



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

RODES ANGELO BATISTA DA SILVA

SISTEMA AUTOMÁTICO DE CLASSIFICAÇÃO DE IMAGENS TÉRMICAS
PARA DETECÇÃO DE MASTITE SUBCLÍNICA BOVINA

RECIFE/PE
2023

UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO

**Sistema automático de classificação de imagens térmicas para
detecção de mastite subclínica bovina**

Trabalho de tese apresentado à Universidade Federal Rural de Pernambuco como requisito para obtenção do grau de Doutor em Engenharia Agrícola.

Orientador: Héilton Pandorfi
Coorientador: Ricardo Brauer Vigoderis

RECIFE – PE
2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal Rural de Pernambuco
Sistema Integrado de Bibliotecas
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

R688s Silva, Rodes Angelo Batista da
Sistema automático de classificação de imagens térmicas para detecção de mastite subclínica bovina / Rodes Angelo
Batista da Silva. - 2023.
134 f. : il.

Orientador: Heliton Pandorfi.
Coorientador: Ricardo Brauer Vigoderis.
Inclui referências.

Tese (Doutorado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Engenharia Agrícola,
Recife, 2023.

1. Imagem térmica. 2. Inteligência Artificial. 3. Mastite Bovina. 4. Processamento de imagens. I. Pandorfi,
Heliton, orient. II. Vigoderis, Ricardo Brauer, coorient. III. Título

CDD 630

RODES ANGELO BATISTA DA SILVA

**Sistema automático de classificação de imagens térmicas para detecção de mastite
subclínica bovina**

Trabalho de tese apresentado à Universidade Federal Rural de Pernambuco como requisito para obtenção do grau de Doutor em Engenharia Agrícola sob a orientação do Prof. Dr. Héilton Pandorfi e Ricardo Brauer Vigoderis.

Tese defendida e aprovada em 24 de Fevereiro de 2023 pela banca examinadora:

Prof. Dr. Héilton Pandorfi (Orientador)
Universidade Federal Rural de Pernambuco (UFRPE)

Prof. Dr. José Antônio Delfino Barbosa Filho
Universidade Federal do Ceará (UFC)

Prof. Dr. João Paulo Silva do Monte Lima
Universidade Federal Rural de Pernambuco (UFRPE)

Prof. Dr. Filipe Rolim Cordeiro
Universidade Federal Rural de Pernambuco (UFRPE)

Prof. Dr. Gledson Luiz Pontes de Almeida
Universidade Federal Rural de Pernambuco (UFRPE)

“A confiança em Deus é ouro, a confiança nos homens é prata”.

Rodes Batista

“Estando nele nada falta, não há dúvidas e tudo contribui”.

Rodes Batista

AGRADECIMENTOS

A Deus, pela sua fidelidade e luz dispensadas em meu caminho. Pela sua fiel proteção e por todos os momentos que estendeu sua mão amiga durante a realização deste estudo.

Agradeço a minha família pelo amor que sempre me dispensaram. A meus pais pelo esforço que sempre fizeram, por carregarem do amor de Deus dentro de si e por transbordarem.

Ao meu esposo Hecton Batista pelo amor, carinho, cuidado, atenção, compreensão, dedicação, incentivo e por estarmos sempre juntos em todos os momentos da vida.

Ao meu irmão, André e minha sobrinha Sophia, por me lembrarem todos os dias que no caminhar da vida, existem coisas fora do comum, pontos fora da curva, inexplicável pelas leis da natureza, que só ocorrem por manifestação ou intervenção da presença divina na vida humana.

À Universidade Federal Rural de Pernambuco pela oportunidade e toda estrutura disponibilizada para a realização dos estudos.

Ao Programa de Pós-Graduação em Engenharia Agrícola da UFRPE, pela oportunidade de realização do Curso de Doutorado.

Ao orientador, professor Héilton Pandorfi, agradeço pela orientação, pela confiança, pela disponibilidade que sempre manifestou e pelo acompanhamento exercido, fundamentais para realizar e prosseguir este estudo.

Ao professor Dr. José Antônio Delfino Barbosa Filho pela parceria e disponibilidade em contribuir com esse estudo.

À Fazenda Roçadinho por todo o suporte fornecido e pela disponibilidade para o registro de imagens.

A todos os professores e alunos do Programa de Pós-Graduação em Engenharia Agrícola por todos os ensinamentos que fizeram parte desta formação.

Aos professores, pela disponibilidade para participação na banca examinadora.

A todo corpo administrativo do programa, coordenador, vice coordenador e secretária.

Aos integrantes do Grupo de Pesquisa em Ambiente (GPESA) agradeço o convívio e trabalhos. Pelos momentos de companheirismo, troca de experiências e descontração.

À Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE) pela concessão da bolsa durante todo esse período e auxílio financeiro.

A todos os que, garantidamente, contribuíram para a realização deste trabalho, meus sinceros agradecimentos.

SUMÁRIO

Lista de Figuras.....	11
Lista de Tabelas.....	15
RESUMO.....	17
ABSTRACT.....	19
1. INTRODUÇÃO GERAL.....	20
2. HIPÓTESES.....	21
3. OBJETIVOS.....	21
3.1. Geral.....	21
3.2. Específicos.....	22
4. CAPÍTULO I - REVISÃO BIBLIOGRÁFICA.....	24
4.1. Bovinocultura de leite.....	24
4.2. Controle e sanidade do rebanho.....	25
4.2.1. Boas práticas na ordenha.....	26
4.2.3. Métodos de detecção.....	28
4.3. Influência dos fatores abióticos na saúde do rebanho.....	29
4.4. Zootecnia de precisão.....	31
4.5. Uso da termografia por infravermelho na produção animal.....	33
4.5.1. Termografia por infravermelho como ferramenta no diagnóstico veterinário.....	35
4.6. Influência das variáveis meteorológicas sobre a medição de temperaturas através da termografia.....	35
4.7. Visão computacional na produção animal.....	36
4.7.1. Segmentação.....	37
4.8. Análise de imagem aplicada.....	38
4.8.1. Redes neurais convolucionais.....	38
4.8.3. Transferência de aprendizagem.....	38
4.8.4. Avaliação dos classificadores.....	41
REFERÊNCIAS.....	42
CAPÍTULO II - LIMIAZIZAÇÃO DE IMAGENS TÉRMICAS PARA DETECÇÃO AUTOMÁTICA DE MASTITE BOVINA.....	51
RESUMO.....	51

ABSTRACT.....	53
1. INTRODUÇÃO.....	55
2. MATERIAL E MÉTODOS.....	56
3. RESULTADOS E DISCUSSÃO.....	60
4. CONCLUSÃO.....	63
CAPÍTULO III - APRENDIZAGEM DE MÁQUINA POR TRANSFERÊNCIA SEQUENCIAL PARA DETECÇÃO AUTOMÁTICA DE MASTITE BOVINA A PARTIR DE IMAGENS TÉRMICAS.....	67
RESUMO.....	67
ABSTRACT.....	69
1. INTRODUÇÃO.....	70
2. TRABALHOS RELACIONADOS.....	72
3. MATERIAL E MÉTODOS.....	73
3.1. Conjunto de dados.....	74
3.2. Pré-processamento de imagem.....	75
3.3. Análise Comparativa dos modelos.....	76
3.4. Utilização dos pesos ImageNet para inicialização da rede e treino nas imagens de mastite (Mastitis – ResNet50).....	78
3.5. Utilização dos pesos ImageNet, treino com as imagens de mamografia e ajuste fino para as imagens de mastite (Mammo_Mast_ImageNet – ResNet50).....	80
3.6. Utilização de pesos aleatórios para inicialização da rede e ajuste fino para treino na base de imagens de mamografia e transferência para a base de imagens de mastite (Mammo_mastitis – ResNet50).....	81
3.7. Utilização dos pesos ImageNet com ajuste fino para o treino na base de imagens de mamografia e transferência de aprendizado com ajuste fino para a base de imagens de mastite (STL – ResNet50).....	81
3.8. Métricas de avaliação.....	82
4. RESULTADOS.....	82
4.1. Desempenho dos modelos na classificação.....	85
5. DISCUSSÃO.....	86
6. CONCLUSÕES.....	87
REFERÊNCIAS.....	88

CAPÍTULO IV - IDENTIFICAÇÃO AUTOMÁTICA DE MASTITE BOVINA UTILIZANDO TRANSFERÊNCIA DE APRENDIZAGEM SEQUENCIAL COM OTIMIZAÇÃO BAYESIANA.....	95
RESUMO.....	95
ABSTRACT.....	97
1. INTRODUÇÃO.....	98
2. MATERIAL E MÉTODOS.....	99
2.1. Abordagem por transferência sequencial.....	100
2.2. Otimização de hiperparâmetros.....	101
2.3. Pré-processamento de imagem.....	104
2.4. Plataforma experimental.....	104
2.5. Ajuste de hiperparâmetros utilizando otimização bayesiana.....	105
2.6. Métricas de avaliação.....	107
3. RESULTADOS E DISCUSSÃO.....	108
3.1. Desempenho da classificação com otimização bayesiana.....	109
3.2. Performance do modelo na classificação e conjunto de hiperparâmetros.....	110
4. CONCLUSÃO.....	111
REFERÊNCIAS.....	112
CAPÍTULO V - DESEMPENHO DA CLASSIFICAÇÃO DE IMAGENS DE MASTITE BOVINA USANDO TRANSFERÊNCIA DE APRENDIZADO SEQUENCIAL COM MECANISMO DE ATENÇÃO E OTIMIZAÇÃO BAYESIANA.....	116
RESUMO.....	116
ABSTRACT.....	118
1. INTRODUÇÃO.....	119
2. MATERIAL E MÉTODOS.....	120
2.1. Conjunto de dados.....	120
2.2. Pré-processamento de imagem.....	122
2.3. Abordagem por transferência sequencial.....	123
2.4. Módulo de atenção de bloqueio convolucional (CBAM).....	123
2.5. Otimização de hiperparâmetros.....	125
2.6. Modelo proposto (STL_Bayesian_CBAM – ResNet50).....	125
3. RESULTADOS E DISCUSSÃO.....	128
3.1. Performance do modelo na classificação e conjunto de hiperparâmetros.....	131
4. CONCLUSÃO.....	132

