, IGF-I, and milk production in dairy cows in a tropical environment. **International Journal of Biometeorology**, v. 57, n. 2, p. 299–306, 2013.

THOM, E. C. The discomfort index. *Weatherwise*, 12:57–59, 1959.

VALLETTA, J. J. et al. Applications of machine learning in animal behaviour studies. **Animal Behaviour**, v. 124, p. 203–220, 2017.

YOUSEF, M. K. **Stress physiology in livestock**. Boca Raton: CRC Press, 1985.

ZHENG, C. et al. Automatic recognition of lactating sow postures from depth images by deep learning detector. **Computers and Electronics in Agriculture**, v. 147, n. August 2017, p. 51–63, 2018.

APÊNDICE A – Análise estatística dos dados meteorológicos do ambiente externo.

As variáveis e parâmetros meteorológicos do ambiente externo, foram avaliados considerando o período total (inverno e verão), sendo:

- (1) Temperatura e umidade relativa do ar (Te e URe);
- (2) Temperatura e umidade relativa do ar das 0 às 6 horas (T06 e UR06);
- (3) Temperatura e umidade relativa do ar das 6 às 12 horas (T612 e UR612);
- (4) Temperatura e umidade relativa do ar das 12 às 18 horas (T1218 e UR1218) e;
- (5) Temperatura e umidade relativa do ar das 18 às 0 horas (T180 e UR180).

Além disso, a temperatura e umidade do ar foram avaliadas conforme os períodos, sendo:

- (6) Temperatura e umidade relativa do ar do período 1 (Te-1 e URi-1) e;

Temperatura e umidade relativa do ar do período 2 (Te-2 e UR-2).

De acordo com os dados meteorológicos do ambiente externo (Tabela 6) dos dois períodos, a média da Te apresentou um valor de 21,65 °C e a URe 74,72 %. Já a Te máxima apresentou valor de 38,29 °C e nos horários mais quentes do dia, entre as 12 e 18 horas (T1218), a média foi de 27,56°C. Quando as médias foram observadas por períodos, os valores registrados foram 18,07°C e 26,48°C para Te-1 e Te-2, respectivamente, e 75,53% e 72,94% para UR-1 e UR-2, respectivamente.

Tabela 30. Estatística descritiva dos dados meteorológicos do ambiente externo.

Variável	N	Média	Desvio	Mínimo	Máximo
Te	1882	21,65	4,54	4,76	38,29
URe	1882	74,42	9,95	18,79	100,00
T06	1882	17,40	4,48	4,79	27,27
UR06	1882	91,79	6,45	51,41	100,00
T612	1882	20,06	4,15	4,76	33,26
UR612	1882	81,20	8,05	27,78	100,40
T1218	1882	27,56	5,46	15,01	38,29
UR1218	1882	50,63	16,81	18,79	100,00
T180	1882	21,62	5,30	8,54	38,01
UR180	1882	74,02	14,48	26,71	100,40
Te-1	1080	18,07	1,87	4,76	32,05
URe-1	1080	75,53	11,38	18,79	83,60
Te-2	802	26,48	1,74	17,53	38,29
URe-2	802	72,94	7,35	25,34	100,00

Média da temperatura média do ar (Te); média da temperatura média do ar registrada durante o período das 0 às 6 horas (T06); média da temperatura média do ar registrada durante o período das 6 às 12 horas (T612); média da temperatura média do ar registrada durante o período das 12 às 18 horas (T1218); média da temperatura média do ar registrada durante o período das 18 às 0 horas (T180); média da umidade relativa média do ar registrada durante todos os dias (URe); média da umidade relativa média do ar registrada durante o período das 0 às 6 horas (UR06); média da umidade relativa média do ar registrada durante o período das 6 às 12 horas (UR612); média da umidade relativa média do ar registrada durante o período das 12 às 18 horas (UR1218); média da umidade relativa média do ar registrada durante o período das 18 às 0 horas (UR180); Siglas com o sufixo “-1” representam as médias das variáveis durante o período 1; Siglas com o sufixo “-2” representam as médias das variáveis durante o período 2.

Entre as variáveis climáticas do ambiente externo e as variáveis fisiológicas (Tabela 9), a Temed foi a que apresentou a melhor correlação com a FR e a TR, com valores de 0,75 e 0,69, respectivamente. Da mesma forma, a Temed apresentou melhores correlações com os dados de TIV, variando de 0,51 a 0,59, sendo que a melhor correlação foi com a TIVFRONmin e TIVFRONmed (ambas com 0,59). Quando observadas por horários, a variável que melhor se correlacionou com as variáveis fisiológicas foi a T1218, que variou de 0,48 a 0,68 e corresponde à média de temperatura dos horários mais quentes do dia.

Tabela 31. Coeficiente de correlação de Pearson relacionando variáveis fisiológicas e climáticas registradas do ambiente externo.

