

UNIVERSIDADE DE SÃO PAULO  
FACULDADE DE ZOOTECNIA E ENGENHARIA DE ALIMENTOS

ALEX VINICIUS DA SILVA RODRIGUES

**Avaliação não invasiva do estresse térmico de bovinos: uma  
abordagem baseada em aprendizado de máquina e termografia de  
infravermelho**

---

Pirassununga

2022

ALEX VINICIUS DA SILVA RODRIGUES

**Avaliação não invasiva do estresse térmico de bovinos: uma  
abordagem baseada em aprendizado de máquina 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. Dr. Rafael Vieira de Sousa

Coorientadora: Profa. Dra. Luciane Silva Martello

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

R696a Rodrigues, Alex Vinicius da Silva  
Avaliação não invasiva do estresse térmico de  
bovinos: uma abordagem baseada em aprendizado de  
máquina e termografia de infravermelho / Alex  
Vinicius da Silva Rodrigues ; orientador Rafael  
Vieira de Sousa ; coorientador Luciane Silva  
Martello. -- Pirassununga, 2022.  
62 f.

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

1. Termografia de infravermelho. 2. Bem-estar  
animal. 3. Medição não-invasiva. 4. Mineração de  
dados. 5. Inteligência artificial. I. de Sousa,  
Rafael Vieira, orient. II. Martello, Luciane Silva,  
coorient. III. Título.

## **DEDICATÓRIA**

Dedico este trabalho aos meus pais que sempre me apoiaram ao longo de minha trajetória me incentivando e motivando a continuar em frente. Dedico também a minha irmã, uma pessoa exemplar, na qual sempre me espelhei para trilhar meu caminho.

## **AGRADECIMENTOS**

À Deus, por me dar forças para realizar esta pesquisa e por sempre estar presente em todos os momentos da minha vida.

Aos meus pais Ademar e Zilda e à minha irmã Zildmara, por me incentivarem nos estudos e me apoiarem sempre em todas as áreas da minha vida.

Ao meu orientador Prof. Dr. Rafael Vieira de Sousa e à minha coorientadora Profa. Dra. Luciane Silva Martello, por todos os ensinamentos e apoio iniciados na graduação e que se estenderam durante todo o mestrado.

Ao técnico do LICon Edson Sardinha por toda a ajuda prestada na execução do meu projeto de mestrado.

À equipe do experimento (Jéssica, André Levi, Isabele, Maria Carolina e Gabriel Pagin) por todo o esforço e dedicação na execução do experimento e pela amizade que construímos.

À todos os meus amigos que de alguma forma contribuíram para eu chegar até aqui e me tornar a pessoa que sou.

À CAPES pela concessão da bolsa de mestrado e pelo apoio financeiro para a realização desta pesquisa no período de 02/2020 a 06/2020.

À FAPESP pela concessão da bolsa de mestrado e pelo apoio financeiro para a realização desta pesquisa no período de 07/2020 a 01/2022.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

## RESUMO

RODRIGUES, A. V. S. **Avaliação não invasiva do estresse térmico de bovinos: uma abordagem baseada em aprendizado de máquina e termografia de infravermelho.** 2022. 62 f. Projeto de dissertação (Mestrado) - Faculdade de Zootecnia e Engenharia de Alimentos. Universidade de São Paulo, Pirassununga, 2022.

Estudos recentes em produção animal têm investigado tecnologias e modelos computacionais para predição do nível de estresse térmico com o uso de medições não invasivas e automáticas. Para contribuir com esse tema, o projeto tem como objetivo a construção e teste de modelos computacionais para predição do nível de estresse térmico de bovinos de leite utilizando base de dados obtida por experimento em câmara climática. O experimento foi conduzido durante 45 dias com 10 bezerras da raça Holandesa distribuídas aleatoriamente em dois grupos. Os animais foram alocados na câmara climática (em sistema *Tie Stall*) e expostos a duas ondas de calor. Durante o período do experimento, além dos dados meteorológicos das instalações, foram coletados 5 vezes ao dia (6, 10, 14, 18 e 22 horas) os dados de temperatura retal, frequência respiratória e da termografia de infravermelho (TIV) de diferentes áreas do corpo (olho, fronte, costela e flanco) para extração de valores temperaturas e da Assinatura Térmica (método de extração de características explorado no trabalho). Para a etapa de modelagem foram avaliados diferentes algoritmos baseados em Aprendizado de Máquina (redes neurais artificiais, máquina de vetores de suporte, árvore de decisão e k-vizinhos mais próximos) utilizando combinações diferentes de entradas para classificação de atributo de nível de estresse térmico. Para determinar o desempenho dos modelos de classificação foram utilizados como métrica os parâmetros obtidos da matriz confusão gerada (acurácia, precisão e sensibilidade). Os melhores resultados foram obtidos com os algoritmos de Floresta Randômica e Máquina de Vetores de Suporte. A Assinatura Térmica se mostrou mais eficiente como atributo previsor dos modelos quando comparada as temperaturas pontuais extraídas das TIVs. Foram obtidos no trabalho modelos com acurácias acima de 90% na classificação de nível de estresse térmico animal. Os resultados obtidos evidenciam o potencial do uso de aprendizado de máquina associado a dados extraídos de termografias de infravermelho para a classificação de nível de estresse térmico animal.

**Palavras-chave:** termografia de infravermelho, bem-estar animal, medição não-invasiva, mineração de dados, inteligência artificial.

## **ABSTRACT**

RODRIGUES, A. V. S. **Non-invasive assessment of heat stress in cattle: an approach based on machine learning and infrared thermography.** 2022. 62 f. Projeto de dissertação (Mestrado) - Faculdade de Zootecnia e Engenharia de Alimentos. Universidade de São Paulo, Pirassununga, 2022.

Recent studies in animal production have investigated technologies and computational models for predicting the level of thermal comfort through noninvasive and automatic measurements. To contribute to this theme, the project aims to build and test computational models for predicting the level of thermal comfort of dairy cattle using a database obtained by an experiment in a climatic chamber. The experiment was conducted for 45 days with 10 Holstein calves randomly distributed in two groups. The animals were placed in the climatic chamber (in a Tie Stall system) and exposed to two heat waves. During the experiment period, in addition to the meteorological data of the facilities, rectal temperature, respiratory rate and infrared thermography (IRT) data from different areas of the body (eye, forehead, rib and flank) to extract temperatures values and the Thermal Signature (feature extraction method explored at work). For the modeling step, different algorithms based on Machine Learning (artificial neural networks, support vector machine, decision tree and closest k-neighbors) were evaluated using different combinations of inputs for classifying the thermal stress level attribute. To compare the classification models, the parameters obtained from the generated confusion matrix (accuracy, precision and recall) were used as a metric. The best results were obtained with the Random Forest and support vector machine algorithms. The Thermal Signature proved to be more efficient as a predictor attribute of the models when compared to the point temperatures extracted from the TIVs. Models with accuracies above 90% in the classification of animal heat stress level were obtained in this work. The results obtained evidence the potential of using machine learning associated with data extracted from infrared thermography for the classification of animal heat stress level.

**keywords:** infrared thermography, animal welfare, non-invasive measurement, data mining, artificial intelligence.

## Lista de Ilustrações

Figura 1 - Visão geral das etapas que compõe o método KDD.....	8
Figura 2 - Estrutura do neurônio artificial básico (perceptron) de uma rede neural artificial.....	10
Figura 3 - Exemplo de árvore de decisão .....	11
Figura 4 - Ilustração dos hiperplanos da classe de algoritmos SVM .....	12
Figura 5 - Linha do tempo período experimental .....	18
Figura 6 - Câmara climática .....	19
Figura 7 - Mensuração da temperatura retal.....	20
Figura 8 - Regiões da superfície corporal que foram obtidos de termografia de infravermelho: frente (verde), área ocular (vermelho), orelha (roxo), costela (amarelo) e flanco (azul).....	21
Figura 9 - Etapas para extração de características das matrizes de dados da termografia de infravermelho .....	22
Figura 10 - Exemplos de Assinaturas Térmicas extraída de matrizes de dados de TIV do olho para diferentes condições de estresse térmico dos bovinos de leite.....	24
Figura 11 - Diagrama ilustrativo da modelagem .....	26
Figura 12 - Fluxograma da etapa de modelagem .....	29
Figura 13 - Correlação de Pearson .....	33
Figura 14 - Análise de diferença significativa primeira etapa de modelagem .....	37
Figura 15 - Acurácias dos modelos baseados em Floresta Randômica para vetores de Assinatura Térmica com número diferente de faixas de temperatura .....	38
Figura 16 - Comparação dos valores das acurácias normalizadas para os modelos classificadores baseados em Floresta Randômica .....	40
Figura 17 - Análise de diferença significativa entre dos modelos baseados em Floresta Randômica para vetores de Assinatura Térmica com número diferente de faixas de temperatura.....	40
Figura 18 - Acurácias dos modelos baseados em Máquina de Vetores de Suporte para vetores de Assinatura Térmica com número diferente de faixas de temperatura .....	41
Figura 19 - Comparação dos valores das acurácias normalizadas para os modelos classificadores baseados em Máquinas de Vetores de Suporte .....	43
Figura 20 - Análise de diferença significativa entre dos modelos baseados em Máquina de Vetores de Suporte para vetores de Assinatura Térmica com número diferente de faixas de temperatura.....	44
Figura 21 - Análise de diferença significativa em modelos de Floresta Randômica com diferentes conjuntos de dados meteorológicos .....	47
Figura 22 - Modelos com melhor desempenho - Floresta Randômica.....	48
Figura 23 - Análise de diferença significativa modelos base de dados e entrada - SVM .....	50
Figura 24 - Modelos com melhor desempenho – máquinas de vetores de suporte.....	51



## Lista de Tabelas

Tabela 1 - Exemplo de matriz confusão com 2 classes .....	13
Tabela 2 - Classificação em níveis de estresse térmico animal .....	27
Tabela 3 - Estatística descritiva dos dados fisiológicos e meteorológicos .....	31
Tabela 4 - Correlações entre variáveis fisiológicas .....	32
Tabela 5 - Correlação entre variáveis fisiológicas e meteorológicas .....	33
Tabela 6 - Acurácias dos melhores modelos da primeira etapa .....	36
Tabela 7 - Acurácias segunda etapa modelagem para os modelos classificadores baseados em Floresta Randômica.....	39
Tabela 8 - Acurácias segunda etapa de modelagem para os modelos classificadores baseados em Máquina de Vetores de Suporte .....	42
Tabela 9 - Acurácia terceira etapa de modelagem para classificadores baseados em floresta randômica .....	46
Tabela 10 - Acurácia terceira etapa de modelagem para classificadores baseados em Máquina de Vetores de Suporte.....	49
Tabela 11 - Matriz de confusão melhor modelo classificador FR 2 classes – Floresta Randômica.....	52
Tabela 12 - Matriz de confusão melhor modelo classificador FR-3-Classes – Floresta Randômica.....	52
Tabela 13 - Matriz de confusão melhor modelo classificador TR-2-Classes – Floresta Randômica.....	53
Tabela 14 - Matriz de confusão melhor modelo classificador FR-2-Classes – Máquina de Vetores de Suporte.....	53
Tabela 15 - Matriz de confusão melhor modelo classificador FR-3-Classes – Máquina de Vetores de Suporte (SVM) .....	54
Tabela 16 - Matriz de confusão melhor modelo classificador TR-2-Classes – Máquina de Vetores de Suporte (SVM) .....	54

## **Lista de Abreviaturas**

AT	Assinatura térmica
ATOI	Assinatura térmica da região ocular dos animais
ATOr	Assinatura térmica da região da orelha dos animais
FLR	Floresta randômica
FR	Frequência respiratória
H	Entalpia
ITGU	Índice de temperatura de globo negro e umidade
ITU	Índice de temperatura e umidade
KNN	K-vizinhos mais próximos
RNA	Rede neural artificial
SVM	Máquina de vetores de suporte
TBS	Temperatura de bulbo seco
TC <sub>o</sub>	Tratamento controle
TE <sub>s</sub>	Tratamento estresse
TIV	Termografia de infravermelho
TPO	Temperatura de ponto de orvalho
TR	Temperatura retal
UR	Umidade relativa

## Sumário

1. Introdução.....	1
2. Objetivos.....	3
2.1 Objetivo geral.....	3
2.2 Objetivos específicos.....	3
3. Revisão bibliográfica.....	3
3.1 Índices de estresse térmico.....	3
3.2 Avaliação do estresse térmico animal e termografia de infravermelho.....	4
3.3 Aprendizado de máquina.....	8
4. Material e Métodos.....	15
4.1 Delineamento experimental e aquisição de dados.....	16
4.1.1 Tratamentos.....	17
4.1.2 Dados do ambiente.....	20
4.1.3 Dados dos animais.....	20
4.2 Extração de características - Assinatura Térmica.....	21
4.3 Análises Estatísticas.....	24
4.4 Desenvolvimento dos modelos.....	25
4.4.1 Estrutura dos modelos.....	25
4.4.2 Execução da modelagem.....	26
5. Forma de análise dos modelos.....	30
6. Resultados.....	30
6.1 Análise estatística .....	31
6.2 Modelagem .....	34
6.2.1 Seleção de algoritmo de aprendizado de máquina .....	34
6.2.2 Seleção de atributo previsor entre os dados de termografia .....	37
6.2.2.1 Assinatura Térmica com Floresta Randômica.....	37
6.2.2.2 Assinatura Térmica com Máquina de Vetores de Suporte .....	41
6.2.3 Seleção de atributor previsor entre os dados metereológicos.....	44
6.2.3.1 Dados meteorológicos com Floresta Randômica .....	44
6.2.3.2 Dados meteorológicos com Máquina de Vetores de Suporte.....	48
6.3 Melhores modelos classificadores de nível de estresse térmico.....	51
7. Conclusão .....	55

8. Referências .....	57
----------------------	----

## 1. Introdução

A produção de bovinos de leite é realizada em todo o território brasileiro e representa uma atividade de grande importância no Brasil em termos econômicos e sociais. Neste contexto, a finalidade principal das fases de cria e recria de bezerras de leite é a reposição dos animais (vacas leiteiras) nas plantas de produção de leite (BARNABÉ et al., 2014). Normalmente os produtores buscam desaleitar os animais e finalizar a fase de cria (ou aleitamento) entre 60 a 90 dias após o nascimento, com o objetivo de introduzir o maior uso de alimentos sólidos (alimentação mais barata que leite) e diminuir a dependência da alimentação líquida (leite), reduzindo, deste modo, os custos de alimentação dos animais. Neste momento é necessária bastante atenção pelos produtores, por se tratar de uma fase de alto risco de incidência de doenças devido ao grande nível de estresse pelos manejos de descorna (remoção de chifres), mudança de dieta (líquida para sólida) e de instalação e, adaptação das bezerras ao novo processo de digestão. Além dos manejos estressantes desta fase, em países como o Brasil, que apresentam altas temperaturas no decorrer do ano, os animais ainda são acometidos pelo estresse térmico (SOUZA e BATISTA, 2012).

Estas condições climáticas e ambientais adversas têm um impacto significativo sobre o desempenho da produção animal, uma vez que níveis altos de estresse térmico pode reduzir o desempenho produtivo e, em situações extremas, levar à morte (FOURNEL et al., 2017; VAN HERTEM et al., 2017). O desempenho é prejudicado porque as condições elevadas de temperatura do ar que levam ao estresse térmico acionam mecanismos termorreguladores para perda de calor e redução de funções de produção de calor como a ingestão de alimentos (consumo de matéria seca) (COLLIER et al., 2006; GAUGHAN e MADER, 2013).

Existem alguns índices baseados em variáveis meteorológicas para indicar níveis de estresse térmico como, por exemplo, o índice de temperatura e umidade (ITU). Entretanto, estes índices normalmente não consideram a variação individual da resposta do animal e das diferentes raças, sendo que o estresse térmico animal é o resultado da troca de energia térmica entre os animais e ambiente em que estão inseridos e, portanto, depende dos fatores individuais (SILVA et al., 2007; DIKMEN e HANSEN, 2009; FOURNEL et al., 2017). Por outro lado, indicadores baseados em respostas fisiológicas (ex. frequência respiratória e temperatura corporal interna) demandam mensuração realizada tradicionalmente de forma manual e visual, que é laboriosa e muitas vezes

invasiva e estressante para o animal (FOURNEL et al., 2017; WATHES et al., 2008). Essas respostas termorregulatórias que ocorrem no organismo dos animais se manifestam como modificações fisiológicas e comportamentais. Os mecanismos fisiológicos incluem alterações na frequência respiratória e cardíaca, na sudorese e na circulação sanguínea para favorecer a troca de calor. A microcirculação na superfície corporal é um parâmetro que tem sido pesquisado para diagnóstico de estresse térmico de maneira indireta, em particular com o uso de termografia de infravermelho (TIV), buscando sua correlação com fatores de bem-estar e desempenho animal (SELLIER et al., 2014; FOURNEL et al., 2017).

As medidas indiretas geralmente demandam um modelo matemático que descreva as relações entre as variáveis envolvidas (entradas e saídas do modelo). Em um sistema biológico típico, seus subsistemas componentes (ex.: sistema de termorregulação animal) e as interações complexas entre eles introduzem um grande número de variáveis, o que resulta em modelos matemáticos bastante complexos. Para superar tal desafio, a pesquisa de métodos computacionais baseados em técnicas de inteligência artificial (IA) tem alcançado resultados promissores para geração de modelos preditivos para avaliação de estresse térmico utilizando sensores não invasivos (HUANG et al., 2010; SOUSA et al., 2018).

Um dos grandes desafios do uso da IA em sistemas de produção animal é a construção de base de dados balanceada com número suficiente de dados que representem cada condição ambiental e fisiológica, e o respectivo nível de estresse térmico. Normalmente as metodologias para construção dessas bases de dados envolvem experimentos laboriosos e dispendiosos com coletas de dados para grupos de animais de uma única raça, em vários dias e em diferentes épocas do ano. Nesse contexto, o uso de câmara climática (ambiente fechado com controle da temperatura) pode ser bastante útil para criar condições ambientais diversas e acelerar o processo de construção de bases de dados balanceada.

O cenário exposto evidencia o potencial de aplicação da TIV e de modelos computacionais baseados em IA para predição do estresse térmico utilizando para sua construção dados experimentais obtidos em câmara climática. Identifica-se a oportunidade de acelerar e diversificar a construção e teste de modelos baseados em diferentes conjuntos de variáveis de entrada, incluindo as temperaturas de diferentes partes da superfície corporal do animal, bem como a sua relação com as variáveis fisiológicas e sua evolução ao longo do dia.

## **2. Objetivos**

### **2.1 Objetivo geral**

O objetivo do trabalho é a construção e avaliação de modelos computacionais baseados em algoritmos de aprendizado de máquina para a classificação de nível de estresse térmico de bovinos de leite (bezerras) a partir de medições não invasivas.

### **2.2 Objetivos específicos**

- Avaliar o potencial de diferentes algoritmos de aprendizado de máquina para geração dos modelos classificadores de nível de estresse térmico em bovinos de leite (bezerras);
- Avaliar os modelos gerados a partir de diferentes combinações de dados meteorológicos com as características extraídas das TIVs de diferentes áreas da superfície corporal dos bovinos;
- Avaliar a construção e a aplicação de base de dados obtida em experimento realizado em câmara climática para construção de modelos computacionais classificadores de estresse térmico.