REFERÊNCIAS.....	132
CONSIDERAÇÕES FINAIS.....	134

Lista de Figuras

CAPÍTULO I

Figura 1. Produção brasileira de leite sob inspeção em bilhões de litros.	25
Figura 2. Produção de leite inspecionado nas regiões brasileiras volume de leite adquirido em 2020 e 2021.....	25
Figura 3. Teste da caneca de fundo escuro (3A) e California Mastitis Test (CMT) (3B).	28
Figura 4: Aparato tecnológico na zootecnia de precisão.....	32
Figura 5. Espectro eletromagnético	33
Figura 6. Diagrama esquemático do sistema ótico de um termovisor e conversão da energia térmica, onde: 1) superfície alvo (que emite energia infravermelha); 2) campo de visão; 3) lente coletora de energia; 4) filtro para a passagem da banda espectral selecionada; 5) detector conversor de energia infravermelha em sinal elétrico, e; 6) amplificador e condicionador do sinal.....	34
Figura 7. Exemplo de imagem segmentada.....	37
Figura 8. Rede Neural Multicamadas e Rede Neural Convolucional.....	38
Figura 9: Processo de transfer learning.....	39
Figura 10: Arquitetura do ajuste fino da rede.....	40
Figura 11: Matriz de confusão utilizada na avaliação dos classificadores.....	41

CAPÍTULO II

Figura 1: Imagens térmicas dos enquadramentos anterolateral direito (A), esquerdo (B), posterior (C) e inferior (D).....	57
Figura 2: Seleção de pontos com o software FLIR Tools.....	57
Figura 3: Imagens térmicas em escala de cinza para os enquadramentos anterolateral direito (A), anterolateral esquerdo (B), posterior (C) e inferior (D)	58
Figura 4: Fluxograma do funcionamento do algoritmo proposto.....	59

Figura 5: Código desenvolvido para segmentação das imagens térmicas de mastite bovina.....	61
Figura 6: Resultado da segmentação com base na temperatura da região de interesse para os animais saudáveis (AI, BI, CI, DI), com mastite subclínica (AII, BII, CII, DII) e clínica (CIII DIII).....	62
Figura 7: Imagens obtidas pelo algoritmo de segmentação e imagens térmicas utilizadas para validação pelo software FLIR Tools para os enquadramentos anterolateral direito (A), esquerdo (B).....	63

CAPÍTULO III

Figura 1: Imagens térmicas dos enquadramentos anterolateral direito (A), esquerdo (B) e posterior (C).....	74
Figura 2: Imagens térmicas de mamografia com lesão benigna (A) e sem lesão (B), utilizadas na fase de treinamento da rede.....	74
Figura 3: Procedimento geral do aprendizado por transferência sequencial proposto.....	75
Figura 4: Resultados da imagem após o uso do aumento de dados.....	76
Figura 5: Arquitetura da rede ResNet.....	76
Figura 6: Arquitetura da rede convolucional.....	77
Figura 7: Fluxograma do modelo Mastitis – ResNet50.....	78
Figura 8: Fluxograma do modelo Mammo_Mast_ImageNet – ResNet50.....	80
Figura 9: Fluxograma do modelo Mammo_mastitis – ResNet50.....	81
Figura 10: Processo de formação de aprendizagem por transferência sequencial (STL – ResNet50).....	82
Figura 11: Curvas de acurácia e perda no treinamento e teste para os modelos utilizados nas redes.....	84
Figura 12: Matrizes de confusão dos quatro modelos empregados na classificação das imagens (0 – animal saudável; 1 – animal com mastite subclínica).....	85

CAPÍTULO IV

Figura 1: Abordagem de aprendizagem por transferência.....	100
Figura 2: Procedimento geral do aprendizado por transferência sequencial.....	101
Figura 3: Imagens térmicas de mamografia lesão benigna (A) e sem lesão (B) utilizadas na fase de treinamento da rede.....	102
Figura 4: Imagens térmicas dos enquadramentos anterolateral direito (A), esquerdo (B) e posterior (C).....	103
Figura 5: Resultados da imagem após o uso do aumento de dados.....	104
Figura 6: Otimização Bayesiana no sistema desenvolvido.....	106
Figura 7: Curvas de acurácia e perda no treinamento e teste para os modelos ajustados.....	108
Figura 8: Gráficos da otimização Bayesiana. (A) Distância entre as avaliações consecutivas, (B) Precisão vs. Iteração.....	109
Figura 9: Matrizes de confusão dos quatro modelos empregados na classificação das imagens (0 – animal saudável; 1 – animal com mastite subclínica).....	110

CAPÍTULO V

Figura 1: Imagens térmicas de mamografia lesão benigna (A) e sem lesão (B) utilizadas na fase de treinamento da rede.....	120
Figura 2: Imagens térmicas dos enquadramentos anterolateral direito (A), esquerdo (B) e posterior (C).....	122
Figura 3: Resultados da imagem após o uso do aumento de dados.....	123
Figura 4: Procedimento geral do aprendizado por transferência sequencial utilizado neste estudo.....	123
Figura 5: Diagrama de um CBAM.....	124
Figura 6: Diagrama de cada submódulo de atenção. O lado superior é o módulo de atenção do canal e o lado inferior é o módulo de atenção espacial.....	124
Figura 7: Modelo proposto STL_Bayesian_CBAM- ResNet50.....	126

Figura 8: Arquitetura geral dos modelos usados neste estudo. O lado esquerdo (a) é o modelo pré-treinado e o lado direito (b) é o modelo pré-treinado integrado ao CBAM.....	127
Figura 9: Os mapas de atenção destacando as regiões nas imagens que são mais discriminativas usadas para classificação de imagens de animais saudáveis (A e C) e animais com mastite subclínica (B e D).....	129
Figura 10: Curvas de acurácia e perda no treinamento e teste para os modelos ajustados.....	130
Figura 11: Matrizes de confusão dos quatro modelos empregados na classificação das imagens (0 – animal saudável; 1 – animal com mastite subclínica).....	131

Lista de Tabelas

CAPÍTULO II

Tabela 1: Valores referentes à estatística descritiva das temperaturas dos quartos.....60

CAPÍTULO IV

Tabela 1: Plataforma experimental.....105

Tabela 2: Hiperparâmetros e espaço de busca.....107

Tabela 3: Melhor conjunto de hiperparâmetros inferidos pelo modelo substituto

Bayesiano.....111

CAPÍTULO V

Tabela 1: Hiperparâmetros e espaço de busca.....128

Tabela 2: Melhor conjunto de hiperparâmetros inferidos pelo modelo substituto

Bayesiano.....132

RESUMO

O Brasil ocupa posição de destaque no setor produtivo leiteiro mundial. No entanto, este setor enfrenta um entrave bastante conhecido pelos produtores, a mastite bovina. Ela provoca muitas perdas produtivas, sendo necessário o desenvolvimento de ferramentas que possibilitem a sua detecção precoce, diminuindo o tempo, custo e subjetividade associados à determinação do diagnóstico de mastite subclínica. Neste sentido, objetivou-se com esta pesquisa desenvolver metodologia computacional capaz de receber imagens térmicas digitais, que permita sua segmentação e classificação automática, auxiliando no diagnóstico de mastite bovina. O levantamento de dados foi realizado em três unidades de produção de leite, localizadas no município de Capoeiras e Pesqueira, na Mesorregião Agreste, Microrregião do Vale do Ipojuca, estado de Pernambuco e no Município de Russas, Ceará. Para desenvolvimento da metodologia automática de segmentação foram utilizadas imagens de 24 animais, em condições clínicas distintas (saudáveis, com mastite clínica e subclínica) determinadas conforme os critérios de seleção. As imagens térmicas do úbere dos animais foram obtidas por câmera termográfica por infravermelho, FLIR i60, obedecendo aos enquadramentos anterolateral esquerdo, anterolateral direito, posterior e inferior, quatro imagens por animal. Para o desenvolvimento das metodologias utilizando transferência de aprendizagem sequencial foram utilizadas 600 imagens do banco *MammoTherm* (câncer de mama humana) e 165 imagens de 360 x 360 pixels, referente ao banco de dados de 55 bovinos, classificados em grupos distintos "Saudável" e "Mastite Subclínica". A segmentação automática indicou representatividade da área segmentada de 19, 15, 37 e 36% do total de pixels para animais saudáveis [32,9 – 33,86 °C] ± 0,99. Para o quadro de mastite subclínica, a representação percentual variou de 21,84 a 69,5% do total de pixels [34,45 – 34,98 °C] ± 0,87. A representação dos animais com mastite clínica variou de 78,5 a 85,85% [35,34 – 35,75 °C] ± 0,67. O algoritmo para segmentação automática permitiu diferenciar as imagens dos animais saudáveis, com mastite subclínica e clínica. O modelo preditivo STL_bayesian_CBAM-ResNet50 foi o que alcançou melhor desempenho (97,28%) comparativamente aos demais modelos, 92,1% (STL_bayesian-ResNet50) e 88,03% (STL_ResNet50) respectivamente. A metodologia computacional aplicada ao estudo, a partir de imagens térmicas do úbere de vacas leiteiras, contribuiu significativamente para a detecção automática de animais saudáveis e animais com mastite subclínica.

Palavras-chave: imagem térmica, inteligência artificial, mastite bovina, processamento de imagens.