Variáveis	Te	URe	T06	UR06	T612	UR612	T1218	UR1218	T180	UR180
FR	0,75	-0,21	0,69	0,02	0,72	0,03	0,68	-0,22	0,73	-0,31
TR	0,69	-0,22	0,62	0,00	0,66	0,05	0,64	-0,24	0,67	-0,31
TIVFRONmin	0,59	-0,14	0,54	0,03	0,57	0,00	0,54	-0,16	0,57	-0,21
TIVFRONmax	0,51	-0,13	0,46	0,03	0,48	0,01	0,47	-0,15	0,50	-0,21
TIVFRONmed	0,59	-0,14	0,54	0,04	0,57	0,01	0,54	-0,16	0,57	-0,22
TIVOLmax	0,58	-0,1	0,55	0,06	0,55	0,07	0,51	-0,12	0,57	-0,21
TIVCOSmin	0,56	-0,09	0,52	0,08	0,54	0,07	0,50	-0,11	0,55	-0,18
TIVCOSmax	0,55	-0,06	0,53	0,08	0,54	0,09	0,49	-0,09	0,53	-0,16
TIVCOSmed	0,57	-0,07	0,54	0,08	0,55	0,08	0,50	-0,09	0,55	-0,16
TIVFLANmin	0,57	-0,08	0,54	0,08	0,57	0,07	0,51	-0,1	0,56	-0,17
TIVFLANmed	0,56	-0,05	0,54	0,09	0,54	0,10	0,49	-0,08	0,54	-0,15
TIVFLANmax	0,55	-0,05	0,53	0,09	0,54	0,11	0,48	-0,07	0,54	-0,15

Frequência respiratória (FR); Temperatura retal (TR); TIVFRONmin: temperatura mínima de superfície da frente dos animais obtidas com técnica de termografia e infravermelho; TIVFRONmax: temperatura máxima de superfície da frente dos animais obtidas com técnica de termografia e infravermelho; TIVFRONmed: temperatura média de superfície da frente dos animais obtidas com técnica de termografia e infravermelho; TIVOLmax: temperatura máxima de superfície da área ocular dos animais obtidas com técnica de termografia e infravermelho. TIVCOSmin: temperatura mínima de superfície da costela dos animais obtidas com técnica de termografia e infravermelho; TIVCOSmax: temperatura máxima de superfície da costela dos animais obtidas com técnica de termografia e infravermelho; TIVCOSmed: temperatura média de superfície da costela dos animais obtidas com técnica de termografia e infravermelho; TIVFLANmin: temperatura mínima de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho; TIVFLANmax: temperatura máxima de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho; TIVFLANmed: temperatura média de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho.

Média da temperatura média do ar (Te); média da temperatura média do ar registrada durante o período das 0 às 6 horas (T06); média da temperatura média do ar registrada durante o período das 6 às 12 horas (T612); média da temperatura média do ar registrada durante o período das 12 às 18 horas (T1218); média da temperatura média do ar registrada durante o período das 18 às 0 horas (T180); média da umidade relativa média do ar registrada durante todos os dias (URe); média da umidade relativa média do ar registrada durante o período das 0 às 6 horas (UR06); média da umidade relativa média do ar registrada durante o período das 6 às 12 horas (UR612); média da umidade relativa média do ar registrada durante o período das 12 às 18 horas (UR1218); média da umidade relativa média do ar registrada durante o período das 18 às 0 horas (UR180).

APÊNDICE B - Modelos baseados em rede neural artificial e correlações obtidas entre os dados reais e estimados nas etapas de treinamento, validação e teste.