## **3. Revisão bibliográfica**

Neste item são apresentadas as informações e as referências utilizadas para o embasamento científico deste projeto. A revisão bibliográfica foi dividida em índices de estresse térmico (apresenta os índices tradicionais utilizados para determinar o nível de estresse térmico animal), termografia de infravermelho (aborda a técnica e pesquisas que a utilizam para determinar o estresse térmico animal) e aprendizado de máquina (destaca ferramentas bem como seu uso em pesquisas aplicadas à produção animal).

### **3.1 Índices de estresse térmico**

Tendo em vista o impacto de fatores meteorológicos, tais como temperatura e umidade no estresse térmico animal, foram desenvolvidos índices que, baseados nessas variáveis climáticas, buscam classificar nível de estresse térmico animal.

O índice de temperatura e umidade (ITU) foi desenvolvido por Thom (1959). Inicialmente criado como um parâmetro para estimar o nível de estresse térmico em humanos, se tornou um dos índices mais utilizados como ferramenta de avaliação do ambiente térmico em instalações pecuárias e de determinação do estado de estresse térmico dos animais alojados nestas instalações. Este índice utiliza a temperatura de bulbo

seco e a umidade relativa do ar, parâmetros de fácil obtenção (estações meteorológicas) para utilização nos sistemas de produção animal (SCHÜLLER; BURFEIND; HEUWIESER, 2013).

Após a elaboração do ITU proposto por Thom (1959) diversos autores propuseram outras formas de cálculo do ITU, variando-se o peso dos parâmetros temperatura e umidade.

Existem diversos estudos que buscam classificar o estado de estresse térmico dos animais de acordo com valores de ITU, porém há dificuldade devido a diferentes características climáticas nas diversas regiões e a individualidade dos animais (POLSKY; VON KEYSERLINGK, 2017).

Apesar de amplamente utilizado o ITU não pondera as respostas individuais de parâmetros fisiológicos dos animais, dificultando assim a obtenção de avaliações precisas do nível de estresse térmico dos animais, fator que incentiva o desenvolvimento de ferramentas para mensuração de estresse térmico animal que considerem além das variáveis meteorológicas os dados fisiológicos dos animais.

O Índice de Temperatura de Globo Negro e Umidade (ITGU) foi desenvolvido para determinar o nível de estresse térmico em vacas leiteiras, e é obtido considerando além das variáveis de temperatura de bulbo seco e umidade, os efeitos da radiação e a movimentação do ar. Deste modo, é possível que este índice apresente maior eficiência na determinação do nível de estresse térmico animal, quando comparado ao ITU, visto que os parâmetros de radiação e movimentação do ar também apresentam influência significativa na sensação térmica animal (BUFFINGTON; CANTON; PITT, 1981).

O método para calcular o ITGU bem como os parâmetros utilizados, são apresentados na equação 1, de acordo com Buffington, Canton e Pitt (1981):

$$ITGU = Tg + 0,36 * Tpo + 41,5 \quad (1)$$

Onde:

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

Tpo = Temperatura do ponto de orvalho, °C.

### **3.2 Avaliação do estresse térmico animal e termografia de infravermelho**

Como alternativa aos tradicionais índices de estresse térmico existem estudos que buscam obter classificações mais precisas e individualizadas, que considerem variáveis dos animais e, que estas variáveis sejam mensuradas de maneira não invasiva. Dentre



estes estudos destaca-se a termografia de infravermelho (TIV), que é uma ferramenta capaz de mensurar mudanças, na transferência de calor e no fluxo sanguíneo, por meio da detecção de alterações na temperatura de superfície corporal (MCMANUS et al., 2016).

A radiação infravermelha foi descoberta em 1800 pelo astrônomo Willian Herschel. Ele realizou a dispersão da luz solar através de um prisma de vidro e mediu a temperatura correspondente a cada cor utilizando um termômetro. Willian Herschel observou que a temperatura das cores aumentava a medida que se aproximava do vermelho. Houve um aumento ainda maior de temperatura na região após a luz vermelha. Apesar de não ser captada pelos olhos humanos, ficou evidente a existência de uma radiação nesta faixa, que ficou conhecida como radiação infravermelha. (OLIVEIRA E SILVA, 2014).

A termografia de infravermelho é uma técnica não invasiva, capaz de captar a radiação infravermelha emitida pela superfície de objetos ou corpos, associada ao grau de agitação de seus átomos e moléculas. Assim TIV pode ser obtida utilizando equipamentos com sensores capazes de captar essa radiação infravermelha, naturalmente emitida pelos objetos ou corpos. As câmeras termográficas possuem sensores capazes de captar a radiação infravermelha e transformá-la em imagens ou vídeos imagens possibilitando a visualização e avaliação da temperatura associada a este tipo de radiação. A utilização das câmeras termográficas como ferramenta de monitoramento de temperatura dos animais apresenta grandes vantagens em relação aos termômetros convencionais, pois não há contato físico com o animal, além de ser uma ferramenta passível de automatização (KNIZKOVA et al., 2007). Deste modo, diversos trabalhos de pesquisa recentes têm investigado a relação entre imagens TIV de partes da superfície corporal de animais associadas com variáveis meteorológicas, com indicadores fisiológicos de bem-estar e desempenho animal (MONTANHOLI et al., 2008; SCHAEFER et al., 2012; MARTELLO et al., 2015; RICCI et al., 2019).

Foi realizado uma revisão de trabalhos com o uso de TIV no diagnóstico de doenças em suínos de maneira não invasiva por Choudhury et al. (2020). De acordo com os autores, a TIV confirmou um aumento de temperatura de áreas do corpo dos animais infectados, quando comparados aos animais saudáveis.

Além do diagnóstico de estado de saúde dos animais a TIV está sendo pesquisada como ferramenta para detecção de nível de estresse animal, dentre outras aplicações. O uso de TIV para avaliar a temperatura de superfície corporal de suínos em duas estações

do ano (verão e outono) foi realizado por Ricci et al. (2019), onde os animais se encontravam alojados em instalações com e sem a presença de sistema de resfriamento. A termografia infravermelha permitiu identificar as áreas de superfície corporal mais quentes e frias dos animais, podendo ser utilizada como ferramenta de avaliação de instalações de suínos e do bem-estar animal.

O uso da termografia de infravermelho foi testado em tubos de ordenha para estimar a temperatura do leite e determinar casos de mastite subclínica por Marrero et al. (2020). O experimento foi realizado com 121 vacas sendo 100 animais com quadro de mastite subclínica. As TIVs foram coletadas 2 minutos após a fixação dos tubos de ordenha e em intervalos de 30 segundos durante a ordenha. Foram realizadas análises de amostras do leite para identificar os casos de mastite. Os pesquisadores observaram temperaturas mais altas nos quartos de glândula mamária com presença de patógenos, concluindo que o uso de TIV pode ser útil na detecção de mastite subclínica.

A correlação entre a temperatura medida por meio de imagens termográficas de diferentes áreas de superfície corporal com a produção de calor e metano em vacas leiteiras foi estudada por Montanholi et al. (2008). Os autores concluíram que a termografia pode ser aplicada para avaliar a produção de calor e metano, por meio da análise da temperatura das regiões dos pés e a diferença de temperatura entre os flancos esquerdo e direito. Foi apontado ainda no estudo a possibilidade de utilização desta ferramenta também na avaliação de respostas fisiológicas à ordenha e alimentação.

Um método não invasivo e automatizado utilizando TIV foi sugerido por Schaefer et al. (2012) para a identificação da doença respiratória bovina em bezerros receptores. Os autores observaram que os animais que apresentaram quadro clínico de doença respiratória apresentaram valores de temperatura de termografia infravermelha mais altos em relação aos animais que não apresentaram a doença. O estudo concluiu que a implementação desta ferramenta em sistemas de produção pecuária pode auxiliar os profissionais do manejo animal na identificação de doenças respiratórias em bovinos de maneira não invasiva.

A TIV foi utilizada para monitorar a temperatura de superfície corporal de bovinos de corte buscando sua correlação com as variáveis fisiológicas de temperatura retal e frequência respiratória por Martello et al. (2015). No estudo foram avaliadas TIVs das regiões do olho, bochecha, flanco, costelas, garupa e patas dianteiras dos animais. A região que obteve maior correlação com as variáveis fisiológicas foi a frente dos animais. Isola et al. (2020) utilizou a TIV utilizada para identificar diferença de temperaturas

corporais entre vacas com pelagem de cores diferentes e auxiliar no entendimento da relação entre fenótipo e temperatura corporal.

Para bezerros existem alguns estudos com o uso da TIV, como pesquisas sobre doenças respiratórias (SCHAEFER et al., 2007; SCHAEFER et al., 2011) e a utilização da TIV para monitoramento de perfis de temperatura corporal dos animais em situações de estresse térmico (HOFFMANN et al., 2012).

Os estudos apresentados evidenciam o potencial do uso da TIV na produção animal, em especial na determinação do nível de estresse térmico, e corroboram no desenvolvimento de novas pesquisas que busquem melhorar a precisão da técnica. Para avaliar uma ferramenta de mensuração de nível de estresse térmico animal é interessante, e muitas vezes necessário, a obtenção de uma base de dados balanceada (com números semelhantes de dados por classe de estresse térmico animal), fato que pode influenciar positivamente na acurácia dos modelos computacionais classificadores de estresse térmico (PACHECO et al., 2020). Em um experimento em ambiente aberto esta situação demandaria realizar coletas em diversas estações do ano. Neste contexto, a câmara climática pode permitir realizar o controle climático do ambiente (por meio da variação da temperatura) e, torna possível simular ambientes com diferentes níveis de estresse térmico animal, auxiliando na obtenção de base de dados diversificada e equilibrada, de maneira mais rápida.

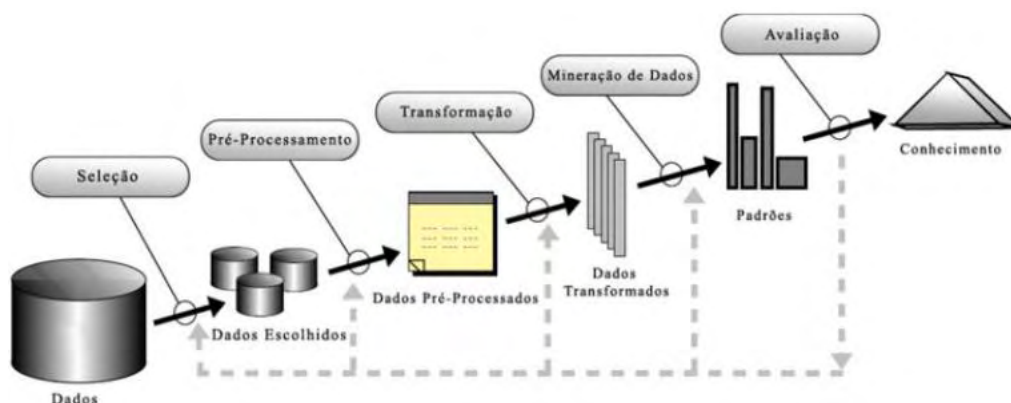
Um estudo sobre os efeitos de ondas de calor foi realizado com 9 bovinos, avaliados por 18 dias, por Brown-Brandl et al. (2005). Os animais foram expostos a 10 dias em temperatura termoneutra ( $18\pm 7^{\circ}\text{C}$ ) e 8 dias de estresse térmico ( $32\pm 7^{\circ}\text{C}$ ) em câmara climática, com o objetivo de observar os efeitos da aclimação dos animais em uma situação de estresse. Garner et al. (2017) utilizaram câmara climática para gerar ondas de calor, avaliando as respostas fisiológicas e de produção de vacas Holstein-Friesian quando expostas a estas condições ambientais. Os resultados indicaram que as condições impostas às vacas nas câmaras de clima controlado foram suficientes para induzir respostas ao estresse térmico e afetar adversamente a produção na vaca leiteira em lactação. Vale et al. (2016) utilizou uma câmara climática para avaliar o efeito de uma onda de calor em um ambiente com cento e sessenta frangos de corte aos 42 dias. Neste estudo foram avaliadas concentrações de oxigênio, monóxido de carbono e amônia em cada curral.

### 3.3 Aprendizado de máquina

A complexidade dos dados gerados pelos sistemas de produção animal tem motivado o desenvolvimento de estudos com aplicação de ferramenta da Inteligência Artificial (IA). O Aprendizado de Máquina (*Machine Learning*) caracteriza-se como um ramo da IA que explora a construção de algoritmos de reconhecimento de padrões em uma base de dados, possibilitando a criação de modelos computacionais capazes de prever saídas a partir da variação dos dados de entrada (GRUS, 2016). Atualmente o processo de aprendizado de máquina está associado ao desenvolvimento de modelos para análise de grande volume de dados, de maneira rápida, automática e precisa (*Big Data*). A mineração de dados (*Data Mining*) é uma importante etapa deste processo de modelagem, uma vez que se busca evidenciar padrões em uma base de dados com o objetivo de transformá-los em conhecimento por meio de modelagens computacionais (SILVA; PERES; BOSCAROIOLI, 2016).

O KDD (*Knowledge Discovery in Databases*), em português Descoberta do Conhecimento em Base de Dados, é uma metodologia de referência que sistematiza o processo da obtenção de informação e conhecimento a partir de conjuntos de dados brutos através de etapas de manipulação de dados que envolvem seleção, organização, transformação, modelagem, reconhecimento de padrões e extração de conhecimento de uma base de dados. Esta metodologia se divide em 5 etapas: seleção de dados, pré-processamento de dados, transformação (extração de características), mineração de dados (obtenção de modelos ou padrões) e interpretação (visualização e avaliação dos modelos). A Figura 1 apresenta de maneira esquemática a metodologia KDD (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

Figura 1 - Visão geral das etapas que compõe o método KDD



Fonte: Adaptado de Fayyad et al., 1996.

O KDD é uma metodologia de referência para orientar o uso de técnicas da ciência de dados para trabalhar explorar de forma sistematizada bases de dados. Nas três primeiras etapas da metodologia são selecionados, pré-processados são aplicados algoritmos para identificar e extrair características relevantes dos dados brutos e gerar uma base de dados consistente e representativa para a etapa seguinte de mineração de dados. Na etapa de mineração são construídos modelos computacionais baseados em estatística e aprendizado de máquina que permitem gerar informações e obter conhecimentos partir da base de dados organizada. Nessa etapa podem ser aplicados diferentes métodos e ferramentas computacionais dependendo da disponibilidade e da finalidade para exploração da base organizada e geração de conhecimento. Os algoritmos de aprendizado de máquina utilizados nesta etapa podem ser classificados de acordo com sua finalidade em dois tipos: algoritmos de aprendizado não-supervisionado e algoritmos de aprendizado supervisionado.


O aprendizado não-supervisionada trata-se um conjunto de métodos e ferramentas computacionais para serem aplicados em bases de dados não rotuladas previamente, sendo considerado como ferramental descritivo identificar relações ou associações entre dados de uma base.

Os métodos e ferramentas de aprendizado supervisionado são utilizados em bases de dados rotuladas, onde os dados de entrada, denominados atributos previsores, estão associados a saídas previamente conhecidas (exemplos coletados previamente), chamadas de atributo meta. O ferramental do aprendizado supervisionado permite treinar algoritmos para construir modelos computacionais preditores de informações quantitativas (valores) ou qualitativas (classificações) a partir de novos dados de entrada fornecidos (HANSON; STUTZ; CHEESEMAN, 1995). Nesse contexto, o ferramental para o desenvolvimento de modelos preditivos (de valores ou de classificação) é vasto, contendo diversas classes de algoritmos aplicados ao aprendizado supervisionado dos quais se destacam: redes neurais artificiais, árvore de decisão, máquina de vetores de suporte e k-vizinhos mais próximos.

As Redes Neurais Artificiais (RNAs) são classes de algoritmos inspirados em modelos de redes neurais biológicas (cérebro humano). As RNAs surgiram para solução de problemas complexos onde estão presentes não-linearidades ou que apresentam um grande número de variáveis, sendo amplamente utilizado em diversos tipos de sistemas devido sua capacidade de mapeamento não-linear, precisão de aprendizado e robustez (SHEELA; DEEPA, 2013).

Os modelos baseados em RNA utilizam uma estrutura organizada em camadas de neurônios computacionais ou artificiais (*perceptrons*), que conectam entre si para formar camadas adjacentes. Os valores de saída de um neurônio são utilizados como entrada pelos neurônios da próxima camada, permitindo assim o processamento e a transmissão de unidades de informação. Cada conexão entre neurônios está associada a um peso (valor) que constitui um elemento de memória adquirida com o treinamento da rede de neurônios. Um neurônio artificial básico recebe como entrada o somatório dos valores das saídas dos neurônios da camada anterior multiplicados pelos pesos das respectivas conexões, conforme a Figura 2. É possível que o neurônio receba uma entrada extra, denominada bias ( $b_k$ ), com função de aumentar ou diminuir o valor da soma ponderada (SILVA et al., 2016). Posteriormente é aplicada a função de ativação  $\varphi(v)$  que fornece o valor de saída do neurônio. Este processamento é realizado por todas as camadas existentes na estrutura da RNA, até a última camada da rede forneça a saída do modelo. O aprendizado ocorre por meio do ajuste dos pesos e bias de cada conexão e neurônio na etapa de treinamento, onde exemplos de entradas e saídas são apresentados à rede de neurônios para ajuste desses parâmetros (WALCZAK; CERPA, 2003).

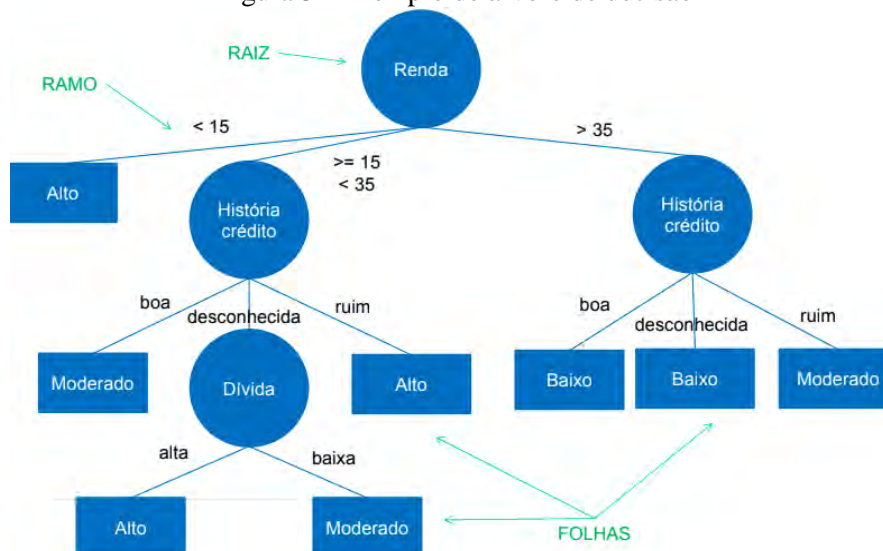
Figura 2 - Estrutura do neurônio artificial básico (*perceptron*) de uma rede neural artificial



Fonte: Haykin, 1999.