ABSTRACT

Brazil occupies a prominent position in the world dairy production sector. However, this sector faces an obstacle well known by producers, the bovine mastitis. It causes many production losses, and it is necessary to develop tools that enable its early detection, reducing the time, cost and subjectivity associated with the determination of the diagnosis of subclinical mastitis. Thus, the objective of this study was to develop a computational methodology capable of receiving digital thermal images, which allows segmentation and automatic classification, helping to diagnose bovine mastitis. The data survey was carried out in three milk production units, located in the municipalities of Capoeiras and Pesqueira, in the Mesoregion Agreste, Microregion of Ipojuca Valley, State of Pernambuco and in the Municipality of Russas, Ceará. To develop the automatic segmentation methodology, images from 24 animals were used, in different clinical conditions (healthy, with clinical and subclinical mastitis) determined according to the selection criteria. The thermal images of the udder of the animals were obtained by infrared thermographic camera, FLIR i60, obeying the left anterolateral, right anterolateral, posterior and inferior frames, four images per animal. For the development of the methodologies using sequential transfer learning, 600 images from the MammoTherm (human breast cancer) bank and 165 images of 360 x 360 pixels, referring to the database of 55 cattle, classified into distinct groups "Healthy" and "Subclinical Mastitis", were used. The automatic segmentation indicated representativeness of the segmented area of 19, 15, 37 and 36% of the total pixels for healthy animals [32.9 - 33.86 °C] ± 0.99. For the subclinical mastitis picture, the percentage representation ranged from 21.84 to 69.5% of total pixels [34.45 - 34.98 °C] ± 0.87. The representation of animals with clinical mastitis ranged from 78.5 to 85.85% [35.34 - 35.75 °C] ± 0.67. The algorithm for automatic segmentation allowed differentiating the images of healthy animals, with subclinical and clinical mastitis. The predictive model STL_bayesian_CBAM-ResNet50 achieved the best performance (97.28%) compared to the other models, 92.1% (STL_bayesian-ResNet50) and 88.03% (STL_ResNet50), respectively. The computational methodology applied to the study, from thermal images of the udder of dairy cows, contributed significantly to the automatic detection of healthy animals and animals with subclinical mastitis.

Keywords: thermal imaging, artificial intelligence, bovine mastitis, image processing.

1. INTRODUÇÃO GERAL

O Brasil ocupa uma posição de destaque no cenário mundial de produção de leite. No 2º trimestre de 2022, a produção de leite no país foi de 5,40 bilhões de litros, equivalente à redução de 7,6% em relação ao 2.º trimestre de 2021, e queda de 8,9% em comparação com o trimestre imediatamente anterior (IBGE, 2022).

Este setor enfrenta muitas perdas econômicas e um dos fatores que mais atua neste sentido é a mastite bovina, principalmente em ambientes com práticas higiênicas inadequadas que estimulam a proliferação de microorganismos contagiosos ou ambientais, ocasionando inflamação da glândula mamária e posterior diminuição da produção e da qualidade do leite (POSSENTI et al., 2018).

A mastite subclínica é o estágio inicial da doença, onde os sinais não são visíveis a olho nu (WATZ et al., 2019; McMANUS et al., 2016). Porém, é possível detectar o aumento da temperatura da superfície da pele do úbere de vacas de leite (BORTOLAMI et al., 2015). Neste estágio é possível detectar perdas na produtividade e grandes impactos econômicos aos produtores, sendo de grande importância o desenvolvimento de ferramentas para a detecção precoce, ajudando o produtor na tomada de decisão.

Os métodos de detecção da mastite bovina têm se desenvolvido intensamente ao longo dos anos, mas os métodos tradicionais de padrão ouro, contagem de células somáticas (CCS) e cultura microbiana (VIGUIER et al., 2009) apresentam alto custo, são trabalhosos, invasivos e dependem de intervenção humana.

Para mastite subclínica, os testes de triagem na fazenda são realizados com o California Mastitis Test (CMT) procedimento barato, rápido e de fácil diagnóstico (RUEGG, 2017), no entanto, é subjetivo, pois depende da interpretação humana, oferecendo menos precisão e confiabilidade (LIMA et al., 2018).

Neste sentido, a pecuária de precisão é um campo emergente que inclui tecnologias computacionais utilizadas para o desenvolvimento de ferramentas visando o monitoramento e gestão em tempo real das menores unidades de produção (animais), melhorando os processos produtivos como detecção precoce de doenças e automatização de tarefas como ordenha, pastoreio, alimentação e gestão eficiente de recursos (MAHMUD et al., 2021).

O emprego da termografia por infravermelho tem se destacado como uma tecnologia cada vez mais utilizada na pecuária de precisão, por se tratar de uma

técnica não invasiva de mapeamento térmico de um corpo a partir da radiação infravermelha emitida por ele, recebendo papel cada vez mais relevante como método seguro e eficaz no processo de tomada de decisão. Além disso, possibilita a digitalização da imagem em tempo real e a visualização da temperatura da superfície corporal, auxiliando no diagnóstico da origem da variação de temperatura (CHACUR et. al, 2016).

Desta forma, o emprego das técnicas de visão computacional, visando desenvolver ferramentas de auxílio ao diagnóstico automático baseado em imagens térmicas, tem sido bastante utilizadas, pois contemplam protocolos de aquisição, pré-processamento, segmentação, extração de atributos ou características de reconhecimento de padrões capazes de auxiliar na detecção precoce de doenças (GARCÍA et al., 2015).

2. HIPÓTESES

- O sistema automático de classificação de imagens térmicas do úbere de bovinos de leite pode diminuir a subjetividade e o custo referente aos métodos tradicionais de detecção de mastite, bem como o caráter invasivo dessas técnicas.
- A utilização de uma base de imagens térmicas de humanos (Mammo Therm) pode servir para classificar imagens de mastite bovina;
- O desenvolvimento de um modelo de classificação de imagens térmicas do úbere de bovinos de leite baseado em critérios de atenção pode ajudar no diagnóstico de mastite;
- A abordagem utilizando transferência de aprendizagem sequencial pode auxiliar à obtenção de um melhor desempenho na classificação de imagens do que a transferência de aprendizagem convencional.

3. OBJETIVOS

3.1. Geral

Esta pesquisa foi conduzida com o objetivo de desenvolver metodologia computacional capaz de receber imagens térmicas digitais, que permita sua classificação automática e auxilie no diagnóstico de mastite bovina, como ferramenta de auxílio à tomada de decisão.

3.2. Específicos

Dessa forma, os objetivos específicos são:

- Ampliar banco de dados de imagens de referência para detecção de mastite bovina;
- Testar metodologias para segmentação e classificação automática de quadros de mastite bovina;
- Desenvolver softwares para análise das imagens;
- Explorar a técnica de transferência de aprendizado;
- Explorar método de otimização e ajuste de hiperparâmetros;
- Explorar o mecanismo de atenção no modelo otimizado

CAPÍTULO I

Revisão Bibliográfica

4. REVISÃO BIBLIOGRÁFICA

4.1. Bovinocultura de leite

O setor leiteiro no Brasil tem passado por importantes transformações nas últimas décadas, registrando grande crescimento de produção e consumo, acompanhado de intensa modernização tecnológica. O maior direcionador de consumo de leite é a renda e esta variável foi a tônica da expansão desta cadeia produtiva nos últimos 30 anos (EMBRAPA, 2020).

No Brasil e no exterior crescem o número de produtores atraídos pelas novas ferramentas tecnológicas desenvolvidas por pesquisadores e empresas do setor. Elas têm promovido melhorias na gestão, aumentando a produtividade e reduzindo o número de horas trabalhadas. Esses recursos trazem para as fazendas informações úteis que podem ser processadas rapidamente por meio de sensores espalhados no campo para uma tomada de decisão rápida e certa. Para isso, o produtor pode contar com sistemas específicos capazes de melhorar a eficiência produtiva (EMBRAPA, 2022).

Nos últimos dois anos, este setor tem passado por grandes desafios que incluem aumento nos custos de produção, demanda enfraquecida e margens pequenas de lucros. O reflexo disso é a diminuição do setor ocasionada por recuos na produção, diminuição das importações e disponibilidade do produto em si. Especificamente, o ano de 2021 foi bastante complicado se comparado a 2020, onde houve crescimento do setor, apesar de todas as dificuldades que vieram após o início da pandemia da Covid-19 (EMBRAPA, 2022).

Desse modo, a disponibilidade do produto no país teve diminuição de 3,6%, o equivalente a 976 milhões de litros comparativamente ao ano de 2020, sendo o menor volume desde 2018. Esse foi o menor volume desde 2014 e está ligado diretamente a importação e ao desempenho da produção nacional (Figura 1).



Figura 1: Produção brasileira de leite sob inspeção em bilhões de litros.
 Fonte: Embrapa/IBGE/Ministério da Economia

No ranking da produção leiteira nacional, a região Sul ocupa a primeira posição, sendo responsável por cerca de 9,8 bilhões de litros adquiridos pelos laticínios. Em seguida, a região Sudeste com 9,5 bilhões de litros. As duas regiões juntas são responsáveis por 77% do leite inspecionado no Brasil, em 2021 (Figura 2). A região Sul em 2021 teve um aumento de 6% comparativamente a 2010. As demais regiões participam com 12%, 7,2% e 3,9% respectivamente, como o caso do Centro-Oeste, Nordeste e Norte. Entre os estados, o maior produtor continua sendo Minas Gerais, sendo responsável por 24,6% da produção (EMBRAPA, 2022).

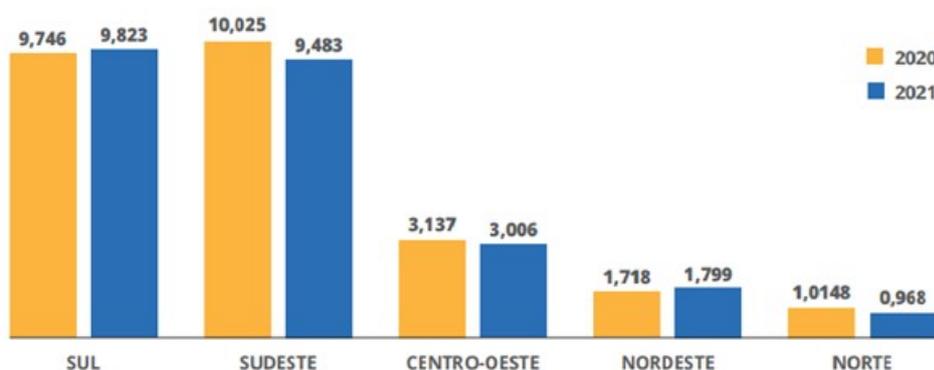


Figura 2: Produção de leite inspecionado nas regiões brasileiras volume de leite adquirido em 2020 e 2021.
 Fonte: Pesquisa Trimestral do Leite (IBGE)

4.2. Controle e sanidade do rebanho

A produção leiteira no Brasil constitui uma das principais atividades agropecuárias pela sua importância social e econômica, sendo um dos maiores setores de geração de renda nacional e arrecadação de tributos (IBGE, 2020).