	Modelos	Correlação Treinamento	Correlação Validação	Correlação Teste	Correlação Total
1	TIVFRONmed-Ti	0.82	0.80	0.84	0.82
2	TIVFRONmed-URi	0.78	0.68	0.79	0.76
3	TIVFRONmed-TBUi	0.83	0.83	0.86	0.84
4	TIVFRONmed-TGNi	0.81	0.78	0.81	0.80
5	TIVFRONmed-TPOi	0.82	0.78	0.84	0.82
6	TIVFRONmed-Ti-URi	0.84	0.84	0.86	0.84
7	TIVFRONmed-Ti-TBUi	0.83	0.85	0.86	0.84
8	TIVFRONmed-URi-TBUi	0.85	0.81	0.85	0.84
9	TIVFRONmed-Ti-TGNi	0.84	0.80	0.85	0.84
10	TIVFRONmed-URi-TGNi	0.84	0.83	0.86	0.84
11	TIVFRONmed-TBUi-TGNi	0.84	0.82	0.86	0.84
12	TIVFRONmed-Ti-TPOi	0.85	0.84	0.86	0.85
13	TIVFRONmed-URi-TPOi	0.85	0.83	0.87	0.85
14	TIVFRONmed-TBUi-TPOi	0.84	0.83	0.86	0.84
15	TIVFRONmed-TGNi-TPOi	0.84	0.83	0.86	0.84
16	TIVFRONmed-Ti-URi-TBUi	0.85	0.84	0.87	0.85
17	TIVFRONmed-Ti-URi-TGNi	0.85	0.81	0.87	0.85
18	TIVFRONmed-Ti-TBUi-TGNi	0.85	0.83	0.86	0.85
19	TIVFRONmed-Ti-URi-TPOi	0.85	0.81	0.86	0.85
20	TIVFRONmed-Ti-TBUi-TPOi	0.86	0.83	0.85	0.85
21	TIVFRONmed-Ti-TGNi-TPOi	0.84	0.86	0.86	0.85
22	TIVFRONmed-URi-TBUi-TGNi	0.85	0.82	0.87	0.85
23	TIVFRONmed-URi-TBUi-TPOi	0.86	0.83	0.86	0.85
24	TIVFRONmed-URi-TGNi-TPOi	0.85	0.81	0.86	0.84
25	TIVFRONmed-TBUi-TGNi-TPOi	0.85	0.82	0.88	0.85
26	TIVFRONmed-Ti-URi-TBUi-TGNi	0.85	0.84	0.87	0.85
27	TIVFRONmed-Ti-URi-TBUi-TPOi	0.85	0.83	0.86	0.85
28	TIVFRONmed-Ti-URi-TGNi-TPOi	0.86	0.83	0.86	0.85
29	TIVFRONmed-Ti-TBUi-TGNi-TPOi	0.84	0.83	0.87	0.84
30	TIVFRONmed-URi-TBUi-TGNi-TPOi	0.85	0.82	0.86	0.85
31	TIVFRONmed-Ti-URi-TBUi-TGNi-TPOi	0.85	0.85	0.87	0.85
32	TIVOLmax-Ti	0.74	0.71	0.77	0.74
33	TIVOLmax-URi	0.72	0.69	0.73	0.72
34	TIVOLmax-TBUi	0.76	0.75	0.80	0.77
35	TIVOLmax-TGNi	0.73	0.69	0.74	0.72
36	TIVOLmax-TPOi	0.76	0.76	0.78	0.77
37	TIVOLmax-Ti-URi	0.83	0.78	0.82	0.82
38	TIVOLmax-Ti-TBUi	0.79	0.75	0.80	0.78
39	TIVOLmax-URi-TBUi	0.80	0.75	0.81	0.79
40	TIVOLmax-Ti-TGNi	0.81	0.78	0.80	0.80

41	TIVOLmax-URi-TGNi	0.80	0.78	0.80	0.80
42	TIVOLmax-TBUi-TGNi	0.81	0.77	0.81	0.80
43	TIVOLmax-Ti-TPOi	0.81	0.78	0.81	0.80
44	TIVOLmax-URi-TPOi	0.84	0.83	0.82	0.84
45	TIVOLmax-TBUi-TPOi	0.78	0.75	0.84	0.79
46	TIVOLmax-TGNi-TPOi	0.79	0.79	0.80	0.79
47	TIVOLmax-Ti-URi-TBUi	0.82	0.77	0.81	0.81
48	TIVOLmax-Ti-URi-TGNi	0.87	0.81	0.81	0.84
49	TIVOLmax-Ti-TBUi-TGNi	0.80	0.79	0.81	0.80
50	TIVOLmax-Ti-URi-TPOi	0.85	0.83	0.84	0.84
51	TIVOLmax-Ti-TBUi-TPOi	0.84	0.80	0.83	0.83
52	TIVOLmax-Ti-TGNi-TPOi	0.82	0.79	0.81	0.81
53	TIVOLmax-URi-TBUi-TGNi	0.86	0.76	0.82	0.83
54	TIVOLmax-URi-TBUi-TPOi	0.84	0.80	0.84	0.83
55	TIVOLmax-URi-TGNi-TPOi	0.85	0.81	0.82	0.84
56	TIVOLmax-TBUi-TGNi-TPOi	0.83	0.79	0.83	0.83
57	TIVOLmax-Ti-URi-TBUi-TGNi	0.85	0.76	0.84	0.83
58	TIVOLmax-Ti-URi-TBUi-TPOi	0.87	0.82	0.83	0.85
59	TIVOLmax-Ti-URi-TGNi-TPOi	0.87	0.83	0.83	0.85
60	TIVOLmax-Ti-TBUi-TGNi-TPOi	0.85	0.78	0.84	0.83
61	TIVOLmax-URi-TBUi-TGNi-TPOi	0.86	0.82	0.85	0.85
62	TIVOLmax-Ti-URi-TBUi-TGNi-TPOi	0.85	0.80	0.85	0.85

Temperatura média de superfície corporal obtida da região da frente das vacas (TIVFRONmed); temperatura máxima obtida da área ocular das vacas (TIVOLmax);

Dados meteorológicos: : temperatura de bulbo seco (Ti); umidade relativa do ar (URi); temperatura de bulbo úmido (TBUi) temperatura de ponto de orvalho (TPOi); temperatura de globo negro (TGNi);

Número de amostras analisadas (N). Siglas sem sufixo representam as médias de todas as variáveis registradas durante todo o experimento (40 dias);

Modelos desenvolvidos para predição da FR (1 a 31); modelos para predição da TR (32 a 62)