A Árvore de Decisão é uma classe de algoritmos que podem ser utilizados para predição (valores) ou classificação e são estruturados como fluxogramas de decisões compostos por atributos previsores (nós da árvore de decisão) e atributo meta (classificado nas folhas da árvore de decisão). Os ramos presentes nesta estrutura representam os valores que os atributos previsores podem assumir. A Figura 3 apresenta um exemplo de árvore de decisão em que o atributo meta é a classificação do risco de análise de crédito. Os atributos previsores representados são: renda, história de crédito e dívida. As folhas apresentam as classificações que o atributo meta pode receber.

Figura 3 - Exemplo de árvore de decisão




Fonte: Adaptado por SOUSA, 2020.

O processo de treinamento para obtenção da árvore de decisão é baseado no ganho de informação de cada atributo predictor. Neste processo o algoritmo calcula o ganho de informação de cada atributo (associado a entropia) criando uma regra para o atributo com maior valor deste parâmetro. Este processo é repetido até que não haja mais ganho de informação significativo com novas regras. Obtém-se então uma hierarquia entre os atributos predictores de acordo com os valores de ganho de informação. Quanto maior o ganho de informação de um atributo maior será sua posição hierárquica na árvore de decisão. O ganho de informação representa a relevância de um atributo predictor na classificação do atributo meta (KOTU; DESHPANDE, 2015).

Os algoritmos baseados em Máquina de Vetores de Suporte (SVM – *Support Vector Machine*) são desenvolvidos (treinados) para separar linearmente os dados em classes por meio de uma fronteira, gerando hiperplanos em um espaço n-dimensional. Quando não é possível realizar a separação linear em um dado espaço n-dimensional, aplica-se uma função ‘kernel’ para mudar a dimensão dos dados, possibilitando dessa maneira obter uma separação linear dos dados nesta outra representação espacial. O treinamento do algoritmo é baseado na ideia de se obter a maior margem para separar duas classes (hiperplanos), buscando reduzir os erros ( $\xi$  - pontos classificados de maneira equivocada) (KOTU; DESHPANDE, 2015). Na Figura 4 é possível observar os parâmetros utilizados na metodologia deste algoritmo.

Figura 4 - Ilustração dos hiperplanos da classe de algoritmos SVM



\*  $\xi$ : erro de classificação (distância da fronteira); *margin*: margens de separação entre dois planos (distância mínima da fronteira do dado mais próximo para cada plano); *boundary*: fronteira de separação entre dois hiperplanos.

Fonte: KOTU; DESHPANDE, 2015.

O algoritmo KNN (*K-Nearest Neighbour* ou K-Vizinhos Mais Próximos) baseia-se nas distâncias entre um novo registro em relação a um determinado número 'K' de vizinhos mais próximos em um espaço n-dimensional. Deste modo o novo registro é classificado de acordo com a maioria dos 'K' vizinhos mais próximos. Neste método não há a necessidade de construção de um modelo preliminar obtido por treinamento, sendo classificado como aprendizagem '*lazy*' (preguiçosa) por ser necessário calcular todas as distâncias a cada registro de entradas novas. A principal métrica de avaliação de distâncias deste algoritmo é a distância euclidiana (ZHANG, 2016).

Para determinar o desempenho dos modelos desenvolvidos é necessário separar a base de dados em dois conjuntos: um determinado percentual para a construção (treinamento e validação) e o percentual restante para a avaliação (teste) do modelo construído, de modo que o modelo treinado seja testado com dados desconhecidos (não utilizados na construção dos modelos). Dessa forma, após a construção, o modelo será utilizado para realizar a predição (de valor ou classificação) do atributo meta e os valores preditos são comparados com os valores reais obtendo assim métricas de determinação do desempenho. Existem variações na forma de separação dos conjuntos de dados para treinamento, validação e teste, sendo que entre essas variações destaca-se método K-subconjuntos de validação cruzada (*K-fold cross-validation*). A avaliação do modelo por este método é obtida dividindo-se a base de dados em K subconjuntos para realizar K iterações de treinamento e teste. Em cada iteração um subconjunto é reservado para testar o modelo, enquanto os demais são utilizados para construir o modelo. Este processo é repetido até que todas as partes sejam testadas, gerando K modelos. Ao final do processo



é calculada a média dos parâmetros relacionados ao desempenho de cada parte testada, obtendo-se as métricas gerais de desempenho do modelo (HASTIE; TIBSHIRANI; FRIEDMAN, 2017).

As métricas utilizadas para determinar o desempenho são diferentes entre as avaliações dos modelos de predição de valor e predição da classificação. Os modelos de predição de valor geralmente são avaliados por meio de parâmetros da análise de regressão linear e de erro entre o valor predito e o valor medido. Entre os parâmetros e erros destacam-se o coeficiente de determinação ( $R^2$ ), coeficiente de correlação de *Pearson* ( $r$ ) e raiz do erro médio quadrático (REMQ).

Os modelos de predição de classificação são avaliados utilizando parâmetros das matrizes de confusão que confronta a classificação real com a classificação predita. A Tabela 1 apresenta um exemplo de matriz confusão com duas classes.

Tabela 1 - Exemplo de matriz confusão com 2 classes

		Classificação Predita	
		Sim	Não
Classificação Medida	Sim	VP	FN
	Não	FP	VN

Fonte: Própria autoria.

A partir da matriz confusão é possível extrair os seguintes parâmetros:

- VP – Verdadeiros positivos: quantidade de classificações corretas que foram preditas na classe ‘Sim’;
- VN – Verdadeiros negativos: quantidade de classificações corretas que foram preditas na classe ‘Não’;
- FP – Falsos positivos: quantidade de classificações incorretas que foram preditas na classe ‘Sim’;
- FN – Falsos negativos: quantidade de classificações incorretas que foram classificadas na classe ‘Não’.

Os valores obtidos destes parâmetros são utilizados para determinar as seguintes métricas de desempenho para os modelos de classificação (KOTU; DESHPANDE, 2015):

- Acurácia  $[(VP+VN)/(VP+VN+FP+FN)]$ : indica a performance geral do classificador (quantidade de acertos em relação ao total de dados);

- Precisão  $[VP/(VP+FP)]$ : indica a quantidade de acertos do modelo na classe ‘Sim’ em relação ao total de acertos do modelo;
- Sensibilidade  $[VP/(VP+FN)]$ : indica a quantidade de acertos na classe ‘Sim’ em relação ao total de valores que foram classificados (classificação real) na classe ‘Sim’;

O uso de ferramenta de IA em sistema de suporte a decisão ainda é um desafio na área de produção animal. Porém, é crescente o número de trabalhos de pesquisa que buscam implementar tais ferramentas para analisar e modelar a resposta de sistemas biológicos, inclusive na produção animal. Um estudo sobre um sistema automatizado de coleta de TIVs de bezerras foi realizado por Lowe et al. (2020), buscando validar um algoritmo capaz de detectar e analisar de forma automática as regiões do olho e da bochecha dos animais, obtendo as temperaturas máximas destas regiões e da imagem completa. A validação do algoritmo foi realizada pela comparação com a análise manual das imagens. O algoritmo apresentou uma correlação com as análises manuais de 1,0, 0,99, 0,85 e 0,9 para as temperaturas máximas da imagem completa, do olho, da bochecha (recorte 3x3) e da bochecha (recorte 9x9) respectivamente.

Joy et al. (2021) realizou um trabalho com ovelhas e propôs o uso de TIV associado a aprendizado de máquina para a predição da temperatura retal (variável associada ao estresse térmico). Joy et al. (2021) utilizaram TIVs da região da cabeça (testa, olhos e narina) dos animais por ser uma área de menor cobertura de lã. Foram desenvolvidos modelos baseados em RNA e os autores obtiveram como melhor resultado um coeficiente de correlação de 0,92 entre valores medidos manualmente e valores preditos pelo modelo.

Cinco modelos diferentes para predição do estresse térmico de bovinos de corte foram construídos e avaliados por Brown-Brandl et al. (2005): dois modelos estatísticos, dois sistemas de inferência por lógica Fuzzy (LF) e um modelo preditivo baseado em RNA. Foram utilizados como entradas (atributos precursores) variáveis meteorológicas (temperatura de bulbo seco, temperatura de ponto de orvalho, radiação solar e velocidade do vento), a raça e a temperatura de superfície da região da costela medida com pirômetro. O modelo baseado em RNA apresentou os melhores resultados, sendo utilizado para predição da frequência respiratória (atributo meta).

Técnicas para modelar as respostas fisiológicas (temperatura retal e frequência respiratória) de vacas leiteiras Holstein foram avaliadas por Hernández-Julio et al. (2014). Foram utilizados como entradas somente os dados climáticos de temperatura e umidade

do ar. O modelo baseado em RNA mostrou o melhor desempenho na estimativa das variáveis fisiológicas, seguido pelos modelos baseados em redes neuro-fuzzy e regressão.

Classificadores de estresse térmico para bovino de corte confinados baseados em modelos gerados com LF e RNA foram propostos por Sousa et al. (2016) e Sousa et al. (2018) respectivamente. Nesses trabalhos foram utilizados como entradas a temperatura de bulbo seco, a temperatura de bulbo úmido e a TIV da frente de bovinos Nelores. Os modelos resultaram em melhores previsões do nível de estresse térmico quando comparado a um ITU tradicional e aos modelos baseados em LF e RNA desenvolvidos por outros autores. A maior acurácia de classificação (94,35%) foi obtida por Sousa et al. (2018) utilizando modelo baseado em RNA.

Quatro algoritmos de aprendizado de máquina diferentes foram avaliados por Gorczyca et al. (2018) para previsão de variáveis associadas ao nível de estresse térmico em leitões utilizando dados ambientais como entrada dos modelos. Dos modelos testados as redes neurais profundas obtiveram o melhor desempenho na previsão da TR. O modelo baseado em florestas randômicas obteve o melhor resultado na previsão da temperatura de superfície de pelagem.

Não foram encontrados trabalhos de pesquisa que utilizem o aprendizado de máquina na produção de bezerras, fato que reforça a contribuição do presente trabalho nesta área.

Os trabalhos citados evidenciam o potencial do uso do aprendizado de máquina na produção animal, em especial para a previsão de nível de estresse térmico. É possível inferir ainda que há espaço para explorar novas ferramentas de IA (testando diferentes algoritmos de aprendizado de máquina) buscando obter e refinar modelos classificadores de estresse térmico. Diante disto o projeto propôs o desenvolvimento de modelos baseados em aprendizado de máquina para previsão de nível de estresse térmico animal, testando quatro classes de algoritmos de aprendizado de máquina diferentes associado proposição de uma metodologia inovadora de extração de características de dados de TIV (usadas como entrada dos modelos) obtidos em experimento realizado em câmara climática.

#### **4. Material e Métodos**

Buscando-se cumprir com os objetivos propostos, o presente estudo conta com quatro etapas: etapa experimental, extração de características de dados de TIV, análise

estatística para subsidiar a modelagem e construção e avaliação de modelos baseados em aprendizagem de máquina. A metodologia desenvolvida no projeto é descrita nos itens seguintes.

#### **4.1 Delineamento experimental e aquisição de dados**

O experimento foi realizado na Faculdade de Zootecnia e Engenharia de Alimentos (FZEA), Campus Fernando Costa da Universidade de São Paulo (USP), em Pirassununga – SP, localizada a 21° 59' 46" S 47° 25' 33" W e altitude aproximada de 627 metros. A cidade possui temperatura e precipitação médias de 21,5°C e 1395 mm, respectivamente, apresentando verão chuvoso e inverno seco. O trabalho apresenta aprovação no CEUA (comitê de ética no uso dos animais) com o protocolo: 6957201219 (ID 001415). A coleta de dados foi realizada na Câmara Climática do Departamento de Reprodução Animal (VRA), pertencente à Faculdade de Medicina Veterinária e Zootecnia da Universidade de São Paulo (FMVZ - USP), no período de 01/09/2020 a 15/10/2020.

A coleta de dados foi realizada a partir do confinamento de 10 bezerras desmamadas da raça Holandesa, puras de origem, com peso médio entre 120 e 140 Kg, pertencentes ao rebanho do setor de gado leiteiro da Prefeitura do Campus Fernando Costa. A instalação (câmara climática) na qual os animais ficaram alojados apresenta piso de concreto, cochos de alimentação e bebedouros. Durante o período de confinamento os cochos eram abastecidos duas vezes ao dia (7 e 15 horas), e os bebedouros repostos sempre que necessário (com acesso *ad libitum*). A alimentação dos animais era composta por feno, silagem e mistura concentrada, sendo ajustadas semanalmente com base em pontuações diárias de consumo.

Devido a capacidade da câmara climática, o experimento foi realizado com a divisão do grupo de animais em dois subgrupos de 5 animais cada. Cada subgrupo foi submetido a período de adaptação fora e dentro da câmara climática antes de iniciar o período de controle de temperatura. Os animais foram expostos a duas ondas de calor com intervalo de recuperação entre as duas ondas. Durante os períodos das ondas de calor foram coletadas as seguintes variáveis fisiológicas dos animais: frequência respiratória (FR), temperatura retal (TR) e termografia de infravermelho (TIV). Além da mensuração dos dados fisiológicos dos animais, registrou-se também dados meteorológicos de temperatura de bulbo seco (TBS, °C), umidade relativa (UR, %) e entalpia (H, kJ/kg).

#### 4.1.1 Tratamentos

Antes da realização do experimento para coleta de dados, estabeleceu-se um contato prévio com os animais, por meio de fornecimento de alimentos e escovação dos pelos, com o objetivo de reduzir a interferência humana causada pelo contato da equipe do experimento com as bezerras durante a coleta de dados.

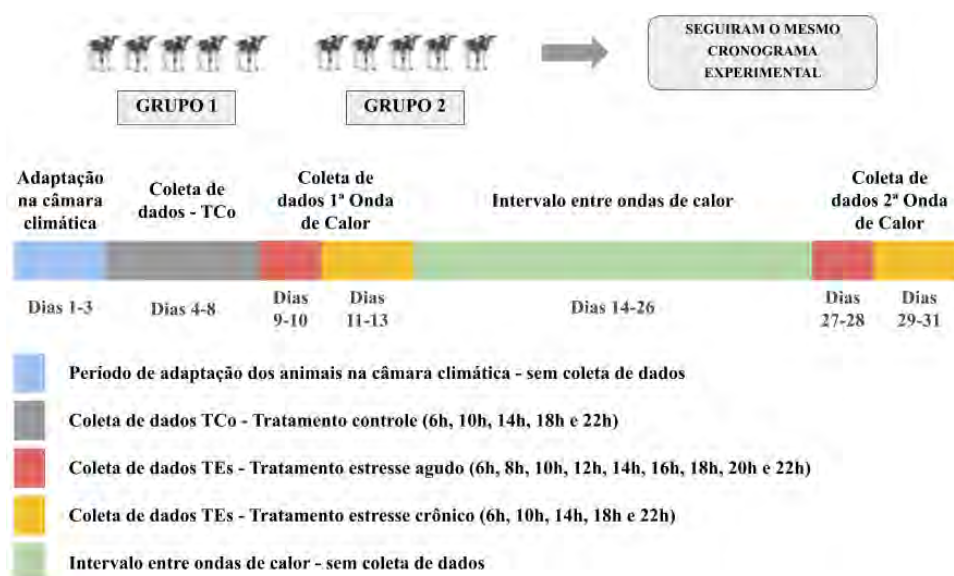
O experimento foi desenvolvido utilizando 3 tratamentos diferentes, para avaliação das respostas fisiológicas das bezerras em diferentes condições de estresse térmico. Foram realizados os seguintes tratamentos:

- Tratamento Controle (TCo) - Temperatura Ambiente: realizado no período inicial de 5 dias (após o período de adaptação de 3 dias dos animais na câmara climática).
- Tratamentos Estresse Agudo e Crônico (TEs agudo e TEs crônico) - Ambiente estressante: realizados simulando ondas de calor, com temperatura variando entre 30°C e 35,7°C no período de 10 horas às 15 horas. Foram considerados 2 dias como TEs agudo e 3 dias como TEs crônico, obtendo assim um período total de 5 dias para cada onda de calor.

Segundo o Painel Intergovernamental sobre mudanças climáticas (*Intergovernmental Panel on Climate Change – IPCC, 2001*), a onda de calor pode ser caracterizada como um período de 5 ou mais dias consecutivos em que a temperatura diária do ar excede em 5 °C ou mais a temperatura média do ar para o período.

Nos tratamentos TEs agudo e crônico as temperaturas das ondas de calor foram determinadas com base em dados climáticos da região de Pirassununga-SP (onde foi desenvolvido o experimento) no período de 1980 a 2013, de acordo com o levantamento de Xavier et al. (2015). As ondas de calor foram simuladas por meio de um aumento gradual da temperatura com ajuste inicial em 30 °C a partir das 10 horas. Posteriormente, ajustou-se o controlador para a temperatura de 32 °C às 12 horas e 35,7 °C às 14 horas, permanecendo neste último ajuste de temperatura até as 15 horas. Após às 15 horas, o controle climático era desativado e a temperatura normalmente reduzia gradualmente a um ponto de equilíbrio natural do ambiente até início do processo novamente às 10 horas do dia seguinte. A Figura 5 apresenta a linha de tempo utilizada para realizar a etapa experimental do projeto.

Figura 5 - Linha do tempo período experimental



Fonte: Própria autoria.

O experimento foi realizado de acordo com o seguinte cronograma:

*Dia 01/09 a 03/09:* Adaptação dos animais do 1º grupo. As 5 bezerras permaneceram na instalação em temperatura ambiente.

*Dia 04/09 a 08/09:* Avaliação dos animais (n=5) em condições de temperatura ambiente.

*Dia 09/09 a 13/09:* Ocorrência da 1ª onda de calor para o 1º grupo de animais, de acordo com a metodologia descrita anteriormente.

*Dia 14/09:* Intervalo de 13 dias para o primeiro grupo de animais. Os animais foram transportados para o piquete do setor do gado leiteiro (local de origem dos animais). E o 2º grupo de 5 bezerras foi transportado até a câmara climática para coleta de dados.

*Dia 14/09 a 16/09:* Adaptação dos animais do 2º grupo. As 5 bezerras permaneceram na instalação em temperatura ambiente.

*Dia 17/09 a 21/09:* Avaliação dos animais (n=5) em temperatura ambiente.

*Dia 22/09 a 26/09:* Ocorrência da 1ª onda de calor para o 2º grupo de animais.

*Dia 27/09:* Intervalo de 13 dias para o segundo grupo de animais. Os animais foram transportados até o piquete do setor gado leiteiro. E o 1º grupo de animais foi transportado até a câmara climática para darem início às avaliações da 2ª onda de calor.

*Dia 28/09 a 02/10:* Ocorrência da 2ª onda de calor para o 1º grupo de animais.

*Dia 03/10:* Devolução do 1º grupo de animais ao piquete do setor gado leiteiro.

*Dia 10/10:* Transporte do 2º grupo de animais até a câmara climática para darem início à ocorrência da 2º onda de calor.

*Dia 11/10 a 15/10:* Ocorrência da 2º onda de calor para o 2º grupo de animais.

*Dia 16/10:* Devolução do 2º grupo de animais ao piquete do setor gado leiteiro e finalização do período experimental.