Apesar dos altos volumes de leite produzidos, sua qualidade ainda é um dos maiores entraves ao desenvolvimento tecnológico e à consolidação da indústria de laticínios no país.

4.2.1. Boas práticas na ordenha

Fatores como a higienização das mãos do ordenhador, dos tetos, das teteiras e dos tanques de resfriamento estão relacionados com a presença ou não de contaminantes no leite. O propósito da higienização dos tetos e a realização do preparo do úbere previamente ao momento da ordenha é a diminuição da carga microbiana presente na pele dos tetos para resultar em um produto sem agentes contaminantes (MORÃO et al., 2018).

Segundo Acosta et al. (2016) a falta de conhecimento dos ordenhadores em relação à mastite, problemas com o saneamento ambiental e o manejo inadequado dos animais durante a ordenha são os principais fatores de risco identificados, que devem ser corrigidos para reduzir a incidência de casos da doença e otimizar a produção de leite no país. Devido à existência de deficiências como estas, ocorre a elevação e persistência da mastite subclínica, e esta persiste porque está diretamente ligada em todos os momentos durante a ordenha.

Neste contexto, é de grande importância o manejo correto durante a ordenha e procedimentos adequados como higienizar o ambiente, o animal, o profissional que realizará a ordenha e os materiais utilizados. Ao programar-se para realizar o controle e a prevenção de mastite, as propriedades devem-se considerar fatores de risco relacionados ao animal, ao manejo em geral, sendo necessário suporte que auxilie no controle dos patógenos ligados à mastite (LANGE et al., 2017).

Segundo Mota e Marçal (2019) conjuntamente com o manejo adequado corroboram fatores como sanidade, higiene e funcionalidade das instalações. Questões como essas convergem à manutenção de um ambiente limpo, e que proporcione um mínimo de conforto. A periodicidade da manutenção depende do manejo particular de cada propriedade, mas em função da presença de resíduos deve-se removê-los anteriormente ao acúmulo excessivo. Devem ser observadas também as condições da água nos quais os bebedouros devem ser de fácil acesso, livre para o consumo e higienizados periodicamente.

A sala de ordenha precisa ser planejada de modo a oferecer conforto aos animais. Devem ser posicionadas para não haver incidência de radiação solar direta

sobre os animais durante a ordenha, sendo necessário um pé direito mínimo de três metros, ser próxima ao estábulo e aos piquetes, para que as vacas possam chegar rapidamente à sala de ordenha. É importante, também, ter uma sequência de ordenha que priorize as novilhas na primeira linha de entrada e segregue as vacas com maior incidência de mastite e com alta mastite clínica e subclínica (ARCANJO et al., 2017).

Desse modo, as vacas com mastite clínica e as cronicamente infectadas com *S. aureus*, deverão ser ordenhadas separadamente e seu leite descartado ou fornecido aos bezerros. Quanto ao controle de casos de mastite bovina, devem ser implantadas ferramentas para diagnóstico e monitoramento rotineiro. Além dessas ferramentas, é de suma importância que haja um controle de informações, pois elas poderão orientar, quantos casos foram graves, se os protocolos de tratamento foram eficazes, qual a incidência de novos casos de mastite, sendo considerado um caso clínico novo quando ocorre o aparecimento de novos sinais clínicos 14 dias após o desaparecimento do caso anterior (SANTOS; FONSECA, 2019).

4.2.2. Identificação da mastite

A mastite bovina, como também é conhecida, é uma doença complexa associada a vários fatores, incluindo fatores intrínsecos (idade, paridade, estágio de lactação e estado de saúde) e fatores extrínsecos (higiene do úbere, material de cama, máquina de ordenha, gestão, clima e região) (GAO et al., 2017).

A forma clínica é diagnosticada pelo quadro inflamatório mais acentuado, como edema, aumento de temperatura, endurecimento e dor na glândula mamária, aparecimento de grumos, pus ou alterações nas características no leite. Para sua detecção realiza-se exame criterioso da glândula mamária e o teste da caneca de fundo preto (Figura 3A). Na forma subclínica, não ocorrem mudanças visíveis no aspecto do leite ou do úbere, mas sim, uma infecção assintomática onde ocorrem principalmente mudanças na composição do leite, detectada pelo *California Mastitis test* (CMT) (SÁ et al., 2018) (Figura 3B).



Figura 3. Teste da caneca de fundo escuro (A) e California Mastitis Test (CMT) (B).

Fonte: CHAPAVAL (2016) e RENNO et al., (2016).

4.2.3. Métodos de detecção

Os métodos de detecção da mastite bovina têm se desenvolvido intensamente ao longo dos anos. Os métodos tradicionais de padrão ouro, incluindo contagem de células somáticas (CCS) e cultura microbiana ainda são dominantes em termos de uso atual (VIGUIER et al., 2009).

Quando ocorre uma infecção na glândula mamária, a mastite pode se apresentar de forma subclínica, ou seja, sem manifestações de sinais clínicos ou alterações visíveis (SANTOS; FONSECA, 2019). Os testes de triagem na fazenda tradicionalmente realizados são o *California Mastitis Test* (CMT) que fornece um procedimento barato, rápido e fácil (RUEGG, 2017). Porém, quando usado sozinho, o CMT oferece menos precisão e confiabilidade devido à sua subjetividade (ASHRAF e IMRAM, 2018; LIMA et al., 2018).

A quantidade de células somáticas no sangue são indicativos do estabelecimento de uma infecção intramamária, considerada um indicador global para detecção de mastite e amplamente utilizada, porém, necessita de pessoal qualificado para operar (ASHRAF e IMRAM, 2018).

A Contagem de Células Somáticas pode ser realizada por meio de amostras do tanque ou de amostras individuais de cada vaca. A CCS do tanque representa uma média da CCS individual das vacas, no entanto, quando há vacas com mastite clínica ou vacas com mastite crônica, são normalmente ordenhadas separadamente, não incluindo a CCS na avaliação do tanque. Devido a exigências de legislação, os laticínios possuem uma rotina de coleta de amostras mensais do tanque de cada produtor, monitorando assim a CCS de cada propriedade, além de que alguns bonificam o produtor no pagamento do

leite quando a CCS fica dentro do exigido pela legislação (médias geométricas trimestrais de no máximo de 500.000 cS/ml) (SANTOS; FONSECA, 2019).

Quando a vaca é sadia, geralmente a CCS se apresenta menor que 100.000 cS/ml, enquanto quando há uma infecção, a CCS é maior que 200.000 cS/ml. A partir da CCS, podemos observar a prevalência da mastite subclínica no rebanho, qual a incidência de mastite subclínica, qual a taxa de vacas crônicas no rebanho, prevalência de mastite subclínica em vacas recém-paridas e a prevalência da mastite subclínica em relação ao estágio da lactação (SANTOS; FONSECA, 2019).

Já o teste da caneca de fundo escuro é utilizado nas ordenhas diariamente. Com ele é possível detectar uma mastite clínica. A mastite clínica apresenta alterações visuais no leite, como grumos, coágulos, pus, sangue ou o leite de forma aquosa, portanto, este teste deve ser realizado anteriormente à ordenha, retirando os primeiros jatos de leite na superfície escura do fundo da caneca, podendo visualizar quando há alterações do leite. O exame do úbere e da vaca também podem ser indicativos da apresentação de mastite clínica. Podem ser observadas, alterações visíveis no leite, inchaço do úbere, endurecimento do quarto mamário afetado, dor e rubor (SANTOS; FONSECA, 2019).

O *California Mastitis Test*, também chamado de CMT é um teste rápido, fácil e prático que pode ser realizado em campo, considerado de baixo custo. O teste pode ser realizado na fazenda para estimativa de CCS, mas tem uma desvantagem potencial, incluindo resultados falsos positivos / negativos (ASHRAF e IMRAM, 2018).

Uma ferramenta potencial que vem sendo aplicada nas fazendas é a medição da temperatura da superfície da pele do úbere por termografia infravermelha. Ela vem sendo utilizada em fazendas na determinação da mastite bovina (HOVINEN et al., 2016; VIGUIER et al., 2009).

4.3. Influência dos fatores abióticos na saúde do rebanho

A pecuária leiteira, ao longo dos anos, vem trabalhando em pesquisas que analisam o efeito da temperatura no ambiente de produção. O Brasil é um país tropical com temperaturas médias entre 20° C e a 32°, chegando a temperaturas entre 35 e 38°C, e isso é um dos principais desafios para os sistemas produtivos que incluem a pecuária leiteira, no qual essas temperaturas são consideradas altas para bovinos especializados em produção de leite (REZENDE et al., 2016).

O estresse térmico é considerado um entrave relacionado ao manejo de animais na atividade leiteira em países de climas tropical e subtropical por causar redução na

produtividade e mudanças nas características químicas do leite, redução na ingestão de alimentos e aumento na ingestão de água. Ele também aumenta o metabolismo basal dos animais ocasionando a diminuição da produção de leite (TAO et al., 2020).

Quando relacionado à mastite pode contribuir com o enfraquecimento do sistema imunológico dos animais, facilitando a infecção por mastite de úbere. As altas temperaturas e umidade elevada provocam redução da imunidade dos animais, ocasionando ataque de doenças e o aparecimento de mastite causada por bactérias (PRAGNA et al., 2017).

O estresse térmico afeta a glândula mamária, pois favorece a sobrevivência e proliferação de patógenos no ambiente, reduzindo a resistência do animal, uma vez que os eles apresentam redução na ingestão de alimento e conseqüente consumo deficiente de nutrientes essenciais para o sistema imune, como vitaminas essenciais (SANTOS; FONSECA, 2006).

Em situações de estresse térmico por calor, além de aumento do aparecimento de doenças, em casos extremos pode resultar em morte do animal. Há evidências de que cargas elevadas de calor podem comprometer a saúde do útero (DUBOIS; WILLIAMS, 1980), do úbere (NORMAN et al., 2000) e causar doenças metabólicas (WHEELOCK et al., 2010).

Alguns autores como Rezende et al. (2016) avaliando as interferências do estresse térmico em vacas leiteiras verificaram que no verão, em função de maior umidade relativa, a temperatura corporal dos animais aumenta, o que pode contribuir com o aumento da temperatura uterina, responsável pela redução da taxa de concepção e que a temperatura retal é um fator que auxilia para determinação do equilíbrio calórico e que pode ser usado na avaliação do estresse.

Nascimento et al. (2017) avaliaram o impacto da temperatura do ar na produção de leite e na transferência de calor de vacas da raça holandesa quando mantidas em sistemas de criação sem o uso de climatização durante a estação do verão no estado do Paraná e verificaram que a temperatura do ar é uma variável que afeta diretamente a produção de leite de vacas holandesas em qualquer estágio da fase de lactação. A influência negativa da temperatura do ar é mais severa durante o período vespertino, em que os animais desviam parte da energia corporal para a manutenção da temperatura corporal, diminuindo a produção de leite.

Santana et al. (2018) relataram que o número de novilhas prenhes reduziu com o aumento do ITU, em que uma novilha nelore exposta a um ambiente com ITU de 88,

reduziu em 4,67% as chances de parir em relação a uma novilha que estava exposta a ITU de 82,5, durante a estação reprodutiva. Além disso, a temperatura corporal das vacas receptoras é crítica durante as fases como a da transferência de embrião. Assim, tratamentos hormonais para apoiar a função do corpo lúteo e sobrevivência embrionária são mais eficientes se os animais mantiverem a temperatura corporal normal, dado que os efeitos do estresse térmico na fertilidade são de natureza multifatorial (WOLFENSON & ROTH, 2019).

4.4. Zootecnia de precisão

No Brasil, o conceito de zootecnia de precisão foi originalmente definido como um pacote tecnológico que considera as características tecnológicas do sistema em relação ao controle e à aquisição das informações e das variáveis do processo de produção. (SILVA e NÄÄS, 1998).

Do termo em inglês *Precision livestock farming* foi definido como o manejo da produção animal utilizando princípios e tecnologia de engenharia de processos. Baseado no uso de tecnologias da informação, modelagem, sensores, atuadores e registros automatizados de dados passíveis de interpretação, favorecendo e auxiliando nas demandas do sistema de produção e do mercado (PANDORFI, ALMEIDA e GUISELINI, 2012)

Ao longo da sua história, no cenário produtivo e científico brasileiro, a definição de Zootecnia de Precisão passou por diversas atualizações, sempre acompanhando as novas tendências tecnológicas. Neste contexto, os avanços desta área se voltaram principalmente ao desenvolvimento de dispositivos eletrônicos e métodos matemáticos para a coleta de dados e foram fundamentais para o sucesso dos processos de digitalização das fazendas (CASTRO JÚNIOR et al., 2020).

Portanto, a Produção Animal atual se dirige a todo o aparato digital utilizado a partir da coleta de dados até a tomada de decisão nas propriedades rurais, possibilitando: a aquisição de dados de forma automatizada e em tempo real. O gerenciamento integrado destes dispositivos (utilizando computação em nuvem e IoT); tomada de decisão de forma mais assertiva (com algoritmos de IA) e maior interação e customização com o usuário ao longo deste processo (por meio de softwares e plataformas de gestão personalizados) (CASTRO JÚNIOR et al., 2021).

A Figura 4 destaca os principais conceitos utilizados na produção animal atual e se referem a quatro elementos que desenham um sistema: a coleta de dados por

dispositivos de hardware; a transmissão de dados; o processamento e armazenamento dos dados e a visualização/manipulação de dados pelas interfaces homem/máquina.

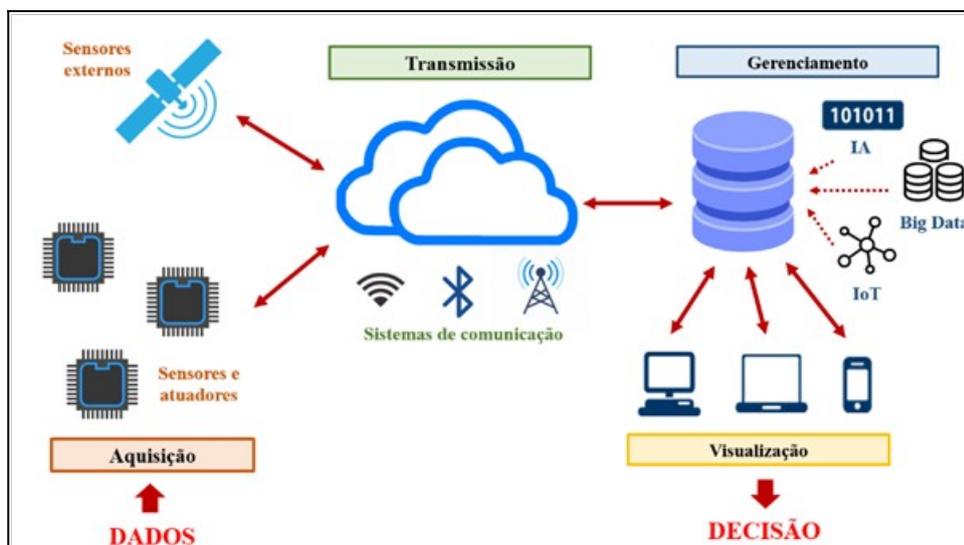


Figura 4: Aparato tecnológico na zootecnia de precisão.
Fonte: CASTRO JÚNIOR et al., (2021)

Com relação à aquisição dados, cada vez mais tem sido desenvolvidos dispositivos para os mais diversos objetivos: monitoramento de medições relacionadas ao ambiente, muito destaque se dá para as características físicas do ar (temperatura ambiente, umidade relativa, velocidade do vento e radiação), o diagnóstico de estresse térmico (OLIVEIRA JUNIOR et al., 2018).

Quando se trata da avaliação fisiológica dos animais, muito se discute sobre a eficiência dos métodos de coleta de dados e substituição por sensores não invasivos, sendo fortemente incentivados, e grande importância são dadas àqueles que promovem a substituição destas técnicas consideradas invasivas pela avaliação não invasiva ou indireta dos animais (CASTRO JÚNIOR et al., 2020).

Com relação à análise de dados obtidos através dos sensores, a modelagem computacional vem sendo amplamente utilizada para a determinação de modelos de predição na zootecnia de precisão, por meio de técnicas como mineração de dados, redes neurais artificiais, lógica fuzzy. São cada vez mais exigidas técnicas de refinamento, aprendizagem e modelagem, devido ao grande volume de dados gerados, requerendo maior atenção na seleção e refinamento das informações coletadas e seleção de dados tanto para o treinamento do sistema quanto para a validação dos modelos propostos (MOROTA et al., 2018).

4.5. Uso da termografia por infravermelho na produção animal

Tecnologias inovadoras podem contribuir consideravelmente para o avanço das pesquisas na agropecuária. Na bovinocultura, os maiores desafios são determinar indicadores do estado dos animais com maior precisão e rapidez. Os métodos empregados normalmente são coleta de sangue, avaliação da temperatura retal, sensores corporais cirurgicamente implantados, dentre outros que envolvem a manipulação dos animais e apesar de ser eficaz são invasivos e geram estresse (EMBRAPA, 2020).

A termografia por infravermelho pode ser definida como uma técnica de mapeamento térmico de um corpo, a partir da radiação infravermelha. Além disso, com ela é possível analisar condições como o bem-estar e conforto térmico de animais de produção, sendo possível realizar diagnósticos diversos (MENEGASSI et al., 2018).

A técnica de infravermelhos é baseada no princípio de que todos os corpos formados por matéria emitem quantidades variáveis de radiação térmica devido à agitação térmica de átomos e moléculas dos quais são constituídos. Quanto maior a agitação, mais quente se encontra o objeto, e mais radiação ele emite (EMBRAPA, 2020).

A radiação emitida pode estar situada nas faixas de ultravioleta, visível, infravermelho e até na faixa de microondas do espectro eletromagnético, em comprimentos que variam de 760 nm a 1 mm (Figura 5). Neste contexto, a maioria da energia emitida pelos materiais, está dentro da faixa do infravermelho.

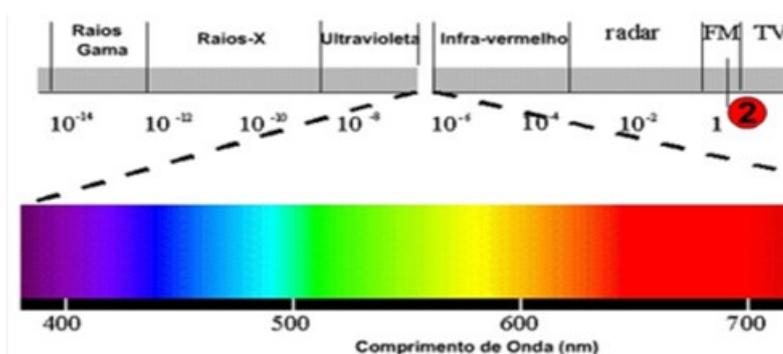


Figura 5. Espectro eletromagnético.