A câmara climática (sistema *Tie Stall*), Figura 6, apresenta área total de 60 m<sup>2</sup> (12m<sup>2</sup>/animal), com piso de concreto e 3 m de pé direito. A instalação apresenta 6 divisões (1,0 m x 1,8 m) com cochos e bebedouros individuais. Os animais foram amarrados nas baias dentro da câmara climática com a possibilidade de deslocamento linear no sentido da baia. Com o objetivo de melhorar o conforto dos animais e manejo sanitário da instalação, o piso foi forrado com cama de feno com altura de aproximadamente 10 cm.

Figura 6 - Câmara climática



Fonte: Própria autoria.

A câmara climática conta com termostatos internos, 4 ventiladores localizados nos cantos da câmara climática e 1 exaustor controlados por um painel elétrico e de comando externo, permitindo ao pesquisador a configuração da temperatura no interior da instalação, de acordo com os objetivos da pesquisa.


#### 4.1.2 Dados do ambiente

O monitoramento do microclima da instalação foi realizado por meio de um coletor de dados (*data logger*), da marca HOBO, modelo U12-012, instalado no centro da câmara climática. Este equipamento realizou a medição e armazenamento automático de TBS, UR e H, durante todo o experimento, 24 horas por dia, a cada 15 minutos. Utilizou-se também um termo-higrômetro para acompanhamento da temperatura e umidade durante o experimento.

#### 4.1.3 Dados dos animais

A coleta de dados fisiológicos foi realizada por meio da medição da TR, FR e TIV. A TR foi medida com um termômetro clínico digital inserido no reto do animal conforme a Figura 7. A FR foi medida pela contagem de tempo a cada dez movimentos do flanco, utilizando um cronômetro, sendo calculado posteriormente o número de movimentos por minuto.

Figura 7 - Mensuração da temperatura retal




Fonte: Própria autoria.

A TIV foi obtida com câmera TESTO 875-2 com projeção perpendicular ao animal e emissividade configurada em 0,98. Foram obtidas TIVs das seguintes regiões corporais: cabeça (fronte, face, orelha e olho), costela e flanco, que estão destacadas na Figura 8. Tais medidas foram realizadas em todos os animais (n=10) durante os tratamentos TCo e TEs crônico 5 vezes ao dia (6, 10, 14, 18 e 22 horas) e durante o tratamento TEs agudo 9 vezes ao dia (6, 8, 10, 12, 14, 16, 18, 20 e 22 horas).



Figura 8 - Regiões da superfície corporal que foram obtidos de termografia de infravermelho: frente (verde), área ocular (vermelho), orelha (roxo), costela (amarelo) e flanco (azul).



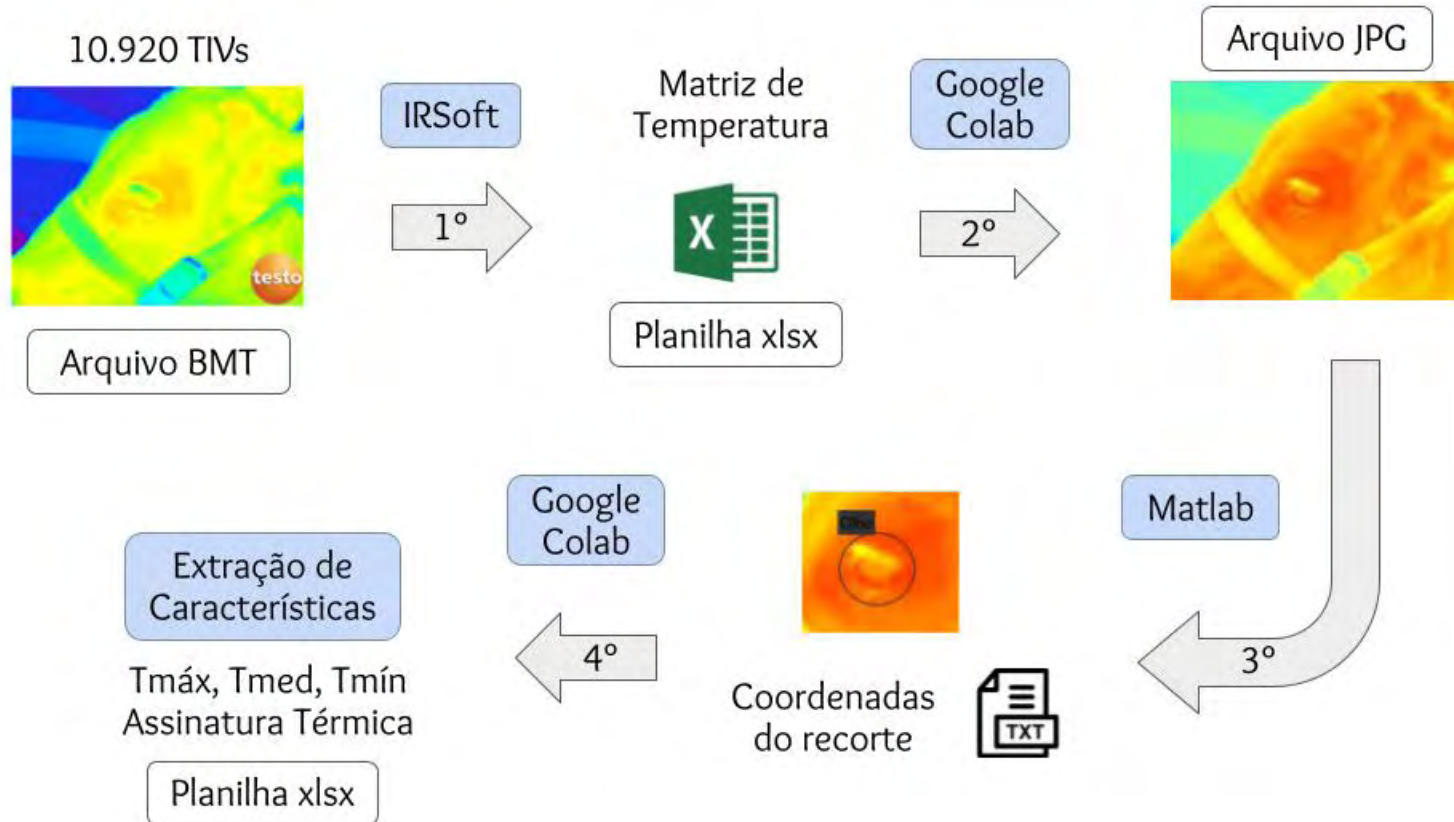
Fonte: Própria autoria.

Os dados de TIV foram armazenados inicialmente no equipamento durante cada dia de coleta, sendo ao final transferidas para um computador. Para cada região de dados de TIV foi definida uma subárea para ser utilizada para se extrair tanto os valores de temperatura média, máxima e mínima, assim como a matriz de temperatura, com o uso do software TESTO IRsoft.

#### 4.2 Extração de características - Assinatura Térmica

A Assinatura Térmica é um conjunto de características extraídas da matriz de dados de TIV para cada região de coleta. A metodologia de extração de características e sua aplicação em modelos de predição foram desenvolvidos pelo Grupo de Robótica e Automação para Engenharia de Biosistemas (RAEB) e é sistematizado e avaliado neste trabalho. Para a obtenção das Assinaturas Térmicas é necessário realizar um processamento de cada matriz de dados TIV, que são recortadas de acordo com a região do animal. A Figura 9 apresenta um diagrama de processamento das TIVs para obtenção da Assinatura Térmica e das temperaturas média, máxima e mínima, utilizando como referência a TIV da região do olho do animal.

Figura 9 - Etapas para extração de características das matrizes de dados da termografia de infravermelho



Fonte: Própria autoria.

Conforme a Figura 9 o processamento dos dados das TIVs foi realizado em 4 etapas:

1. Utilizando-se o software IRSoft obteve-se matrizes de temperatura (arquivos tipo ‘csv’) a partir das TIVs coletadas. Cada arquivo ‘csv’ pode ser aberto em um software editor de planilhas (ex. Microsoft Excel), sendo que cada célula da planilha corresponde a um pixel da imagem observada no IRSoft;
2. Com o auxílio da plataforma *web* Google Colab, desenvolveu-se um script para criar imagens visíveis a partir das matrizes de temperatura (cada célula da matriz corresponde a um pixel colorizado conforme escala adequada para visualização humana), para se obter uma imagem em escala de cores definida e permitir o recorte das regiões de interesse;
3. Foi desenvolvido outro script utilizando o software Matlab 2015b (Mathworks Inc., USA) para realizar o recorte e rotulagem das áreas de interesse. Após o processo de recorte, o script gera um arquivo (formato txt) com as coordenadas referentes aos recortes que possui correspondência com a respectiva matriz de temperatura;
4. Para esta etapa foi desenvolvido um último script no Google Colab para a extração de características dos recortes selecionados na etapa anterior. O script realiza a leitura do arquivo txt (com coordenadas do recorte), associa essa informação com a matrizes de temperatura correspondentes e extrai de cada uma delas as temperaturas média, máxima e mínima das TIVs e a Assinatura Térmica.

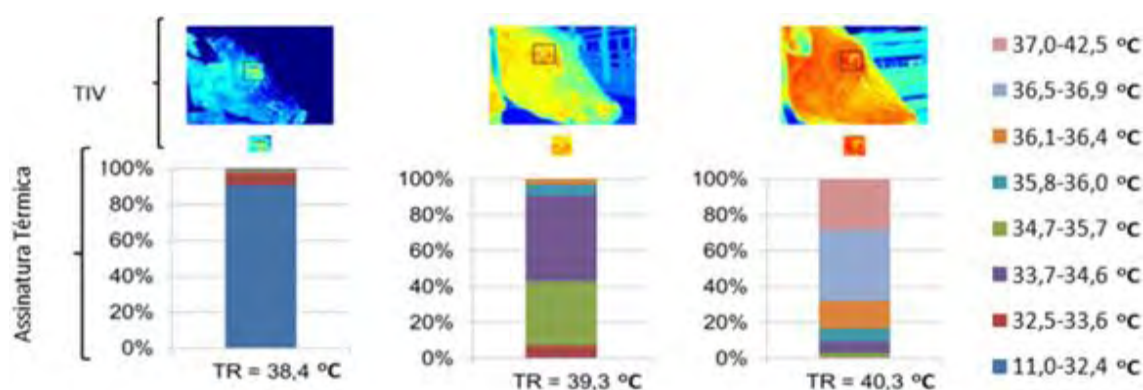
Observa-se que as etapas 3 e 4 são simplesmente a criação e utilização de um aplicativo prático para visualizar as matrizes de dados de TIV como uma imagem e permitir selecionar regiões de interesse em cada uma delas. O principal resultado dessas quatro etapas é que as matrizes de dados brutos de TIV obtidas com a câmera são analisadas manualmente e geram-se os recortes das regiões de interesse dessas matrizes. De cada um dos recortes é que se extraem os valores de temperatura (média, máxima e mínima) e a Assinatura Térmica.

Para a obtenção da Assinatura Térmica o algoritmo desenvolvido na etapa 4 realiza a contabilização da soma do número de células de todas as matrizes e a distribuição dessas temperaturas em faixas, para ter um banco de dados homogêneo (com números semelhantes de células por faixa de temperatura). Este processo gera valores de faixas assimétricas para realizar o agrupamento em números semelhantes de células de

temperatura por faixa, encontradas em cada imagem. São construídos vetores característicos, denominados ‘Assinatura Térmica’, com um determinado número de faixas e estes vetores são utilizados como entradas de modelos preditivos de TR e FR (variáveis relacionadas ao nível de estresse térmico animal).

A Figura 10 apresenta três exemplos dos vetores de Assinatura Térmica representados em gráficos de barra com agrupamento em 8 faixas obtidas a partir da aplicação da metodologia descrita em recortes da região ocular da face do animal. O exemplo conta com dados de TIV de animais expostos a diferentes condições de estresse térmico conforme explicitado pela correspondente TR. As 8 faixas de temperatura utilizadas para a obtenção das assinaturas térmicas estão especificadas na legenda mais à direita da Figura 10.

Figura 10 - Exemplos de Assinaturas Térmicas extraída de matrizes de dados de TIV do olho para diferentes condições de estresse térmico dos bovinos de leite.



\*Dados fisiológicos: (TIV) termografias de infravermelho; (TR) temperatura retal.

Fonte: Própria autoria.

O método de obtenção da Assinatura Térmica e sua aplicação em modelos baseados em RNA constitui-se um método inovador apresentado de forma oral pelo aluno no evento V Workshop Internacional de Ambiência de Precisão (Rodrigues et al., 2019).

### 4.3 Análises Estatísticas

Após o processamento das imagens termográficas, todos os dados foram tabulados, e as variáveis meteorológicas (TBS, UR e H) e fisiológicas (TR e FR) foram alocadas nas colunas em planilha de dados. Os dados extraídos dos dados de TIV (temperaturas mínima, máxima e média e a assinatura térmica) também foram registrados em planilha (cada faixa da assinatura térmica correspondeu a uma coluna) junto com a

informação do número do animal (identificação) e dia e horário de coleta. Esta planilha foi utilizada para as etapas de análise estatística e modelagem computacional.

Antes das construções dos modelos realizou-se análise estatística baseada em indicadores de associação (coeficiente de correlação) para identificar a relação entre as variáveis envolvidas, e nortear a seleção de variáveis para a etapa de modelagem. A análise estatística foi realizada utilizando o software SAS® 9.3 (SAS Institute Inc., Cary, NC, USA).

#### **4.4 Desenvolvimento dos modelos**

Este tópico apresenta de maneira detalhada a metodologia utilizada para o desenvolvimento dos modelos classificadores de nível de estresse térmico animal baseados em aprendizado de máquina.

##### **4.4.1 Estrutura dos modelos**

Depois que os dados foram coletados e analisados, os modelos foram construídos, programados, simulados e confrontados. A Figura 11 ilustra em forma de diagrama a metodologia utilizada no desenvolvimento dos modelos classificadores. Neste diagrama pode-se observar que os atributos previsores (atributos de entrada) são compostos pelas características extraídas das TIVs (assinatura térmica e temperaturas de superfície) e variáveis meteorológicas. O atributo meta (atributo de saída) dos modelos é a classificação de nível de estresse térmico baseada em valores de FR e TR encontrados na literatura. Os modelos foram então desenvolvidos a partir destes dados de entrada e de saída, os quais encontram-se registrados em planilha eletrônica. Neste processo foram realizados o treinamento, validação e teste dos modelos.

Figura 11 - Diagrama ilustrativo da modelagem



\*Dados fisiológicos: (TIV) dados extraídos das termografias de infravermelho; (FR) frequência respiratória; (TR) temperatura retal.

Fonte: Própria autoria.

A modelagem baseada em métodos de aprendizado supervisionado foi desenvolvida com o software Weka (2020). O software permite carregar os dados da planilha e selecionar os atributos previsores (variáveis meteorológicas e variáveis extraídas da termografia de infravermelho) e a atributo meta (classificação de estresse térmico baseada em valores de TR e FR). Para construção e teste de comparação dos modelos foi aplicado o protocolo de validação cruzada com dados selecionados de forma aleatória. Foram construídos modelos para predição de nível de estresse térmico baseados nos algoritmos de aprendizado de máquina: floresta randômica - FLR, máquinas de vetores de suporte - SVM, redes neurais artificiais - RNA e K-vizinhos mais próximos - KNN. Foram avaliados conjuntos com diferentes combinações de entrada de dados de TIV, Assinatura Térmica e de variáveis meteorológicas, tendo como atributo meta a classificação de estresse térmico em níveis (normal, alerta e perigo) baseada nas variáveis fisiológicas de TR e FR.

#### 4.4.2 Execução da modelagem

A execução da modelagem proposta no projeto foi desenvolvida em 3 etapas buscando a obtenção dos melhores resultados. Em cada etapa o conjunto de entradas dos modelos e os hiperparâmetros dos algoritmos foram simulados com diferentes combinações para sua otimização. Os hiperparâmetros são parâmetros ajustáveis dos algoritmos de aprendizado de máquina que compõem os modelos computacionais. O

objetivo do ajuste dos hiperparâmetros é a busca por modelos que apresentem melhor desempenho. As entradas exploradas foram a TBS, a UR, a H, as temperaturas mínima, máxima e média dos dados de TIVs e diferentes números de faixas de Assinatura Térmica.

Todas as modelagens foram realizadas para obter a classificação de nível de estresse tendo como referência os valores de FR (2 e 3 classes de estresse térmico) e TR (2 classes de estresse térmico), de acordo com valores encontrados na literatura (ROBINSON, 1999) como ilustra a Tabela 2.

Tabela 2 - Classificação em níveis de estresse térmico animal

Níveis de Estresse Térmico	FR-3-Classes (mov/min)	FR-2-Classes (mov/min)	TR-2-Classes (°C)
<b>Conforto</b>	FR < 50	FR < 50	TR ≤ 39,3
<b>Alerta</b>	50 ≤ FR ≤ 65		
<b>Perigo</b>	FR > 65	FR ≥ 50	TR > 39,3

\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal.

\*Parâmetros: (Classes): número de classes utilizadas na classificação de nível de estresse térmico.

Fonte: Própria autoria.

O presente trabalho tem como um dos resultados finais a geração de 3 classificadores de estresse térmico: FR-3-Classes, FR-2-Classes e TR-2-Classes. O FR-3-Classes utiliza como referência interna as faixas de classificação da FR em 3 níveis de estresse térmico conforme a Tabela 2 (Conforto, Alerta e Perigo). Os classificadores FR-2-Classes e TR-2-Classes são classificadores ditos binários, pois terão como saída duas classes de nível de estresse, sendo que o classificador FR-2-Classes utiliza como referência interna as faixas de classificação da FR em 2 níveis de estresse térmico (conforto e Perigo) conforme a Tabela 2, e o classificador TR-2-Classes utiliza como referência interna as faixas de classificação da TR em 2 níveis de estresse térmico (Conforto e Perigo) conforme a Tabela 2. Observa-se que os valores de FR e TR são utilizados apenas para construção dos modelos para associar cada registro (conjunto de entradas) à um rótulo de classe. Quando construídos, os classificadores apenas utilizam os dados de TIV e meteorológicos para prever o nível de estresse individualmente de cada animal submetido a uma inspeção.