Fonte: <https://bioinformaticacc.wordpress.com/2012/05/31/espectro-letromagnetico/>

Considerando que diferentes objetos apresentam emissividades distintas e interagem de maneira própria com o ambiente, a fim de estabelecer um balanço entre a radiação que é absorvida e a emitida para o ambiente, a capacidade que o objeto

apresenta para irradiar energia é comparada com a de um “corpo negro perfeito”, obedecendo à Lei de Stefan-Boltzmann (Equação 1). Este, por sua vez, pode absorver e emitir 100% de toda a radiação incidente sobre ele, independentemente de seu comprimento de onda e direção de incidência, dependendo apenas de sua temperatura. Em uma escala de zero a um, a emissividade desse objeto é considerada um, emissor perfeito (LAUBEUR et al., 2017).

$$W = \epsilon \cdot B \cdot T^4 \quad (1)$$

em que:

W: taxa de emissão de energia radiante (W/m^2); ϵ : emissividade do corpo (adimensional); B: constante de Stefan-Boltzmann ($5,7 \cdot 10^{-8} \text{W} \cdot \text{m}^{-2} \cdot \text{K}^{-4}$);

T: temperatura absoluta do corpo (K).

Diante deste contexto, os materiais que apresentam superfícies de baixa reflexão apresentam alta emissividade ($\epsilon = 0,80$ a $0,95$), enquanto materiais orgânicos apresentam $0,95$ e $0,99$ (FERREIRA et al., 2009), semelhante à pele humana e de animais (DAS et al., 2016). Assim, os sensores, ao identificar uma variação térmica, captam essa radiação emitida e a convertem em sinais elétricos amplificados (Figura 6), que a seguir são transformados e convertidos em pixels de diferentes escalas de cores, gerando uma imagem térmica, denominada “termograma”.

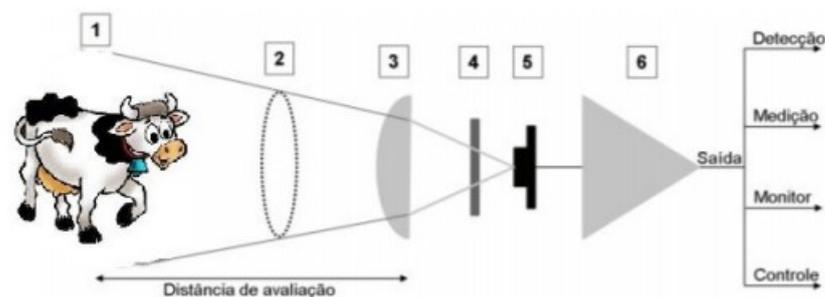


Figura 6: Diagrama esquemático do sistema óptico de um termovisor e conversão da energia térmica, onde: 1) superfície alva (que emite energia infravermelha); 2) campo de visão; 3) lente coletora de energia; 4) filtro para a passagem da banda espectral selecionada; 5) detector conversor de energia infravermelha em sinal elétrico, e; 6) amplificador e condicionador do sinal.

Fonte: Adaptado de Maldague (2001).

4.5.1. Termografia por infravermelho como ferramenta no diagnóstico veterinário

A termografia por infravermelho vem sendo utilizada na medicina humana há mais de 50 anos para diagnósticos diversos. Na medicina veterinária foi inicialmente aplicada em equinos no ano de 1960 e vem sendo empregada de diversas formas como ferramenta de triagem diagnóstica para guiar o manejo terapêutico e avaliar a resposta em tratamento de longo prazo (SMITH, 1964).

Os princípios iniciais da termografia estão relacionados com a descoberta do Sir William Herschel, que em 1800 fez, dentre várias, a descoberta da radiação térmica, essa luz invisível, mais tarde chamada de infravermelho ou radiação infravermelha (RING, 2000, HERSCHEL, 1800). Em seu experimento, Herschel decidiu medir a temperatura após o vermelho e descobriu que nesta região, mesmo não tendo luz, a temperatura aumenta e possui índices mais elevados.

O método de termografia infravermelho vem sendo amplamente empregado na Medicina Veterinária, tanto em áreas clínicas como em pesquisas, tendo aplicabilidade nas mais variadas espécies (ÁVILA FILHO, SANTOS & SILVA, 2020). Ela tem sua utilização na área da saúde desde a década de 50 se estendendo a diagnósticos diversos, dentre eles a detecção de câncer de mama (NG, 2009). Na Medicina Veterinária, essa tecnologia tem sido uma ferramenta muito útil para fins diagnósticos como, por exemplo, a detecção de mastite subclínica (DA SILVA et al., 2019; ZHANG et al., 2020) e atualmente algumas ferramentas têm sido desenvolvidas a partir das imagens para essa finalidade (MARRERO et al., 2020; ZANINELLI et al., 2018; WATZ et al., 2019).

4.6. Influência das variáveis meteorológicas sobre a medição de temperaturas através da termografia

Com a evolução do conhecimento científico e dos equipamentos para medição de temperatura no infravermelho também se modificaram os procedimentos adotados nos ensaios. O procedimento padrão para utilização destes equipamentos consiste em registrar a imagem do objeto baseada na radiação da superfície de um determinado objeto, convertida em outra imagem a ser analisada computacionalmente (SAKAMOTO e FIORITI, 2017).

A análise dos termogramas consiste no registro da diferença local da temperatura superficial na superfície, verificando as diferenças de cores registrada, indicando assim

a existência de uma anomalia, sendo necessário registrar e introduzir uma série de parâmetros, tais como, a temperatura ambiente, umidade relativa, distância à superfície e emissividade (SAKAMOTO e FIORITI, 2017).

A irradiância refletida é diretamente afetada pela atmosfera e pela superfície no momento do registro da imagem, devido aos fenômenos de espalhamento, absorção e refração da energia eletromagnética. Neste sentido, para amenizar os principais efeitos atmosféricos na irradiância de uma cena, devem ser realizados processos denominados correção atmosférica (WEISS et al., 2015).

Estes procedimentos de correção do termograma foram desenvolvidos para imagens multiespectrais, caracterizam-se por serem modelos do tipo ordinário discreto em que se obtém um único valor de correção para toda a cena em estudo, com base apenas na calibração linear. Não obstante, com o surgimento da espectroscopia de imageamento, verifica-se uma tendência para modelos de correção atmosférica do tipo distribuído, utilizando a calibração linear ponderada, em que é realizado um tratamento específico de pixel a pixel. Portanto, para fazer uma correção atmosférica, é necessário conhecer dados referentes ao perfil atmosférico, como quantidade de vapor d'água, umidade relativa, temperatura e pressão (SOUZA e SILVA, 2005).

4.7. Visão computacional na produção animal

Os sistemas que utilizam técnicas de visão computacional recorrem a algoritmos específicos para identificar elementos específicos e determinadas características de interesse nas imagens capturadas. Os métodos baseados em Inteligência Artificial (IA) tem se destacado para tal aplicação, caracterizando-se por algoritmos que simulam a capacidade humana de raciocínio e tomada de decisão. Um dos ramos da IA bastante utilizados em sistemas de visão de computacional é a aprendizagem de máquina (Machine Learning), que contempla técnicas baseados em algoritmos construídos pela exposição a exemplos (treinamento). Sendo fortemente impulsionada pelos avanços na capacidade de processamento computacional (FERNANDES et al., 2018).

As ferramentas de Aprendizado de Máquina têm sido utilizadas para análise de grandes volumes de dados e para proposição de soluções para problemas em sistemas complexos em diversas áreas, incluindo a produção agropecuária (KAMILARIS; PRENAFETA-BOLDÚ, 2018; KAMILARIS; KARTAKOULLIS; PRENAFETA-BOLDÚ, 2017). Diversos estudos demonstram o potencial dessas técnicas para

interpretar características comportamentais e prever alguns parâmetros produtivos, bem como de bem-estar animal (PANDORFI et al., 2012).

4.7.1. Segmentação

Os melhores resultados obtidos a partir da análise de informações extraídas de uma imagem está diretamente ligada à qualidade do tratamento feito sobre a fonte. De acordo com Gonzalez e Woods (1987), as técnicas de extração de informação a partir de imagens fazem parte da análise de imagens, que para ser executada tem como passo inicial a realização de uma segmentação (Figura 7).



Figura 7. Exemplo de imagem segmentada.

Fonte: <https://www.facom.ufu.br/~backes/>

A segmentação da região de interesse de uma imagem é o processo que particiona a imagem em regiões ou objetos nos quais se propõe separar em regiões distintas nas quais cada uma contém pixels com atributos similares. Desta forma, podem-se extrair as regiões a serem analisadas do restante da imagem (BACKES, 2015).

Os métodos de segmentação podem ser categorizados em dois grupos, segmentação baseada em aresta e segmentação baseada em região (VALA e BAXI, 2013). A segmentação baseada em regiões semelhantes se dá por um critério específico, que é definido previamente. Desta forma, pixels semelhantes, baseado neste critério, pertencem ao mesmo grupo ou região.

As técnicas de segmentação de imagens térmicas têm sido muito úteis para fins diagnósticos no estudo da mastite por meio de imagens térmicas (DA SILVA et al., 2021; MARRERO et al., 2020; ZANINELLI et al., 2018; WATZ et al., 2019).

4.8. Análise de imagem aplicada

4.8.1. Redes neurais convolucionais

Uma rede neural convolucional (CNN) é uma arquitetura de rede neural artificial, variante do perceptron de múltiplas camadas (multicamadas) que, assim como as redes neurais já citadas anteriormente, são baseadas em um processo biológico: o processamento de dados visuais. As redes neurais convolucionais são comumente usadas em aplicações de detecção, classificação e reconhecimento em imagens e vídeos (Figura 8).

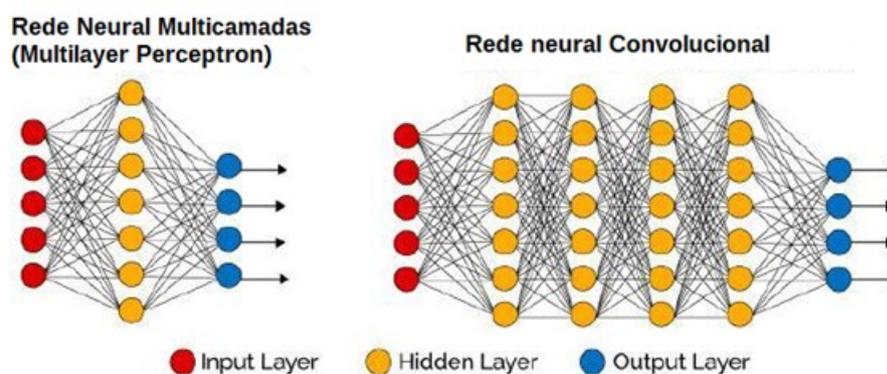


Figura 8: Rede Neural Multicamadas e Rede Neural Convolucional.
Fonte: Adaptado de Deep Learning Book (<https://www.deeplearningbook.com.br>)

As redes convolutivas tem como principal objetivo de extrair, processar e analisar informações do ambiente externo (LECUN; BENGIO; HINTON, 2015; PATRÍCIO; RIEDER, 2018; SILVA; PERES; BOSCARIOLI, 2016). Esta técnica tem sido largamente estudada e utilizada na agricultura, com aplicações na produção animal tanto para identificação animal, reconhecimento e análise do comportamento alimentar de vacas leiteiras (ACHOUR et al., 2021; LI et al., 2018; BELLO et al., 2020), dentre outras.

4.8.3. Transferência de aprendizagem

O estudo do *Transfer Learning* (TL) é um problema de aprendizagem de máquinas onde se utiliza o armazenamento do conhecimento adquirido ao resolver um problema, podendo ser aplicado em um problema diferente, podendo estes ter alguma semelhança ou relação (Figura 9).

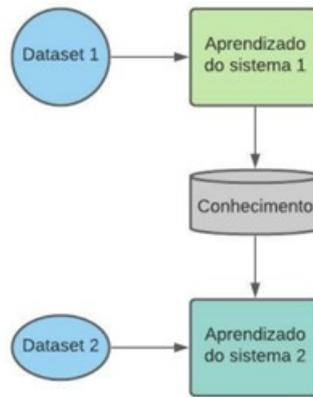


Figura 9: Processo de transfer learning.

Nesta técnica, o conjunto de dados ImageNet (Deng et al., 2009), que consiste em 1,2 milhão de imagens em 1.000 categorias, é normalmente usado para o pré-treinamento da rede. A rede convolucional pré-treinada no conjunto de dados ImageNet é então ajustada usando o pequeno conjunto de dados de destino. Nesse processo, são utilizados os mesmos pesos da rede após o pré-treino como ponto de partida para o treinamento da nova base. Inicialmente, as camadas originais totalmente conectadas são substituídas por novas camadas recém-inicializadas. Em seguida, as camadas de base da rede convolucional pré-treinada no ImageNet são congeladas enquanto as camadas superiores totalmente conectadas recém-adicionadas são treinadas. Finalmente, as camadas de base da CNN são parcial ou totalmente descongeladas para o ajuste fino de toda a rede. Esta abordagem é motivada pela intuição de que as camadas de rede inferiores geralmente transmitem recursos genéricos (por exemplo, bordas, cores), enquanto as camadas superiores tornam-se progressivamente mais adaptadas para a tarefa de classificação necessária (Figura 10).

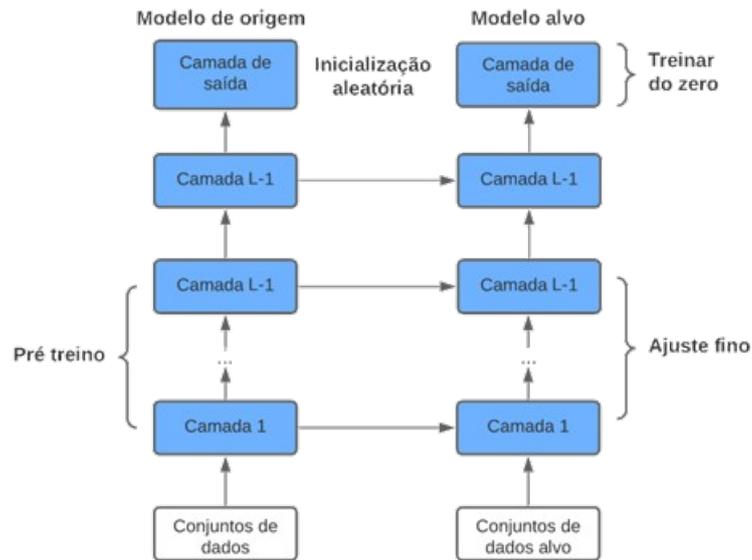


Figura 10: Arquitetura do ajuste fino da rede.

Fonte: Adaptado de Dive in to Deep Learning (https://d2l.ai/chapter_computer-vision/fine-tuning.html)

O Fine-Tuning (FT) ou ajuste fino, modifica os parâmetros de uma CNN existente para treinar uma nova tarefa. A camada de saída é estendida com pesos aleatoriamente iniciados para a nova tarefa e uma pequena taxa de aprendizado é usada para ajustar os parâmetros a partir de seus valores originais para minimizar a perda (GIRSHICK et al., 2014). O FT adapta os parâmetros compartilhados para torná-los mais discriminativos para a nova tarefa, e a baixa taxa de aprendizagem é um mecanismo indireto para preservar algumas das estruturas representacionais aprendidas nas tarefas originais.

Wang et al. (2020) utilizou um método de reconhecimento de rosto de bovinos baseado em transferência de parâmetros e aprendizado profundo. Huang et al. (2019) realizou medições da dimensão corporal dos bovinos com aprendizagem por transferência do sensor LiDAR.

A aprendizagem por transferência demonstrou atingir desempenho de ponta em várias aplicações, uma vez que facilita o treinamento rápido e confiável de redes convolucionais profundas quando pequenos conjuntos de dados estão disponíveis (MAZO ET AL., 2018; PRATAP & KOKIL, 2019).

Estudos como os de Mehrotra et al. (2020) utilizaram a técnica de *transfer learning* para classificar imagens de tumores cerebrais onde o aprendizado profundo demonstrou uma apresentação surpreendente, particularmente na segmentação e

classificação de tumores cerebrais. O arranjo projetado realiza um desempenho notável com a melhor precisão de 99,04%. O resultado alcançado significa a capacidade do algoritmo proposto para a classificação de tumores cerebrais.

Boumaraf et al. (2021) utilizaram método de transferência de aprendizagem baseado na estratégia de ajuste fino em blocos para classificação automatizada no diagnóstico de câncer e alcançaram resultados promissores e eficazes, superando o estado da arte recente

4.8.4. Avaliação dos classificadores

Existem, também, diversas métricas utilizadas para a avaliação dos classificadores, as mais comuns e as utilizadas em pesquisas são: acurácia (Equação 2), pontuação F1 score (Equação 3) e matriz de confusão (Figura 11). Para entender o significado dessas métricas, é necessário definir os conceitos por trás dos seus cálculos, são eles de: verdadeiro positivo (VP), falso positivo (FP), verdadeiro negativo (VN) e falso negativo (FN) (Figura 11). No contexto das imagens médicas, as seguintes definições são utilizadas: verdadeiro positivo: número de amostras rotuladas como doentes identificadas como doentes. Falso positivo: Número de amostras rotuladas como saudáveis identificadas como doentes. Verdadeiro negativo: Número de amostras rotuladas como saudáveis identificadas como saudáveis. Falso negativo: Número de amostras rotuladas como doentes identificadas como saudáveis. (BARATLOO et al., 2015). As métricas citadas são extraídas a partir das equações como segue:

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$F1 = \frac{2 \times \text{precisão} \times \text{recall}}{\text{precisão} + \text{recall}} \quad (3)$$

	Preditos	
Reais	Positivos	Negativos
Positivos	VP	FN
Negativos	FP	VN

Figura 11: Matriz de confusão utilizada na avaliação dos classificadores

Em que:

VP = Verdadeiros Positivos

VN = Verdadeiros Negativos

FN = Falso Negativo

FP = Falso Positivo

REFERÊNCIAS

ACHOUR, B.; BELKADI, M.; FILALI, I.; LAGHROUCHE, M.; LAHDIR, M. Image analysis for individual identification and feeding behaviour monitoring of dairy cows based on Convolutional Neural Networks (CNN). *Biosystems Engineering*, v.198, p. 31-49, 2020.

ACOSTA, A. C.; SILVA, L.B.G.; MEDEIROS, E. S. M.; PINHEIRO-JÚNIOR, J.W.; MOTA, R.A. Mastites em ruminantes no Brasil. *Pesquisa Veterinária Brasileira*. v.36, n.7, p. 565-573, 2016.

ARCANJO, A.H.M.; OLIVEIRA, P.C.S.; MOREIRA, L.C.; JAYME, C.G.; SOARES, N.A.; OLIVEIRA, A.R.; PEREIRA, K.A.; PEREIRA, A.; NOGUEIRA, M.A.R. Programa dos seis pontos de controle da mastite em rebanhos leiteiros. *Global Science and Technology*, v.10, n.01, p.78 – 88, 2017.

ASHRAF, A.; IMRAM, M. Diagnosis of bovine mastitis: from laboratory to farm. *Trop. Anim. Health Prod.* v.50, p. 1193–1202, 2018.

BACKES, A. R. Segmentação de imagens. Disponível em: <<http://www.facom.ufu.br/~backes/gsi058/Aula09-Segmentacao.pdf>> Acesso em 08/02/2021.

ÁVILA FILHO, S. H.; DOS SANTOS, T. P.; DA SILVA, L.A. Aspectos Gerais, Físicos e aplicabilidades médica veterinária da termografia infravermelho. *ENCICLOPÉDIA BIOSFERA*, Centro Científico Conhecer – Jandaia-GO, v.17 n.34, p. 44, 2020

BARATLOO, A.; HOSSEINI, M.; NEGIDA, A.; El ASHALD, G. Part 1: simple definition and calculation of accuracy, sensitivity and specificity. *Emergency*, v. 3, n. 2, p. 48-49, 2015.