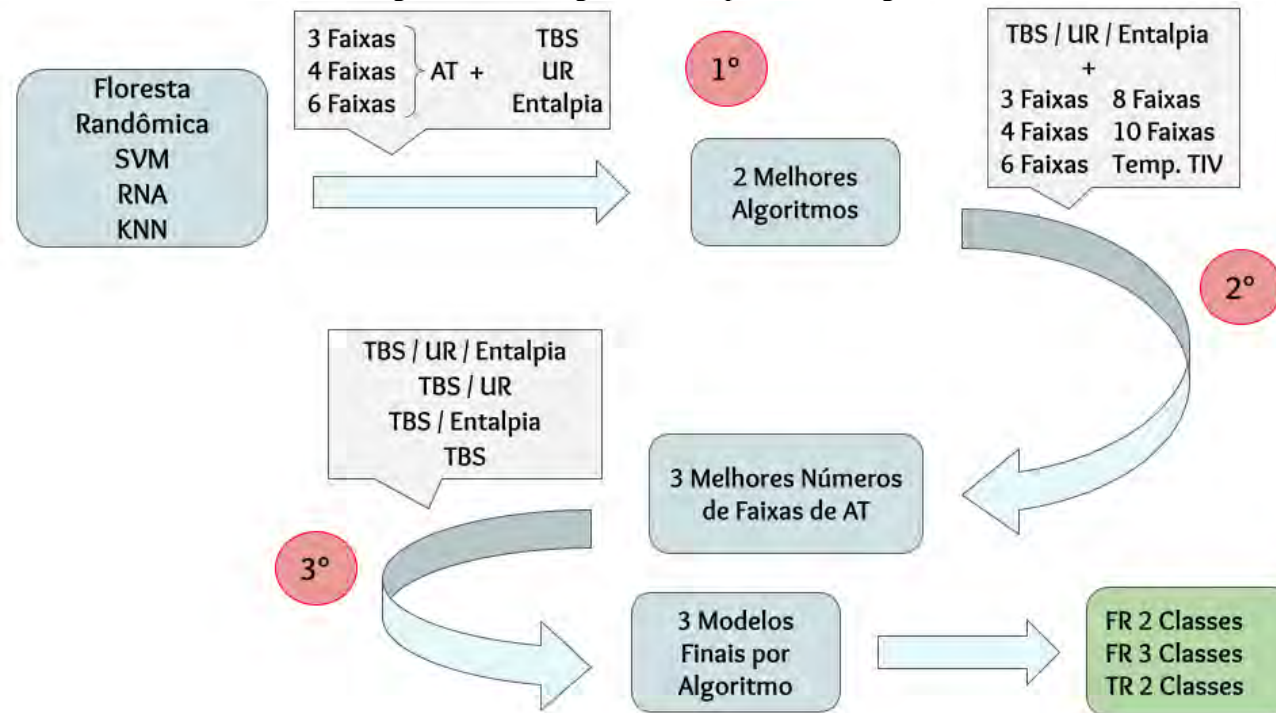
Os melhor classificador de cada tipo (FR-3-Classes, FR-2-Classes e TR-2-Classes) será obtidos através de uma sequência de simulações (Figura 12) onde se busca ter em conjunto ótimo para os seguintes parâmetros: tipo algoritmo de aprendizado supervisionado e melhores conjuntos de hiperparâmetros e de entradas para o tipo de

algoritmo identificado. A Figura 12 ilustra as 3 etapas construção dos modelos que são descritas a seguir:

1. Etapa 1: avalia-se como entrada 3 conjuntos de vetores de Assinatura Térmica com números diferentes de faixas de temperatura (3, 4 e 6 faixas) combinados com as variáveis meteorológicas (TBS, UR e entalpia) para a obtenção dos melhores modelos classificadores de estresse térmico. Esta etapa é executada com todos os algoritmos propostos no trabalho (FLR, SVM, RNA e KNN). Ao final da avaliação são selecionados os 2 melhores algoritmos para as próximas etapas;
2. Etapa 2: os dois melhores algoritmos da etapa anterior são utilizados para a geração de novos modelos classificadores. Nesta etapa varia-se o número de faixas de Assinatura Térmica (3, 4, 6, 8 e 10 faixas), incluindo-se também a não utilização da Assinatura Térmica ('0 Faixas'), sendo esta substituída pela utilização da forma convencional com valores pontuais de temperaturas obtidas das TIVs (temperaturas máxima, média e mínima). Além disso, os diferentes grupos de entradas de dados de TIV são associados às variáveis meteorológicas (TBS, UR e H). Os 3 melhores classificadores com o respectivo número de faixas de Assinatura Térmica e os melhores algoritmos de aprendizado de máquina, segundo a simulação, são selecionados para terceira etapa de modelagem;
3. Utilizando-se os melhores algoritmos e as melhores número de faixas de assinatura térmica obtidos na etapa anterior, os modelos classificadores, são avaliados por simulação, desta vez, com combinações diferentes de variáveis meteorológicas associadas aos dados de TIV selecionados. Foram gerados modelos com a inclusão e exclusão das variáveis de UR e entalpia, de acordo com as combinações apresentadas na terceira etapa da Figura 12.



Figura 12 - Fluxograma da etapa de modelagem



\*Dados meteorológicos: referem-se as dados registrados com *data loggers* instalados na câmara climática: (TBS) temperatura do ar; (UR) umidade relativa do ar.

\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (AT) assinatura térmica; (Temp. TIV); temperaturas máxima, média e mínima extraída das termografias de infravermelho.

\*Parâmetros: (Classes): número de classes utilizadas na classificação de nível de estresse térmico; (Faixas): número de faixas da assinatura térmica.

Fonte: Própria autoria.

## 5. Forma de análise dos modelos

A análise dos modelos classificadores obtidos foi realizada com métricas extraídas da matriz de confusão gerada pela contabilização de acertos e erros de classificação na comparação da classificação predita com classificação obtida a partir da mensuração da FR e TR. São apresentados os seguintes parâmetros extraídos da matriz de confusão: acurácia, precisão e sensibilidade.

De forma a complementar a análise que utiliza parâmetros da matriz de confusão, foi realizada análise de diferença estatística significativa por meio dos testes de Friedman e Nemenyi (PEREIRA; AFONSO; MEDEIROS, 2015). Estes testes são baseados na análise comparativa das acurácias obtidas pelos modelos gerados por cada algoritmo. Estas acurácias dos modelos são comparadas por meio de classificação em ordem crescente das mesmas, ou seja, o modelo com maior acurácia fica em primeiro lugar, seguido pelos demais. A classificação geral do algoritmo se dá pela média das classificações obtidas por todos os modelos gerados pelo mesmo. Deste modo, quanto mais próximo de 1 este valor, melhor classificado o algoritmo vai estar.

Nesta análise realiza-se inicialmente o teste de Friedman que, quando resulta em um valor próximo a 0 indica que os algoritmos obtiveram desempenhos diferentes, fato observado de acordo com a acurácia dos modelos gerados. A segunda etapa desta análise é o teste de Nemenyi, que por meio do cálculo de um parâmetro denominado distância crítica (critical distance - CD) determina se há diferença estatisticamente significativa entre os algoritmos avaliados. Esta diferença é observada quando a diferença entre as classificações dos algoritmos (obtidas a partir da média das classificações dos modelos) é maior que a distância crítica.

A análise dos resultados do projeto busca evidenciar não só as melhores técnicas e parâmetros computacionais para construção dos modelos, mas também evidenciar o potencial do uso de experimento com câmara climática para gerar uma base de dados mais homogênea e de forma mais rápida em relação a técnicas baseadas em experimento realizado em ambiente aberto.

## 6. Resultados

Neste item serão abordados os resultados obtidos durante a execução projeto. Os resultados foram divididos em análise estatística e modelos obtidos.

## 6.1 Análise estatística

Os resultados da análise estatística abordados neste item nortearam a etapa de modelagem. Foi possível observar o comportamento das variáveis fisiológicas e meteorológicas e suas associações. A Tabela 3 apresenta a estatística descritiva dos dados fisiológicos e meteorológicos coletados na etapa experimental. É possível notar, conforme os valores máximos e mínimos das variáveis fisiológicas, que a câmara climática permitiu a obtenção de dados em diversas condições de nível de estresse térmico animal. A TR máxima de 41°C mostra que houve períodos em que os animais apresentaram estresse térmico elevado, uma vez que a literatura apresenta uma TR limite de conforto térmico para bezerros de 39,3°C (Tabela 2). No mesmo sentido, observa-se na Tabela 3 valores elevados de FR tanto para o valor médio (58,4 mov/min), como para o valor máximo (151,5 mov/min) que estão acima do limiar indicativo de conforto térmico de 50 mov/min (Tabela 2).

Tabela 3 - Estatística descritiva dos dados fisiológicos e meteorológicos

	Variável		Média ±	Mínimo	Máximo	
			Desvio Padrão			
Dados Fisiológicos	FR (mov/min)		58,4 ± 19	23,4	151,5	
	TR (°C)		39,2 ± 0,5	37,7	41,0	
	TIVOI (°C)	Max		37,1 ± 0,8	34,6	39,4
		Med		34,4 ± 1,3	30,1	37,4
		Min		32,6 ± 1,8	27,5	36,5
	TIVFron (°C)	Max		30,7 ± 2,4	23,5	36,0
		Med		37,1 ± 1,2	27,3	39,8
		Min		36,2 ± 1,3	26,7	38,8
	TIVOre (°C)	Max		34,9 ± 1,7	25,8	38,3
		Med		34,3 ± 1,6	29,5	39,0
		Min		33,2 ± 1,7	28,2	38,1
	TIVCos (°C)	Max		32 ± 2	25,4	37,4
Med			34,6 ± 1,5	30,1	38,6	
Min			33,5 ± 1,6	27,6	37,8	
TIVFlan (°C)	Max		32 ± 1,9	24,0	36,9	
	Med		28,5 ± 3,4	21,6	35,9	
	Min		52,4 ± 10,7	31,3	80,3	
Dados Meteorológicos	TBS (°C)		63,4 ± 7,3	47,1	84,2	
	UR (%)					
	Entapia (kJ/kg)					

\*Dados meteorológicos: referem-se as dados registrados com *data loggers* instalados na câmara climática: (TBS) temperatura média do ar; (UR) umidade relativa do ar.

\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (TIVFron): temperatura de superfície da frente dos animais obtidas com técnica de termografia e infravermelho; (TIVOI): temperatura de superfície da região ocular dos animais obtidas com técnica de termografia e infravermelho; (TIVOre): temperatura de superfície da orelha dos animais obtidas com técnica de termografia e infravermelho; (TIVFlan): temperatura de superfície do flanco dos

animais obtidas com técnica de termografia e infravermelho; (TIVCos): temperatura de superfície da costela dos animais obtidas com técnica de termografia e infravermelho.

\*Parâmetros: (Méd) média; (Min) mínima; (Max) máxima.

Fonte: Própria autoria.

A Tabela 4 apresenta as correlações entre as variáveis fisiológicas e as temperaturas máxima, média e mínima extraídas das TIVs obtidas do olho, frente, orelha, costela e flanco. Buscando-se refinar a seleção de dados para etapa de modelagem foram obtidas também as correlações entre essas variáveis nos dois períodos de onda de calor. De acordo com os resultados é possível notar que as temperaturas TIVOI<sub>Max</sub> e TIVORE<sub>Med</sub> obtiveram maior correlação com a FR e a TR com valores de 0,48 e 0,55, respectivamente, para a base de dados geral (todos os dados do experimento). Nota-se também que os dados de TIV obtidos na 2ª onda de calor possuem maior correlação com FR e TR, com valores de correlação de 0,63 entre TR e TIVOI<sub>Max</sub> e 0,58 entre FR e TIVORE<sub>Min</sub>. As menores correlações de FR e TR são observadas na base de dados da 1ª onda de calor com a temperatura mínima da região da frente dos animais, apresentando valores de 0,23 e 0,18, respectivamente.

Tabela 4 - Correlações entre variáveis fisiológicas

		TIVOI			TIVFron			TIVORE			TIVCos			TIVFlan		
		Max	Max	Med	Min	Max	Med	Min	Max	Med	Min	Max	Med	Min		
<b>Geral</b>	<b>FR</b>	0,48	0,36	0,38	0,33	0,38	0,46	0,50	0,45	0,46	0,41	0,39	0,41	0,38		
	<b>TR</b>	0,55	0,38	0,35	0,26	0,49	0,48	0,43	0,39	0,36	0,31	0,39	0,36	0,29		
<b>1ª Onda</b>	<b>FR</b>	0,37	0,27	0,31	0,23	0,28	0,39	0,46	0,32	0,35	0,34	0,23	0,29	0,30		
	<b>TR</b>	0,46	0,31	0,28	0,18	0,43	0,43	0,39	0,29	0,27	0,23	0,30	0,29	0,24		
<b>2ª Onda</b>	<b>FR</b>	0,54	0,42	0,44	0,39	0,45	0,54	0,58	0,49	0,50	0,45	0,46	0,47	0,43		
	<b>TR</b>	0,63	0,43	0,40	0,33	0,55	0,54	0,47	0,45	0,42	0,36	0,45	0,41	0,33		

\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (TIVFron): temperatura de superfície da frente dos animais obtidas com técnica de termografia e infravermelho; (TIVOI): temperatura de superfície da região ocular dos animais obtidas com técnica de termografia e infravermelho; (TIVORE): temperatura de superfície da orelha dos animais obtidas com técnica de termografia e infravermelho; (TIVFlan): temperatura de superfície do flanco dos animais obtidas com técnica de termografia e infravermelho; (TIVCos): temperatura de superfície da costela dos animais obtidas com técnica de termografia e infravermelho.

\*Parâmetros: (Méd) média; (Min) mínima; (Max) máxima.

Fonte: Própria autoria.

A Tabela 5 apresenta as correlações entre as variáveis fisiológicas e meteorológicas. Foram obtidas correlações por tratamento (utilizando a base de dados de todo o experimento e, com a base de dados da 1ª onda de calor e da 2ª onda de calor separadamente), com o objetivo de refinar a seleção dos dados para a etapa de modelagem. Assim, na Tabela 5 é possível observar maior correlação entre os dados

obtidos na 2ª onda de calor. Pode-se observar que a maior correlação de 0,40 ocorre entre a FR e a TBS com a base de dados da 2ª onda de calor.

Tabela 5 - Correlação entre variáveis fisiológicas e meteorológicas

		TBS	UR	H
<b>Geral</b>	<b>FR</b>	0,36	-0,26	0,27
	<b>TR</b>	0,27	-0,20	0,22
<b>1ª Onda</b>	<b>FR</b>	0,28	-0,43	-0,02
	<b>TR</b>	0,21	-0,21	0,12
<b>2ª Onda</b>	<b>FR</b>	0,40	-0,20	0,36
	<b>TR</b>	0,32	-0,19	0,25

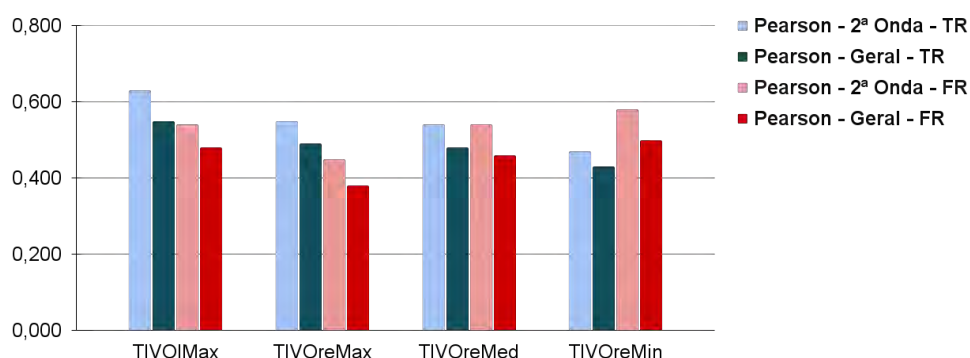
\*Dados meteorológicos: referem-se aos dados registrados com *data loggers* instalados na câmara climática: (TBS) temperatura média do ar; (UR) umidade relativa do ar; (H) entalpia.

\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal.

Fonte: Própria autoria.

A Figura 13 mostra a comparação entre os valores de correlação de FR e TR com as temperaturas extraídas por TIV das regiões do olho e da orelha (regiões melhores correlacionadas com FR e TR de acordo com a Tabela 5). As barras de cor clara representam as correlações obtidas com a base de dados da 2ª onda de calor, enquanto as barras de cor escura representam as correlações com a base de dados geral (dados de todo o experimento). Nesta comparação fica evidente que a base de dados da 2ª onda de calor apresenta maiores correlações entre as TIVs e as variáveis fisiológicas TR e FR, utilizadas como referência para classificação de nível de estresse, em relação a base de dados de todo o experimento.

Figura 13 - Correlação de Pearson



\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (TIVOI): temperatura de superfície da região ocular dos animais obtidas com técnica de termografia e infravermelho; (TIV Ore): temperatura de superfície da orelha dos animais obtidas com técnica de termografia e infravermelho.

\*Parâmetros: (Med) média; (Min) mínima; (Max) máxima.

Fonte: Própria autoria.

Os resultados observados neste item evidenciaram a maior correlação das temperaturas extraídas das TIVs das regiões do olho e da orelha dos animais com as variáveis ligadas ao estresse térmico (TR e FR), além disso a análise por tratamento apontou uma maior correlação das temperaturas das TIVs e das variáveis meteorológicas com a TR e a FR para a base de dados da 2ª onda de calor. Estas análises nortearam a seleção de variáveis e da base de dados para a etapa de modelagem apresentada no item 6.2.

## **6.2 Modelagem**

Neste item são apresentados os resultados obtidos no desenvolvimento da modelagem. Conforme descrito na metodologia, a modelagem foi realizada em 3 etapas, com o objetivo de determinar os algoritmos e suas configurações que resultaram em melhores acurácias de classificação. Deve-se ressaltar que os resultados apresentados nos itens seguintes são a seleção das acurácias dos melhores modelos obtidos em cada etapa da modelagem para cada algoritmo testado, uma vez que foram obtidos 2052 modelos com diferentes variações de hiperparâmetros.

### **6.2.1 Seleção de algoritmo de aprendizado de máquina**

Na primeira etapa da modelagem foram gerados modelos com os 4 algoritmos propostos no projeto (FLR, SVM, RNA e KNN). Nesta etapa (fase inicial da modelagem) foram utilizados os dados obtidos na 2ª onda de calor do experimento, uma vez que estes dados apresentaram maior correlação com as variáveis utilizadas para a classificação de nível de estresse térmico. Foram utilizados também, como atributos previsores (variáveis de entrada) as variáveis meteorológicas (TBS, UR e H), os vetores de Assinaturas Térmicas da região do olho (ATOI) e da orelha (ATOr) com quantidades diferentes de faixas de temperatura (3, 4 e 6 faixas) para a obtenção do atributo meta (variável de saída – classificação de nível de estresse térmico).

A Tabela 6 apresenta os resultados obtidos na primeira etapa da modelagem. A métrica utilizada foi a acurácia dos modelos, que representa o percentual de classificações corretas. É possível observar que os melhores resultados foram obtidos com o algoritmo de FLR com acurácia de 94,1%. Estes modelos foram obtidos com os atributos previsores de TBS, UR, H e ATOI com 4 e 6 faixas para o atributo meta da FR-2-Classes. As melhores acurácias obtidas pelos algoritmos de SVM, RNA e KNN foram de 94,0%, 86,0% e 87,1%, respectivamente, sendo que todos os modelos utilizam como atributos

previsores as variáveis meteorológicas e a Assinatura Térmica da região do olho dos animais. O melhor modelo para a classificação de FR-3-classes obteve acurácia de 80,3%. Para classificação de TR-2-Classes a melhor acurácia obtida foi de 81,7% utilizando o algoritmo SVM.

Tabela 6 - Acurácias dos melhores modelos da primeira etapa

Entradas	Saída	FLR			SVM			RNA			KNN		
		3 Faixas	4 Faixas	6 Faixas	3 Faixas	4 Faixas	6 Faixas	3 Faixas	4 Faixas	6 Faixas	3 Faixas	4 Faixas	6 Faixas
ATOI TBS UR Entalpia	FR 2 Classes	94,0%	94,1%	94,1%	92,4%	93,2%	94,0%	86,0%	85,6%	85,6%	87,1%	85,9%	84,0%
ATOr TBS UR Entalpia	FR 2 Classes	91,4%	91,3%	90,7%	91,2%	91,5%	91,5%	86,0%	85,9%	85,5%	84,9%	83,4%	82,9%
ATOI TBS UR Entalpia	FR 3 Classes	79,6%	79,7%	80,3%	77,6%	79,6%	79,0%	68,4%	67,2%	67,1%	69,9%	68,8%	67,8%
ATOr TBS UR Entalpia	FR 3 Classes	77,7%	77,4%	76,3%	75,8%	78,3%	77,3%	68,5%	68,3%	66,8%	67,5%	66,0%	65,4%
ATOI TBS UR Entalpia	TR 2 Classes	80,6%	81,2%	79,3%	79,4%	81,7%	81,0%	77,9%	77,5%	76,7%	78,5%	77,4%	78,3%
ATOr TBS UR Entalpia	TR 2 Classes	79,0%	79,0%	78,7%	77,6%	79,5%	80,5%	74,8%	74,1%	75,1%	75,5%	74,2%	75,2%

\*Dados meteorológicos: referem-se as dados registrados com *data loggers* instalados na câmara climática: (TBS) temperatura média do ar; (UR) umidade relativa do ar.

\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (ATOI): assinatura térmica da região ocular dos animais obtidas com técnica de termografia e infravermelho; (ATOr): assinatura térmica da região da orelha dos animais obtidas com técnica de termografia e infravermelho.

\*Algoritmos: (FLR) Floresta Randômica; (SVM) máquina de vetores de suporte; (RNA) rede neural artificial; (KNN) K-vizinhos mais próximos.


\*Parâmetros: (Faixas): número de faixas da assinatura térmica; (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem.

Fonte: Própria autoria.



A Figura 14 apresenta o diagrama de análises de diferença significativa de Friedman e Nemenyi entre os algoritmos testados na etapa inicial da modelagem. A distância crítica (Critical Distance - CD) observada nesta análise foi de 1,106. Comparando os dois algoritmos com melhor desempenho, FLR e SVM, obtém-se uma diferença = 0,12 (1,56 – 1,44), indicando que não existe diferença estatística significativa entre eles (indicado pela linha azul clara no gráfico), uma vez que é um valor menor que 1,106. Entre os dois algoritmos com melhor desempenho e os dois piores colocados houve diferença significativa, conforme observado no diagrama.

Figura 14 - Análise de diferença significativa primeira etapa de modelagem



\*Algoritmos: SVM- Máquina de Vetores de Suporte; RNA - Rede Neural Artificial; KNN - K-Vizinhos Mais Próximos.

Fonte: Própria autoria.

## 6.2.2 Seleção de atributo predictor entre os dados de termografia


Para a execução desta etapa foram selecionados os algoritmos melhores colocados da etapa anterior (FLR e SVM), buscando explorar diferentes vetores de ATOI e ATOr (melhor correlação com FR e TR) com diferentes números de faixas de temperatura, assim como utilizar as temperaturas pontuais obtidos dos dados de TIV (máxima, ínima e média). Nesta etapa todos os modelos utilizam como atributos previsores as variáveis meteorológicas obtidas no experimento (TBS, UR e H).

### 6.2.2.1 Assinatura Térmica com Floresta Randômica

A Figura 15 apresenta a comparação entre os valores de acurácia dos modelos obtidos pelo algoritmo FLR em função da base de dados (geral ou 2ª onda de calor), dos atributos previsores extraídos das termografias (ATOI, ATOr e temperaturas máxima, mínima e média) e do atributo meta (FR-2-Classes, FR-3-Classes e TR-2-Classes). Para cada atributo meta foram gerados diversos modelos variando-se os atributos previsores.

As barras de cor clara representam os modelos gerados com a base de dados de todo o experimento (Geral) e as barras de cor escura representam os modelos gerados utilizando a base de dados da 2ª onda de calor do experimento, para fins de comparação. Nota-se que a grande maioria dos modelos gerados com a base de dados da 2ª onda de calor apresentaram resultados superiores aos modelos gerados com a base de dados “Geral”, fato que concorda com as correlações observadas nestas duas base de dados (os dados de termografia apresentaram maior correlação com os dados fisiológicos de FR e TR na base dados da 2ª onda de calor).

Figura 15 - Acurácias dos modelos baseados em Floresta Randômica para vetores de Assinatura Térmica com número diferente de faixas de temperatura



\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (ATOI): assinatura térmica da região ocular dos animais obtidas com técnica de termografia e infravermelho; (ATOr): assinatura térmica da região da orelha dos animais obtidas com técnica de termografia e infravermelho; (Temp TIV) temperatura máxima do olho (para os modelos que utilizaram a termografia do olho), temperatura mínima da orelha (para os modelos que utilizaram a FR como base de classificação e utilizaram a termografia da orelha) e temperatura máxima da orelha (para os modelos que utilizaram a TR como base de classificação e utilizaram a termografia da orelha).

\*Parâmetros: (Faixas): número de faixas da assinatura térmica; (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem; (Geral): Modelagem realizada com a base de dados de todo o experimento; (2ª Onda): Modelagem realizada com a base de dados da 2ª onda.

Fonte: Própria autoria.

A Tabela 7 apresenta os valores de acurácia variando-se a entrada dos modelos (atributos previsores) a partir de dados extraídos das TIVs utilizando a base de dados da 2ª onda de calor. Variou-se o número de faixas de assinatura térmica (3, 4, 6, 8 e 10 faixas). Para fins de comparação, utilizou-se também valores pontuais de temperatura obtidos a partir das termografias de infravermelho. Nota-se que em todos os modelos obtidos utilizando como atributo predictor as assinaturas térmicas com 3, 4, 6 e 8 faixas se mostraram superiores a temperatura pontual extraída da TIV. Os modelos com melhores acurácias obtidos foram com a assinatura térmica da região do olho com 4 e 6 faixas para a classificação por FR 2 classes, obtendo acurácias de 94,1%.

Tabela 7 - Acurácias segunda etapa modelagem para os modelos classificadores baseados em Floresta Randômica

<b>Entradas</b>	<b>Saída</b>	<b>3 Faixas</b>	<b>4 Faixas</b>	<b>6 Faixas</b>	<b>8 Faixas</b>	<b>10 Faixas</b>	<b>Temp TIV</b>
ATOI TBS UR Entalpia	FR 2 Classes	94,0%	94,1%	94,1%	93,3%	92,7%	92,3%
ATOr TBS UR Entalpia	FR 2 Classes	91,4%	91,3%	90,7%	90,3%	89,3%	90,2%
ATOI TBS UR Entalpia	FR 3 Classes	79,6%	79,7%	80,3%	78,9%	77,5%	75,5%
ATOr TBS UR Entalpia	FR 3 Classes	77,7%	77,4%	76,3%	76,0%	74,5%	74,6%
ATOI TBS UR Entalpia	TR 2 Classes	80,6%	81,1%	79,3%	80,3%	80,2%	78,6%
ATOr TBS UR Entalpia	TR 2 Classes	79,0%	79,0%	78,7%	79,0%	79,4%	81,3%

\*Dados meteorológicos: referem-se as dados registrados com *data loggers* instalados na câmara climática: (TBS) temperatura média do ar; (UR) umidade relativa do ar.

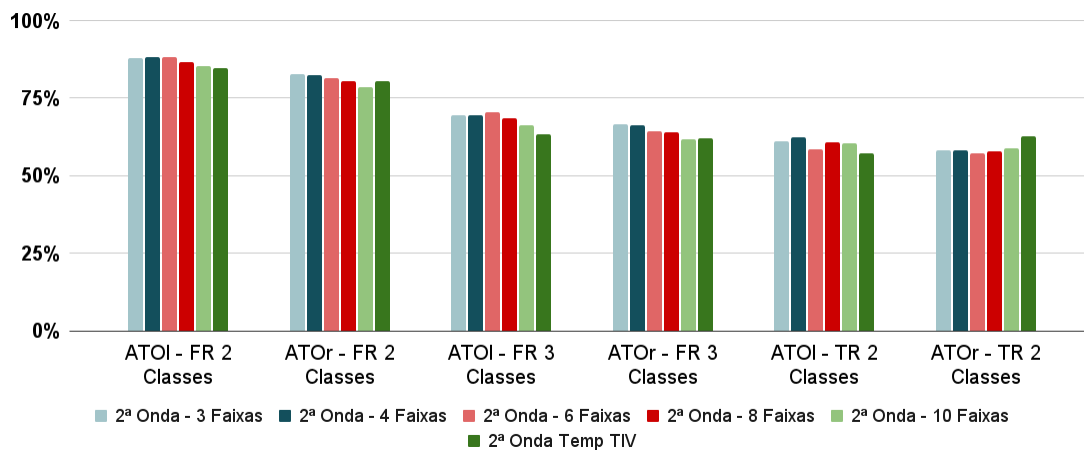
\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (ATOI): assinatura térmica da região ocular dos animais obtidas com técnica de termografia e infravermelho; (ATOr): assinatura térmica da região da orelha dos animais obtidas com técnica de termografia e infravermelho.

\*Parâmetros: (Faixas): número de faixas da assinatura térmica; (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem; (2ª Onda): Modelagem realizada com a base de dados da 2ª onda.

Fonte: Própria autoria.

A Figura 16 apresenta as acurácias normalizadas. A normalização é utilizada com o intuito de comparar os modelos classificadores considerando os diferentes números de classes do atributo meta (FR-2-Classes, TR-2-Classes e FR-3-Classes). Deste modo, não são ilustrados os resultados reais dos modelos, mas sim as acurácias em função do número de classes utilizadas pelo atributo meta. Nota-se que os modelos classificadores obtidos com base na FR demonstraram melhores resultados em relação aos modelos classificadores obtidos com base na TR. Ao utilizar as acurácias normalizadas é possível remover o efeito de probabilidades diferentes de acerto entre modelos com atributos meta de 2 e 3 classes.

Figura 16 - Comparação dos valores das acurácias normalizadas para os modelos classificadores baseados em Floresta Randômica




\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (ATOI): assinatura térmica da região ocular dos animais obtidas com técnica de termografia e infravermelho; (ATOr): assinatura térmica da região da orelha dos animais obtidas com técnica de termografia e infravermelho.

\*Parâmetros: (Faixas): número de faixas da assinatura térmica; (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem; (2ª Onda): Modelagem realizada com a base de dados da 2ª onda.

Fonte: Própria autoria.

A Figura 17 apresenta uma análise de diferença significativa dos modelos apresentados na Tabela 7. O objetivo desta análise é determinar quais os atributos previsores extraídos das TIVs que apresentaram, de maneira geral, os melhores desempenhos. A análise do gráfico ainda permite determinar se houve diferença significativa variando-se as entradas dos modelos. Nota-se que os 3 melhores atributos previsores foram os vetores de Assinaturas Térmicas com 4, 3 e 6 faixas, respectivamente. Não houve diferença estatística nos atributos previsores melhores classificados entre si, porém houve diferença entre os 3 melhores e 3 piores colocados.

Figura 17 - Análise de diferença significativa entre dos modelos baseados em Floresta Randômica para vetores de Assinatura Térmica com número diferente de faixas de temperatura



\*Parâmetros: (Faixas): número de faixas da assinatura térmica utilizada na construção dos modelos; (Sem AT): modelos desenvolvidos utilizando temperatura pontual extraída das TIVs.


Fonte: Própria autoria.

Os três atributos previsores que geraram os melhores modelos classificados foram utilizados para o desenvolvimento da terceira etapa de modelagem, onde serão exploradas várias combinações entre as variáveis meteorológicas.

### 6.2.2.2 Assinatura Térmica com Máquina de Vetores de Suporte

A Figura 18 apresenta a comparação entre os valores de acurácias dos modelos obtidos pelo algoritmo SVM em função da base de dados (geral ou 2ª onda de calor), dos atributos previsores extraídos das termografias (ATOI, ATOr e temperaturas máxima, mínima e média) e do atributo meta (FR-2-Classes, FR-3-Classes e TR-2-Classes).. Para cada atributo meta foram obtidos diversos modelos variando-se os atributos previsores. As barras de cor clara representam os modelos gerados com a base de dados de todo o experimento (Geral) e as barras de cor escura representam os modelos gerados utilizando a base de dados da 2ª onda do experimento, com o objetivo de visualizar qual base de dados obteve resultados melhores. Nota-se que todos os modelos FR-2-Classes e TR-2-Classes apresentaram resultados melhores utilizando a base de dados da 2ª onda de calor, quando comparados aos modelos gerados com a base de dados “geral”. O modelo FR-3-Classes gerado com a temperatura pontual da TIV (temperatura mínima da orelha) obteve resultado superior com a base de dados “Geral”, quando comparado a base de dados da 2ª onda calor, os demais modelos obtidos com vetores de Assinatura Térmica seguiram o padrão observado em FR-2-Classes e TR-2-Classes. Este fato corrobora com as correlações observadas nestas duas bases de dados (os dados de termografia apresentaram maior correlação com os dados fisiológicos de FR e TR na base dados da 2ª onda de calor).

Figura 18 - Acurácias dos modelos baseados em Máquina de Vetores de Suporte para vetores de Assinatura Térmica com número diferente de faixas de temperatura



\*Dados fisiológicos: (ATOI): assinatura térmica da região ocular dos animais obtidas com técnica de termografia e infravermelho; (ATOr): assinatura térmica da região da orelha dos animais obtidas com técnica de termografia e infravermelho.

\*Parâmetros: (Geral): Modelagem realizada com a base de dados de todo o experimento; (2ª Onda): Modelagem realizada com a base de dados da 2ª onda.

Fonte: Própria autoria.

A Tabela 8 apresenta os valores de acurácia variando-se a entrada dos modelos a partir de dados extraídos das TIVs. Variou-se o número de faixas de assinatura térmica (3, 4, 6, 8 e 10 faixas). Para fins de comparação, utilizou-se também valores pontuais de temperatura obtidos a partir das termografias de infravermelho. Nota-se que a maioria dos modelos obtidos utilizando como atributo predictor as assinaturas térmicas apresentaram desempenhos superiores quando comparados aos modelos obtidos utilizando a temperatura pontual extraída da TIV como atributo predictor. O modelo para a classificação de FR 2 classes com maior acurácia (94,0%) foi obtido com a assinatura térmica de 6 faixas. Os melhores modelos classificadores de FR 3 classes e TR 2 classes foram obtidos com a assinatura térmica de 8 faixas com acurácias de 79,8% e 81,9%, respectivamente.

Tabela 8 - Acurácias segunda etapa de modelagem para os modelos classificadores baseados em Máquina de Vetores de Suporte

Entradas	Saída	2ª Onda 3 Faixas	2ª Onda 4 Faixas	2ª Onda 6 Faixas	2ª Onda 8 Faixas	2ª Onda 10 Faixas	2ª Onda Temp TIV
ATOI TBS UR Entalpia	FR 2 Classes	92,4%	93,2%	94,0%	93,3%	93,8%	91,8%
ATOr TBS UR Entalpia	FR 2 Classes	91,2%	91,5%	91,5%	91,4%	91,5%	92,9%
ATOI TBS UR Entalpia	FR 3 Classes	77,6%	79,6%	79,0%	79,8%	78,0%	73,9%
ATOr TBS UR Entalpia	FR 3 Classes	75,8%	78,3%	77,3%	76,4%	79,0%	74,4%
ATOI TBS UR Entalpia	TR 2 Classes	79,4%	81,7%	81,0%	81,9%	80,0%	77,2%
ATOr TBS UR Entalpia	TR 2 Classes	77,6%	79,5%	80,5%	79,4%	79,0%	78,2%

\*Dados meteorológicos: referem-se as dados registrados com *data loggers* instalados na câmara climática: (TBS) temperatura média do ar; (UR) umidade relativa do ar.

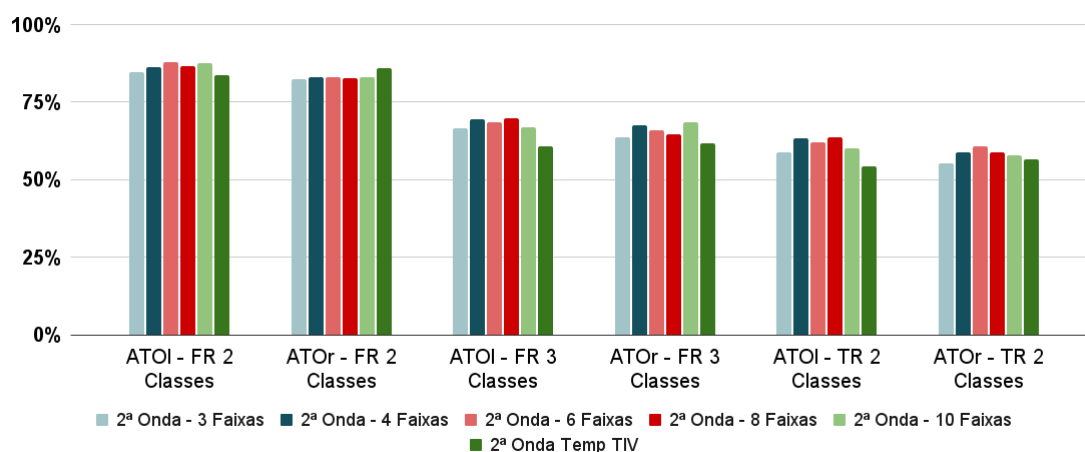
\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (ATOI): assinatura térmica da região ocular dos animais obtidas com técnica de termografia e infravermelho; (ATOr): assinatura térmica da região da orelha dos animais obtidas com técnica de termografia e infravermelho.

\*Parâmetros: (Faixas): número de faixas da assinatura térmica; (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem; (2ª Onda): Modelagem realizada com a base de dados da 2ª onda.

Fonte: Própria autoria.

A Figura 19 apresenta um gráfico de acurácias dos modelos gerados na Tabela 8 normalizadas. Este gráfico foi obtido com o intuito de realizar uma comparação dos modelos classificadores considerando os diferentes números de classes do atributo meta (FR 2 e 3 classes e TR 2 classes). Deste modo, este gráfico não ilustra os resultados reais dos modelos, mas sim as acurácias em função do número de classes utilizadas para pelo atributo meta. Nota-se de acordo com o gráfico que, assim como no algoritmo de floresta randômica, os modelos classificadores obtidos com a FR demonstraram melhores resultados em relação aos modelos classificadores por TR.

Figura 19 - Comparação dos valores das acurácias normalizadas para os modelos classificadores baseados em Máquinas de Vetores de Suporte




\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (ATOI): assinatura térmica da região ocular dos animais obtidas com técnica de termografia e infravermelho; (ATOr): assinatura térmica da região da orelha dos animais obtidas com técnica de termografia e infravermelho.

\*Parâmetros: (Faixas): número de faixas da assinatura térmica; (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem; (2ª Onda): Modelagem realizada com a base de dados da 2ª onda.

Fonte: Própria autoria.

A Figura 20 apresenta uma análise de diferença significativa dos modelos apresentados na Tabela 8. Nota-se de acordo com o gráfico que apesar da distância entre as colocações dos modelos não houve diferença significativa nos 4 melhores classificados entre si. O atributo predictor que ficou em quarto lugar (10 faixas), não apresentou diferença significativa com os dois últimos colocados.

Figura 20 - Análise de diferença significativa entre dos modelos baseados em Máquina de Vetores de Suporte para vetores de Assinatura Térmica com número diferente de faixas de temperatura



\*Parâmetros: (Faixas): número de faixas da assinatura térmica utilizada na construção dos modelos; (Sem AT): modelos desenvolvidos utilizando temperatura pontual extraída das TIVs.

Fonte: Própria autoria.

Os três melhores atributos previsores observados nesta etapa para a modelagem por SVM (4, 6 e 8 Faixas de assinatura térmica) foram utilizados na última etapa de modelagem, com diferentes combinações de variáveis meteorológicas.

### 6.2.3 Seleção de atributor previsor entre os dados meteorológicos

Nesta etapa de modelagem foram analisadas diferentes combinações de variáveis meteorológicas como atributos previsores, o que correspondeu a última etapa da modelagem em busca dos melhores modelos classificadores do presente trabalho. Nesta etapa manteve-se constante como atributos previsores os melhores vetores de Assinatura Térmica obtidas na etapa anterior para os algoritmos FLR e SVM.

#### 6.2.3.1 Dados meteorológicos com Floresta Randômica

A Tabela 9 apresenta valores de acurácias dos modelos obtidos com FLR em função da combinação dos atributos previsores. Os modelos FR-2-Classe, TR-2-Classes e FR-3-Classes foram gerados utilizando como atributos previsores os vetores de Assinatura Térmica para 3, 4 e 6 faixas de temperatura e combinações diferentes de variáveis meteorológicas (TBS, UR e H). Observa-se-se que a remoção de qualquer uma das variáveis meteorológicas resultou em prejuízo para os modelos em todos os casos. A remoção de H e UR em um mesmo modelo resultou no pior resultado, com as acurácias reduzindo de 94,0% para 88,1%, de 94,1% para 87,4% e de 94,1% para 85,1% no classificador FR-2-Classes utilizando como vetor a Assinaturas Térmicas do olho de com 4, 6 e 8 faixas de temperatura, respectivamente. Para as variações do modelo classificador de FR-3-Classes observa-se uma redução da acurácia ainda maior com a remoção de H e



da UR como atributo previsor. O modelo classificador de FR-3-Classes com vetor de Assinatura Térmica do olho com 8 faixas de temperatura teve sua acurácia reduzida nestas condições de 80,3% para 67,1%.

Tabela 9 - Acurácia terceira etapa de modelagem para classificadores baseados em floresta randômica

Entradas	Saída	3 Faixas				4 Faixas				6 Faixas			
		Todas Variáveis	Sem Entalpia	Sem UR	Sem Entalpia e UR	Todas Variáveis	Sem Entalpia	Sem UR	Sem Entalpia e UR	Todas Variáveis	Sem Entalpia	Sem UR	Sem entalpia e UR
ATOI TBS UR Entalpia	FR 2 Classes	94,0%	93,2%	93,5%	88,1%	94,1%	92,9%	93,3%	87,4%	94,1%	91,8%	93,2%	85,1%
ATOr TBS UR Entalpia	FR 2 Classes	91,4%	90,1%	90,8%	86,9%	91,3%	89,5%	90,5%	86,2%	90,7%	89,1%	89,9%	84,9%
ATOI TBS UR Entalpia	FR 3 Classes	79,6%	78,3%	78,6%	70,7%	79,7%	76,8%	78,6%	67,4%	80,3%	78,3%	77,8%	67,1%
ATOr TBS UR Entalpia	FR 3 Classes	77,7%	75,2%	75,9%	68,1%	77,4%	74,7%	75,3%	68,1%	76,3%	73,2%	74,5%	67,5%
ATOI TBS UR Entalpia	TR 2 Classes	80,6%	79,8%	79,4%	77,9%	81,1%	80,2%	79,9%	78,6%	79,3%	78,7%	79,4%	77,5%
ATOr TBS UR Entalpia	TR 2 Classes	79,0%	77,9%	77,6%	75,7%	79,0%	78,2%	77,8%	75,9%	78,7%	77,6%	77,5%	75,6%

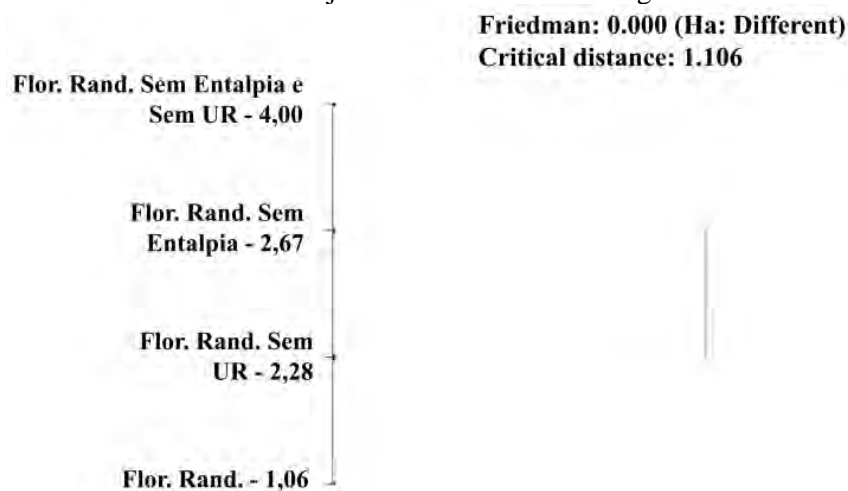
\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (ATOI): assinatura térmica da região ocular dos animais obtidas com técnica de termografia e infravermelho; (ATOr): assinatura térmica da região da orelha dos animais obtidas com técnica de termografia e infravermelho.

\*Parâmetros: (Faixas): número de faixas da assinatura térmica; (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem.

Fonte: Própria autoria.

A Figura 21 apresenta a análise de diferença significativa entre os modelos gerados alterando-se os atributos previsores com diferentes combinações de variáveis meteorológicas, conforme apresentados na Tabela 9. É possível observar que houve diferença estatística entre os modelos gerados com todas as variáveis meteorológicas para os demais modelos que foram obtidos removendo alguma variável meteorológica. Não houve diferença significativa entre os modelos em que se removeu a H e os modelos em que se removeu a UR.

Figura 21 - Análise de diferença significativa em modelos de Floresta Randômica com diferentes conjuntos de dados meteorológicos



\*Dados meteorológicos: (UR) umidade relativa do ar.

\*Algoritmo: (Flor. Rand.) Modelo obtido com Floresta Randômica com todas as variáveis meteorológicas.

Fonte: Própria autoria.

A Figura 22 apresenta as 3 melhores acurácias obtidas em função da classificação (atributo meta) para FLR. É possível observar o FR-2-Classes e TR-2-Classes foram obtidos com vetor de Assinatura Térmica de 4 faixas de temperatura com acurácias de 94,1% e 81,1 % respectivamente, enquanto que o modelo classificador de FR-3-Classes obteve a melhor acurácia 80,3% utilizando como atributo predictor o vetor de Assinatura Térmica com 6 faixas de temperatura. Estes 3 modelos foram obtidos utilizando o vetor de Assinatura Térmica do olho dos animais e todas as variáveis meteorológicas (TBS, UR e entalpia) como atributos previsores.

Figura 22 - Modelos com melhor desempenho - Floresta Randômica



\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (ATOI): assinatura térmica da região ocular dos animais obtidas com técnica de termografia e infravermelho.

\*Parâmetros: (Faixas): número de faixas da assinatura térmica; (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem.

Fonte: Própria autoria.

### 6.2.3.2 Dados meteorológicos com Máquina de Vetores de Suporte

A Tabela 10 apresenta valores de acurácias dos modelos obtidos com o algoritmo SVM em função da combinação dos atributos previsores. A primeira coluna de cada faixa de assinatura térmica representa os modelos gerados utilizando como atributos previsores todas as variáveis meteorológicas (TBS, UR e entalpia) combinadas as assinaturas térmicas correspondentes a cada número de faixas descrito. As demais colunas representam as acurácias dos modelos obtidas quando removidas uma ou mais variáveis meteorológicas, conforme descrito nos títulos das colunas. É possível notar que a remoção das variáveis provocou queda das acurácias em todos os casos. Quando removidas a entalpia ou a UR individualmente observa-se uma pequena queda nos valores das acurácias, porém quando removidas a UR e a entalpia simultaneamente observa-se uma queda brusca no desempenho dos modelos. No modelo com atributo meta FR 3 classes e atributos previsores assinatura térmica do olho com 8 faixas, TBS, UR e entalpia observa-se uma acurácia de 79,6%. Ao se remover a entalpia do modelo nota-se uma queda para 79,1% e, com a remoção da UR a acurácia apresenta um valor de 75,8% porém, com a remoção simultânea das duas variáveis (entalpia e UR), nota-se uma redução da acurácia de mais de 20% e esta assume o valor de 57,5%.

Tabela 10 - Acurácia terceira etapa de modelagem para classificadores baseados em Máquina de Vetores de Suporte


Entradas	Saída	4 Faixas				6 Faixas				8 Faixas			
		Todas Variáveis	Sem Entalpia	Sem UR	Sem Entalpia e UR	Todas Variáveis	Sem Entalpia	Sem UR	Sem Entalpia e UR	Todas Variáveis	Sem Entalpia	Sem UR	Sem entalpia e UR
ATOI TBS UR Entalpia	FR 2 Classes	93,2%	92,5%	92,7%	78,3%	94,0%	93,2%	92,8%	78,4%	93,3%	92,6%	91,3%	77,9%
ATOr TBS UR Entalpia	FR 2 Classes	91,5%	91,3%	90,8%	79,9%	91,5%	91,0%	91,1%	79,3%	91,4%	90,5%	90,5%	79,4%
ATOI TBS UR Entalpia	FR 3 Classes	79,6%	79,1%	75,8%	57,5%	79,0%	77,3%	75,7%	57,2%	79,8%	77,9%	74,5%	58,5%
ATOr TBS UR Entalpia	FR 3 Classes	78,3%	76,3%	75,1%	63,2%	77,3%	75,3%	74,7%	63,3%	76,4%	73,9%	72,2%	62,4%
ATOI TBS UR Entalpia	TR 2 Classes	81,7%	80,7%	75,3%	75,7%	81,0%	79,9%	77,4%	76,1%	81,9%	79,5%	76,6%	75,3%
ATOr TBS UR Entalpia	TR 2 Classes	79,5%	79,0%	74,9%	74,9%	80,5%	79,6%	75,1%	74,6%	79,4%	77,7%	75,1%	74,3%

\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (ATOI): assinatura térmica da região ocular dos animais obtidas com técnica de termografia e infravermelho; (ATOr): assinatura térmica da região da orelha dos animais obtidas com técnica de termografia e infravermelho.

\*Parâmetros: (Faixas): número de faixas da assinatura térmica; (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem.

A Figura 23 apresenta a análise de diferença significativa entre os modelos gerados alterando-se os atributos previsores com diferentes combinações de variáveis meteorológicas, conforme apresentados na Tabela 13. Pode-se observar que houve diferença estatística entre os modelos gerados com todas as variáveis meteorológicas para os demais modelos que foram obtidos removendo alguma variável. Não houve diferença estatística significativa entre os modelos em que se removeu a entalpia e os modelos que foi removida a UR.

Figura 23 - Análise de diferença significativa modelos base de dados e entrada - SVM



\*Dados meteorológicos: (UR) umidade relativa do ar.

\*Algoritmo: (SVM) Máquina de vetores de suporte.

Fonte: Própria autoria.

A Figura 24 apresenta a acurácia dos 3 melhores modelos obtidos utilizando o algoritmo SVM em função da classificação (atributo meta) utilizada. É possível observar que para FR 3 classes e TR 2 classes os melhores modelos foram obtidos com a assinatura térmica de 8 faixas e apresentaram acurácias de 79,8% e 81,9% respectivamente, enquanto que o modelo classificador de FR 2 classes obteve melhor acurácia utilizando como atributo predictor a assinatura térmica de 6 faixas e apresentou acurácia de 94%. Estes 3 modelos foram obtidos utilizando a assinatura térmica do olho dos animais e todas as variáveis meteorológicas (TBS, UR e entalpia) como atributos previsores.

Figura 24 - Modelos com melhor desempenho – máquinas de vetores de suporte



\*Dados fisiológicos: (FR) frequência respiratória; (TR) temperatura retal; (ATOI): assinatura térmica da região ocular dos animais obtidas com técnica de termografia e infravermelho; (ATOr): assinatura térmica da região da orelha dos animais obtidas com técnica de termografia e infravermelho.

\*Parâmetros: (Faixas): número de faixas da assinatura térmica; (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem.

Fonte: Própria autoria.

### 6.3 Melhores modelos classificadores de nível de estresse térmico

Buscando-se obter uma análise mais detalhada dos resultados são abordados a seguir os 3 melhores modelos que foram obtidos com o algoritmo FLR e SVM para a classificação em 2 e 3 classes de nível de estresse térmico (FR-2-Classes, FR-3-Casses e TR-2-Classes).

Com o intuito de realizar uma análise mais detalhada dos melhores modelos obtidos pelo algoritmo Floresta Randômica são apresentadas matrizes de confusão dos mesmos. A Tabela 11 apresenta a matriz de confusão do melhor modelo classificador FR-2-Classes. Nota-se que a classe que o modelo apresentou maior precisão na classificação (94,7%) foi na situação de perigo. A classe conforto apresentou uma precisão de 92,4%.

Tabela 11 - Matriz de confusão melhor modelo classificador FR 2 classes – Floresta Randômica

		<b>Classificador Floresta Randômica</b>		
		<b>Conforto</b>	<b>Perigo</b>	<b>Sensibilidade</b>
<b>Classificação FR 2 Classes</b>	<b>Conforto</b>	414	69	85,7%
	<b>Perigo</b>	34	1223	97,3%
<b>Precisão</b>		92,4%	94,7%	<b>Acurácia</b> 94,1%

\*Dados fisiológicos: (FR) frequência respiratória.

\*Parâmetros: (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem.

Fonte: Própria autoria.

A Tabela 12 apresenta a matriz de confusão do melhor modelo classificador FR-3-Classes. É possível observar que a classe intermediária (alerta) apresentou menor precisão e sensibilidade com valores de 72,8% e 57,1% respectivamente. As classes conforto e perigo apresentaram precisão de 88,2% e 79,2% nesta ordem.

Tabela 12 - Matriz de confusão melhor modelo classificador FR-3-Classes – Floresta Randômica

		<b>Classificador Floresta Randômica</b>			<b>Sensibilidade</b>
		<b>Conforto</b>	<b>Alerta</b>	<b>Perigo</b>	
<b>Classificação FR 3 Classes</b>	<b>Conforto</b>	426	28	29	88,2%
	<b>Alerta</b>	39	262	158	57,1%
	<b>Perigo</b>	18	70	710	89,0%
<b>Precisão</b>		88,2%	72,8%	79,2%	<b>Acurácia</b> 80,3%

\*Dados fisiológicos: (FR) frequência respiratória.

\*Parâmetros: (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem.

Fonte: Própria autoria.

A Tabela 13 apresenta a matriz de confusão do melhor modelo classificador para o atributo meta TR-2-Classes. Este modelo apresentou valores equilibrados de precisão e sensibilidade para as classes conforto e perigo. As precisões observadas para as classes conforto e perigo, respectivamente, foram de 80,4% e 81,9%. Estes valores próximos de precisão entre as classes podem ser resultante dos valores próximos de dados em cada nível de estresse térmico, visto que as classes conforto e perigo apresentaram 867 e 873 registros respectivamente.



Tabela 13 - Matriz de confusão melhor modelo classificador TR-2-Classes – Floresta Randômica

		Classificador Floresta Randômica		
		Conforto	Perigo	Sensibilidade
Classificação TR 2 Classes	Conforto	713	154	82,2%
	Perigo	174	699	80,1%
Precisão		80,4%	81,9%	Acurácia
				81,1%

\*Dados fisiológicos: (TR) temperatura retal.

\*Parâmetros: (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem.

Fonte: Própria autoria.

Com o objetivo de realizar uma análise mais detalhada dos melhores modelos obtidos pelo algoritmo SVM são apresentadas matrizes de confusão dos mesmos. A Tabela 14 apresenta a matriz de confusão do melhor modelo classificador FR-2-Classes. Nota-se que a classe que o modelo apresentou maior precisão na classificação foi na situação de perigo (precisão de 96%). A classe conforto apresentou uma precisão de 88,9%. Esta diferença pode ter ocorrido devido ao maior número de dados na classe perigo (1257 registros) em relação a classe conforto (483 registros).

Tabela 14 - Matriz de confusão melhor modelo classificador FR-2-Classes – Máquina de Vetores de Suporte

		Classificador SVM		
		Conforto	Perigo	Sensibilidade
Classificação FR 2 Classes	Conforto	433	50	89,6%
	Perigo	54	1203	95,7%
Precisão		88,9%	96,0%	Acurácia
				94,0%

\*Dados fisiológicos: (FR) frequência respiratória.

\*Parâmetros: (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem.

Fonte: Própria autoria.

A Tabela 15 apresenta a matriz de confusão do melhor modelo classificador para o atributo meta FR-3-Classes. É possível observar que a classe intermediária (alerta) apresentou menor precisão e sensibilidade com valores de 69,1% e 66,9% respectivamente. As classes conforto e perigo apresentaram precisão de 87,0% e 81,5% e sensibilidade de 82,8% e 85,3% respectivamente.

Tabela 15 - Matriz de confusão melhor modelo classificador FR-3-Classes – Máquina de Vetores de Suporte (SVM)

		Classificador SVM			
		Conforto	Alerta	Perigo	Sensibilidade
Classificação FR 3 Classes	Conforto	400	35	48	82,8%
	Alerta	45	307	107	66,9%
	Perigo	15	102	681	85,3%
Precisão		87,0%	69,1%	81,5%	<b>Acurácia</b> 79,8%

\*Dados fisiológicos: (FR) frequência respiratória.

\*Parâmetros: (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem.

Fonte: Própria autoria.

A Tabela 16 apresenta a matriz de confusão do melhor modelo classificador TR-2-Classes. Este modelo apresentou valores equilibrados de precisão e sensibilidade para as classes conforto e perigo. As precisões observadas para as classes conforto e perigo, respectivamente, foram de 82,0% e 81,8%. Estes valores próximos de precisão entre as classes podem ser resultado dos valores próximos de dados em cada nível de estresse térmico, visto que as classes conforto e perigo apresentaram 867 e 873 registros respectivamente.

Tabela 16 - Matriz de confusão melhor modelo classificador TR-2-Classes – Máquina de Vetores de Suporte (SVM)

		Classificador SVM		
		Conforto	Perigo	Sensibilidade
Classificação TR 2 Classes	Conforto	707	160	81,5%
	Perigo	155	718	82,2%
Precisão		82,0%	81,8%	<b>Acurácia</b> 81,9%

\*Dados fisiológicos: (TR) temperatura retal.

\*Parâmetros: (Classes) Número de níveis de classificação de estresse térmico utilizado na modelagem.

Fonte: Própria autoria.

Foram apresentados modelos classificadores de nível de estresse térmico (atributo meta) utilizando dados meteorológicos (temperatura de bulbo seco, umidade relativa e entalpia) e dados fisiológicos não invasivos extraídos da termografia de infravermelho (assinatura térmica e temperaturas pontuais). Foram obtidos resultados significativos com acurácias de 94,1%, 80,3% e 81,9% pra classificação de estresse térmico com base na FR

com 2 e 3 níveis de estresse térmico e TR com 2 níveis de estresse térmico respectivamente. Os melhores resultados foram obtidos com a ferramenta denominada no trabalho de Assinatura Térmica. Os algoritmos que apresentaram melhores resultados no desenvolvimento dos modelos classificadores, com diferença estatística significativa em relação aos demais algoritmos, foram a FLR e a SVM. Os vetores de Assinaturas Térmicas que geraram os modelos com melhores acurácias para o algoritmo FLR foram aqueles com 4, 3 e 6 faixas de temperatura respectivamente, enquanto para o algoritmo SVM as melhores acurácias foram obtidas com 6, 4 e 8 faixas nesta ordem. Os resultados apontaram que a remoção da H e da UR ou de ambas as variáveis como atributos previsores dos modelos provocou uma redução com diferença estatística significativa das acurácias dos modelos classificadores gerados pelos algoritmos FLR e SVM.

O modelo com maior desempenho obtido neste trabalho (com 94,1% de acurácia) obteve um resultado muito próximo ao melhor modelo classificador de estresse térmico para bovinos encontrado na literatura, que apresentou uma acurácia de 94,35% (SOUSA et al., 2018), conforme descrito no item 3.3 da revisão bibliográfica. Este fato reforça o potencial do uso da metodologia abordada neste trabalho de extração de características das TIVs associada ao aprendizado de máquina, bem como o uso de câmara climática para obtenção de base de dados com diversos níveis de estresse térmico em um curto período de tempo.

## **7. Conclusão**

O presente trabalho propôs a construção e avaliação de modelos baseados em aprendizado de máquina para a predição do nível de estresse térmico animal utilizando base de dados obtida em câmara climática de bezerras de leite. Foram desenvolvidos modelos classificadores utilizando quatro tipos algoritmos de aprendizado de máquina sendo eles Floresta Randômica, Máquina de Vetores de Suporte, K-Vizinhos Mais Próximos e Redes Neurais Artificiais, buscando-se obter os melhores modelos (tendo como parâmetro a acurácia) em função do algoritmo e dos atributos previsores (dados meteorológicos e dados extraídos das imagens termográficas – vetores de Assinatura Térmica e temperaturas pontuais). Como atributo meta foram utilizados a classificação em 2 e 3 classes (níveis de estresse térmico) baseadas na rotulagem por faixas de FR e em 2 classes baseadas na rotulagem por faixas de TR, conforme faixas encontradas na literatura. A Assinatura Térmica se mostrou mais eficiente como atributo predictor dos modelos em relação as temperaturas pontuais extraídas dos dados de termografia. Este

fato pode estar ligado a maior robustez que a Assinatura Térmica, uma vez que esta ferramenta utiliza dados que consideram todos os pontos das regiões da superfícios corporal. Os melhores modelos classificadores em 2 e 3 níveis de estresse térmico baseados na rotulagem por faixas de FR foram obtidos com 4 e 6 faixas de Assinatura Térmica. Para a rotulagem por faixas de TR o melhor modelo classificador foi obtido com 8 faixas de Assinatura Térmica. Os resultados obtidos evidenciam o potencial do uso de aprendizado de máquina associado a dados extraídos de TIVs na predição de nível de estresse térmico. Os resultados também demonstram que o uso de câmara climática pode auxiliar na obtenção, de maneira mais rápida que em experimentos realizados em campo, de base de dados balanceada para a criação dos modelos classificadores de estresse térmico.

## 8. Referências

- AMAKIRI, S.F.; MORDI, R. The rate of cutaneous evaporation in some tropical and temperate breeds of cattle in Nigeria. **Journal of Animal Production**, v.20, n. 1, p.63-68, 1975.
- BARNABÉ, J.M.C.; PANDORFI, H.; ALMEIDA, G.L.P.de; GUISELINI, C.; JACOB, A.L. Temperatura superficial de materiais utilizados para cobertura individual de bezerreiros. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.18, n.5, p.545-550, 2014.
- 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.
- BURFEIND, O.; SUTHAR, V. S.; HEUWIESER, W. Effect of heat stress on body temperature in healthy early postpartum dairy cows. **Theriogenology**, v. 78, n. 9, p. 2031-8, 2012.
- BUFFINGTON, D. E.; CANTON, G. H.; PITT, D. Black globe-humidity index (BGHI) as comfort equation for dairy cows. **Transactions of the ASAE**, v. 24, n. 3, p. 711-714, 1981.
- CHOUDHURY, M.; SAIKIA, T.; BANIK, S.; PATIL, G.; PEGU, S. R.; RAJKHOWA, S.; ... DAS, P. J. Infrared imaging a new non-invasive machine learning technology for animal husbandry. **The Imaging Science Journal**, p. 1-10.
- COLLIER, R. J.; DAHL, G. E.; VANBAALE, M. J. Major advances associated with environmental effects on dairy cattle. **Journal of Dairy Science**, v. 89, n. 4, p. 1244-1253, 2006.
- 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, n. 1, p. 109- 116, 2009.
- DU PREZZ, J. H. Parameters for determinaiton and evaluation of heat stress in dairy cattle in South Africa. **Onderstepoort Journal Veterinary Research**, v.67, p. 263-271, 2000.
- EUSTÁQUIO FILHO, A.; TEODORO, S.M.; CHAVES, M.A.; SANTOS, P.E.F.dos.; SILVA, M.W.R.da.; MURTA, R.M.; CARVALHO, G.G.P.de.; SOUZA, L.E.B.de. Zona de conforto térmico de ovinos da raça Santa Inês com base nas respostas fisiológicas. **Revista Brasileira de Zootecnia**, v.40, n.8, p.1807-1814. 2011.
- FONSECA, F. N. da; ABE, J. M.; NÄÄS, I. de A.; CORDEIRO, A. F. da S.; AMARAL, F. V. do; UNGARO, H. C. Automatic prediction of stress in piglets (*Sus Scrofa*) using infrared skin temperature. **Computers and Electronics in Agriculture**, 105148, 2020.
- FOURNEL, S.; ROUSSEAU, A. N.; LABERGE, B. Rethinking environment control strategy of confined animal housing systems through precision livestock farming.

**Biosystems Engineering**, v. 155, n. 1, p. 96-123, 2017.

GARNER, J. B.; DOUGLAS, M.; WILLIAMS, S. R. O.; WALES, W. J.; MARETT, L. C.; DIGIACOMO, K.; LEURY, B.J.; HAYES, B. J. Responses of dairy cows to short-term heat stress in controlled-climate chambers. **Animal Production Science**, v. 57, n. 7, p. 1233-1241, 2017.

GAUGHAN, J. B.; MADER, T. L. Body temperature and respiratory dynamics in unshaded beef cattle. **International Journal of Biometeorology**, v. 58, n. 7, p. 1–8, 2013.

GORCZYCA, M. T.; MILAN, H. F. M.; MAIA, A. S. C.; GEBREMEDHIN, K. G. Machine learning algorithms to predict core; skin; and hair-coat temperatures of piglets. **Computers and Electronics Agriculture**, v. 151, n. 1, p. 286-294, 2018.

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

HANSON, R.; STUTZ, J.; CHEESEMAN, P. Bayesian classification theory. **Research Institute for Advanced Computer Science**, 1995.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference and Prediction**. 2nd ed. Stanford: Springer, 2017.

HAYKIN, Simon. **Redes Neurais: Princípios e Prática**. 2. Ed. Tradução de Paulo Martins Engel. São Paulo: Editora Artmed LTDA, 1999.

HERNANDEZ-JULIO, Y. F.; YANAGI JR., T.; AVILA PIRES, M. De F.; LOPES, M. A.; LIMA, R. R. de. Models for prediction of physiological responses of holstein dairy cows. **Applied Artificial Intelligence**, v. 28, n. 8, p. 766–792, 2014.

HOFFMANN, G.; SCHMIDT, M.; AMMON, C.; ROSE-MEIERHOFER, S.; BURFEIND, O.; HEUWIESER, W.; BERG, W. Monitoring the body temperature of cows and calves using video recordings from an infrared thermography camera. **Veterinary Research Communications**, p.1-9, 2012.

HUANG, Y.; LAN, Y.; THOMSON, S.J.; FANG, A.; HOFFMANN, W.C.; LACEY, R.E. Development of soft computing and applications in agricultural and biological engineering. **Computers and Electronics Agriculture**. V. 71, n. 2, p. 107–127, 2010.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **Climate Change 2001 - The scientific basis. Contribution of Working Group I to the Third Assessment Report of the IPCC**. Cambridge Univ. Press, Cambridge, UK, 2001.

ISOLA, J. V. V.; MENEGAZZI, G.; BUSANELLO, M.; Santos, S. B. D.; AGNER, H. S. S.; SARUBBI, J. Isola, G. Menegazzi, M. Busanello, S.B. dos Santos, H.S.S. Agner, J. Sarubbi, Differences in body temperature between black-and-white and red-and-white Holstein cows reared on a hot climate using infrared thermography. **Journal of Thermal Biology**. V. 94, P. 102775 – 102781, 2020.

JOY, A.; TAHERI, S.; DUNSHEA, F. R.; LEURY, B. J.; DIGIACOMO, K.; OSEI-AMPONSAH, R.; BRODIE, G.; CHAUHAN, S. S. Non-invasive measure of heat stress

in sheep using machine learning techniques and infrared thermography. **Small Ruminant Research**, p 106592 – 106613, 2021.

LOWE, G.; MCCANE, B.; SUTHERLAND, M.; WASS, J.; SCHAEFER, A.; COX, N.; STEWART, M. Automated collection and analysis of infrared thermograms for measuring eye and cheek temperatures in calves. **Animals**, v.10, n.2, p.292, 2020.

KADZERE, C.T.; MURPHY M.R.; SILANIKOVE N.; MALTZ E. Heat stress in lactating dairy cows: a review. **Livestock Production Science**, v. 77, n. 1, p. 59 –91, 2002.

KNIZKOVA, I.; KUNK, P.; GURDIL, G.; PINAR, Y.; SELVI, K. Ç. Applications of infrared thermography in animal productions. **Anadolu Journal of Agricultural Sciences**, v. 22, n. 3, p. 329–336, 2007.

KOTU, V.; DESHPANDE, B. Classification. **Predictive Analytics and Data Mining**. p. 63–163, 257–273, 2015.

KOTU, V.; DESHPANDE, B. Model Evaluation. **Predictive Analytics and Data Mining**, p. 257–273, 2015.

MADER, T. L.; GRIFFIN, D. Management of cattle exposed to adverse environmental conditions. **Veterinary Clinics of North America: Food Animal Practice**, v. 31, n. 2, p. 247–258, 2015.

MARRERO, M. G.; RIJOS-FERNÁNDEZ, C.; VÉLEZ-ROBLES, Y.; ORTIZ-COLÓN, G., SÁNCHEZ-RODRÍGUEZ, H.; JIMÉNEZ-CABÁN, E.; CURBELO-RODRÍGUEZ, J. Short-milking-tube infrared temperature as a subclinical mastitis detection tool in tropical dairy farms. **Applied Animal Science**, v. 36, n. 3, p. 329–334, 2020.

MARTELLO, L. S.; SILVA, S. L.; GOMES, R. C.; CORTE, R. R. S.; LEME, P. R. 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, 2015.

MC LEAN, J.A. The partition of insensible losses of body weight and heat from cattle under various climatic conditions. **Journal of Physiology**, v.167, n. 1, p. 427-447, 1963.

MCMANUS, C.; TANURE, C. B.; PERIPOLLI, V.; SEIXAS, L.; FISCHER, V.; GABBI, A. M.; MENEGASSI, S. R. O.; STUMPF, M. T.; KOLLING, G. J.; DIAS, E.; COSTA, J. B. G. Infrared thermography in animal production: An overview. **Computers and Electronics in Agriculture**, v. 123, n. 1, p. 10-16, 2016.

MENDEZ, V.; CATALÁN, H.; ROSSEL, J.R.; ARNÓ, J.; SANZ, R.; TARQUIS, A. SIMLIDAR – Simulation of LIDAR performance in artificially simulated orchards. **Biosystems Engineering**, v. 111, n. 1, p.72-82, 2012.

MONTANHOLI, Y. R.; ODONGO, N. E.; SWANSON, K. C.; SCHENKEL, F.S.; MCBRIDE, B.W.; MILLER, S.P. Application of infrared thermography as an indicator of heat and methane production and its use in the study of skin temperature

in response to physiological events in dairy cattle (*Bos taurus*). **Journal of Thermal Biology**, v.33, n. 1, p. 468–475, 2008.

OLIVEIRA, R. A.; SILVA, A. P. B. William Herschel, os raios invisíveis e as primeiras ideias sobre radiação infravermelha. *Revista Brasileira de Ensino de Física*, v. 36, n. 4, p. 4603-4613, 2014.

PACHECO, V. M.; SOUSA, R. V.; RODRIGUES, A. V. da S.; SARDINHA, E. J. De S.; MARTELLO, L. S. Thermal imaging combined with predictive machine learning based model for the development of thermal stress level classifiers. **Livestock Science**, 104244, 2020.

PEARCE, S. C.; GABLER; N. K.; ROSS; J. W.; ESCOBAR; J.; PATIENCE; J. F.; RHOADS; R. P.; BAUMGARD; L.H. The effects of heat stress and plane of nutrition on metabolism in growing pigs. **Journal of animal science**, v. 91, n. 5, p. 2108-2118, 2013.

PEREIRA, D.G., AFONSO, A., MEDEIROS, F.M. Overview of Friedman's Test and Post-hoc Analysis. **Communications in Statistics - Simulation and Computation**, 44:10, 2636-2653, 2015.

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.

ROBINSON E.N. **Termorregulação**. In: CUNNINGHAM, J.G. Tratado de fisiologia veterinária. 2.ed. Rio de Janeiro: Guanabara Koogan, cap.51, 427-435, 1999.

RODRIGUES, A. V. S.; PACHECO, V.M.; MARTELLO, L. S.; SARDINHA, E. J. S.; SOUSA, R.V. (2019). Assinatura térmica: uma proposta para avaliação de estresse térmico na produção animal. **V Workshop Internacional de Ambiente de Precisão**, Campinas, 2019.

RICCI, G. D.; SILVA-MIRANDA, K. O.; TITTO, C. G. Infrared thermography as a non-invasive method for the evaluation of heat stress in pigs kept in pens free of cages in the maternity. **Computers and Eletronics in Agriculture**, v. 157, n. 1, p. 403-409, 2019.

SELLIER, N.; GUETTIER, E.; & STAUB, C. A review of methods to measure animal body temperature in precision farming. **American Journal of Agricultural Science and Technology**, v. 2, n. 2, p. 74-99, 2014.

SCHAEFER, A.L.; COOK, N.J.; CHURCH, J.S. et al. The use of infrared thermography as an early indicator of bovine respiratory disease complex in calves. **Veterinary Science**, v.83, p.376-384, 2007.

SCHAEFER, A.L.; COOK, N.J.; BENCH, C. et al. The non-invasive and automated detection of bovine respiratory disease onset in receiver calves using infrared thermography. **Research in Veterinary Science**, v.93, p.928-935, 2011.

SCHAEFER, A. L.; COOK, N. J.; BENCH, C.; CHABOT, J. B.; COLYN, J.; LIU, T.; WEBSTER, J. R. The non-invasive and automated detection of bovine respiratory disease onset in receiver calves using infrared thermography. **Research in Veterinary**



**Science**, v. 93, n. 2, p. 928–935, 2012.

SCHARF, B.; LEONARD, M. J.; WEABER, R. L.; MADER, T. L.; HAHN, G. L.; SPIERS, D. E. Determinants of bovine thermal response to heat and solar radiation exposures in a field environment. **International Journal of Biometeorology**, v. 55, n. 4, p. 469–480, 2011.

SCHLEGER, A.V.; TURNER, H.G.; Sweating rates of cattle in the field and their reaction to diurnal and seasonal changes. **Australian Journal of Agricultural Research**, v. 16, n. 1, p.92-106, 1965.

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.

SILVA, L. A. da; PERES, S. M.; BOSCARIOLI, C. **Introdução à mineração de dados**: Com aplicações em R. Rio de Janeiro: Elsevier, 2016. 296p.

SILVA, R.G. **Introdução à bioclimatologia animal**. São Paulo: Nobel, 2000. 286p.

SILVA, R.G.; MORAIS, D.A.E.F.; GUILHERMINO, M.M. Evaluation of thermal stress indexes for dairy cows in tropical regions. **Revista Brasileira de Zootecnia**, v. 36, n. 4, p. 1192–1198, 2007.

SOUSA, R.V. de; CANATA, T.F.; LEME, P.R.; MARTELLO, L.S. Development and evaluation of a fuzzy logic classifier for assessing beef cattle thermal stress using weather and physiological variables. **Computers and Electronics Agriculture**, v. 127, n. 1, p. 176–183, 2016.

SOUSA, R.V.; RODRIGUES, A.V.S.; ABREU, M.G.; TABILE, R.A.; MARTELLO, L.S. Predictive model based on artificial neural network for assessing beef cattle thermal stress using weather and physiological variables. **Computers and Electronics Agriculture**, v. 144, n. 1, p. 37–43, 2018.

SOUSA, Rafael; MARTELLO, Luciane Silva. *Árvores de Decisão*, 2020. 19 slides.

SOUZA, B.B.; BATISTA, N.L. **Agropecuária Científica no Semiárido**. v.8, n.3,p.06-10. 2012.

VALE, M. M. DO; MOURA, D. J.; NÄÄS, I. DE A. DE; CURI, T. M. R. C.; LIMA, K. A. O. Effect of a simulated heat wave in thermal and aerial environment broiler-rearing environment. **Engenharia Agrícola**, v. 36, n. 2, p. 271–280, 2016.

VAN HERTEM; T.; ROOIJAKKERS; L.; BERCKMANS; D.; PEÑA FERNÁNDEZ; A.; NORTON; T.; BERCKMANS; D.; VRANKEN; E. Appropriate data visualisation is key to Precision Livestock Farming acceptance. **Computers and Electronics in Agriculture**, v. 138, n. 1, p. 1–10, 2017.

WALCZAK, S.; CERPA, N. Artificial Neural Networks. In: **Encyclopedia of Physical Science and Technology**. [s.l.] Elsevier, 2003. p. 631–645.

WATHES, C. M.; KRISTENSEN, H. H.; AERTS, J. M.; BERCKMANS, D. Is precision livestock farming an engineer's daydream or nightmare; an animal's friend or foe; and a farmer's panacea or pitfall? **Computers and Electronics in Agriculture**, v. 64, n. 1, p. 2–10, 2008.

WEKA: Waikato Environment for Knowledge Analysis. Versão 3.8.5. The University of Waikato, Hamilton, New Zealand, 2020.

ZHANG, Z. Introduction to machine learning: k-nearest neighbors. **Annals of Translational Medicine**, v. 4, n. 11, p. 218–218, 2016.