BELLO, R.W.; TALIB, A.Z.H.; MOHAMED, A.S.A.B. Deep learning-based architectures for recognition of cow using cow nose image pattern. *Gazi University Journal of Science*, v.33, n. 3, p.831–844, 2020.

BOUMARAF, S.; XIABI, L.; ZHONGSHU, Z.; XIAOHONG, M.; FERKOUS. C. A new transfer learning based approach to magnification dependent and independent classification of breast cancer in

histopathological images. *Biomedical Signal Processing and Control*, v. 63, p.102192, 2021.

BORTOLAMI, A.; FIORE, E.; GIANESELLA, M.; CORRÓ, M.; CATANIA, S., & MORGANTE, M. Evaluation of the udder health status in subclinical mastitis affected dairy cows through bacteriological culture, somatic cell count and thermographic imaging. *Polish Journal of Veterinary Sciences*, v.18, n.4, p. 799–805, 2015.

CASTRO JÚNIOR, S. L.; BALTHAZAR, G.R.; ARNO, A.; VINÍCIUS, M.; CRUZ, A. SILVA, I. J. O. Produção animal 4.0: conceitos, aplicações e tendências. *ReviVale Araçuaí*, v. 1, n. 1, 2020.

CHACUR, M. G. M.; SOUZA, C. D.; ANDRADE, I. B.; BASTOS, G. P.; DEAK, F. L. G.; SOUZA, M. G. R.; CORNACINI, G. F.; MARQUES JUNIOR, A. de P. Aplicações da termografia por infravermelho na reprodução animal e bem-estar em animais domésticos e silvestres. *Revista Brasileira de Reprodução Animal*, v.40, n.3, p.88-94, 2016.

DA SILVA, R. A. B.; PANDORFI, H.; DE ALMEIDA, G. L. P.; DE ASSUNÇÃO MONTENEGRO, A. A.; DA SILVA, M. V. Spatial dependence of udder surface temperature variation in dairy cows with healthy status and mastitis. *Revista Brasileira de Saúde e Produção Animal*, 20, 2019.

DAS, R.; SAILO, L.; VERMA, N.; BHARTI, P.; SAIKIA, J.; IMTIWATI; KUMAR, R. Impact of heat stress on health and performance of dairy animals: A review, *Veterinary World*, v.9, n.3, p.260- 268, 2016.

DENG, J.; DONG, W.; SOCHER, R.; LI, L. J.; LI, K.; FEI-FEI, L. ImageNet: A Large-Scale Hierarchical Image Database. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*, 2009.

DUBOIS, P.R.; WILLIAMS, D. J. Increased incidence of retained placenta associated with heat stress in dairy cows. *Theriogenology*, v. 13, n. 2, p.115-121, 1980.

EMBRAPA. Aplicações da Termografia por Infravermelho (TIV) na bovinocultura de corte. 2020. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/214175/1/DOC-276-Finalem-Alta.pdf>> Acesso em 24/12/2020.

EMBRAPA. Anuário do leite 2022. Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1144110/anuario-leite-2022-pecuaria-leiteira-de-precisao>>. Acesso em 16/12/2022.

FERREIRA, F.; CAMPOS, W. E.; CARVALHO, A. U.; PIRES, M. F. A.; MARTINEZ, M. L.; SILVA, M. V. G. B.; VERNEQUE, R. S.; SILVA, P. F. Parâmetros clínicos, hematológicos, bioquímicos e hormonais de bovinos submetidos ao estresse calórico. *Arquivo Brasileiro de Medicina Veterinária e Zootecnia*, v.61, n.4, p.769-776, 2009.

FERNANDES, J. G. L.; SILVA, N. A. M. da; BROCK, T. R.; QUEIROGA, A. P. G. de.; RODRIGUES, L. C. Inteligência Artificial: Uma Visão Geral. Revista Eletrônica Engenharia Estudos e Debates, São José do Rio Preto, v. 1, n. 1, 2018.

GAO, J.; BARKEMA, H.W.; ZHANG, L.M.; LIU, G.; DENG, Z.J.; CAI, L.J.; SHAN, R.X.; ZHANG, S.Y.; ZOU, J.Q.; KASTELIC, J. P.; HAN, B. Incidence of clinical mastitis and distribution of pathogens on large Chinese dairy farms. Journal of Dairy Science, v. 100, p.4797- 4806, 2017.

GARCÍA, G. B.; SUAREZ, O. D.; ARANDA, J. L. E.; TERCERO, J. S.; GRACIA, I. S.; ENANO, N. V. Learning Image Processing with OpenCV. Packt Publishing, 2015.

GIRSHICK, R.; DONAHUE, J.; DARRELL, T.; MALIK, J. Rich feature hierarchies for accurate object detection and semantic segmentation. In: The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2014.

GONZALEZ, R. C.; WOODS, R. E. Digital image processing. New York: Addison-Wesley Publishing Company, Inc, 1987.

HERSCHELL, W. Experiments on the Solar and on the Terrestrial Rays that Occasion Heat; With a Comparative View of the Laws to Which Light and Heat, or Rather the Rays Which Occasion Them, Are Subject, in Order to Determine Whether They Are the Same, or Different. Part II; Philosophical Transactions of the Royal Society of London: Slough, UK, v. 90, p. 437–538, 1800.

HOVINEN, M.; SIMOJOKI, H.; POSO, R.; SUOLANIEMI, J.; KALMUS, P.; SUOJALA, L.; PYORALA, S. N-Acetyl - β -D-glucosaminidase activity in cow milk as an indicator of mastitis. Journal of Dairy Research. v. 83, p. 219–227, 2016.

HUANG, L.; GUO, H.; RAO, Q.; HOU, Z.; LI, S.; QIU, S.; WANG, H. Body dimension measurements of qinchuan cattle with transfer learning from liDAR sensing. Sensors (Switzerland), v.19, n. 22, p. 5046, 2019.

IBGE, 2022. Instituto Brasileira de Geografia e Estatística. Indicadores da pecuária. Disponível em:< <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?id=72380&view=detalhes>> Acesso em 16/12/2022.

KAMILARIS, A.; KARTAKOULLIS, A.; PRENAFETA-BOLDÚ, F.X. A review on the practice of big data analysis in agriculture. Computers and Electronics in Agriculture, Cambridge, v. 143, p. 23-27, 2017.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: a survey. Computers and Electronics in Agriculture, Cambridge, v. 147, p. 70-90, 2018.

LABEUR, L.; VILLIERS, G.; SMALL, A. H. H.; HINCH, G. N. N.; SCHMOELZL, S. Infrared thermal imaging as a method to evaluate heat loss in newborn lambs. Research Veterinarian Science, v.115, p.517–22, 2017.

LANGE, M.J.; ZAMBOM, M.A.; POZZA, M.S.S.; SIMÕES, G.H.; FERNANDES, T.; TININI, R.C.R.; FORNARI, J.; ANSCHAU F.A. Tipologia de manejo de

ordenha:análise de fatores de risco para a mastite subclínica. Pesquisa Veterinária Brasileira, v.37, n.11, 2017.

LANGONI, H.; SALINA, A.; OLIVEIRA, G.C.; JUNQUEIRA, N.B.; MENOZZI, B.D.; JOAQUIM, S.F. Considerações sobre o tratamento das mastites. Pesquisa Veterinária Brasileira v.37, n.11, p.1261-1269, 2017.

LABEUR, L.; VILLIERS, G.; SMALL, A. H. H.; HINCH, G. N. N.; SCHMOELZL, S. Infrared thermal imaging as a method to evaluate heat loss in newborn lambs. Research Veterinarian Science, v.115, p.517–22, 2017.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. Nature, London, v. 521, n. 7553, p. 436-44, 2015.

LI, Z.; GE, C.; SHEN, S.; LI, X. Cow individual identification based on convolutional neural network. ACM International Conference Proceeding Series, 2018.

LIMA, R.S.; DANIELSKI, G.C.; PIRES, A.C.S. Mastitis detection and prediction of milk composition using gas sensor and electrical conductivity. Food Bioprocess Technology, 2018.

MAHMUD, M.S.; ZAHID, A.; DAS, A.K.; MUZAMMIL, M.; KHAN, M.U. A systematic literature review on deep learning applications for precision cattle farming. Computers and Electronics in Agriculture, v.187, p. 106313, 2021.

McMANUS, C.; TANURE, C. B.; PERIPOLLI, V.; SEIXAS, L.; FISHER, V.; GABBI, A. M.; MNENEGASSI, 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, n.123, p. 10–16, 2016.

MARRERO, M.G.; RIJOS-FERNANDÉZ, C.; VÉLEZ-ROBLES, Y.; ORTÍZCOLÓN, G.; SANCHÉZ-RODRÍGUES, H.; JIMENÉZ-CABÁN, E.; CURBELORODRÍGUEZ, J. Short-milking-tube infrared temperature as a subclinical mastitis detection tool in tropical dairy farms. Applied Animal Science, v.36, p. 329-334, 2020.

MAZO, C.; BERNAL, J.; TRUJILLO, M.; ALEGRE, E. Aprendizagem de transferência para classificação de tecidos cardiovasculares em imagens histológicas Computer Methods and Programs in Biomedicine, 165, p. 69 – 76, 2018.

MEHROTRA, R.; ANSARI, M.A.; AGRAWAL, R.; ANAND, R.S. A Transfer Learning approach for AI-based classification of brain tumors. Machine Learning with Applications, 2020.

MENDES, C.C.T.; FRÉMONT, V.; WOLF, D.F. Exploiting Fully Convolutional Networks for Fast Road Detection. In 2016 IEEE International Conference on Robotics and Automation (ICRA), p. 3174-3179, 2016.

MENEGASSI, S. R. O.; PEREIRA, G. R.; DIAS, E. A.; ROCHA, M. K. da.; CARVALHO, H.R.; KOETZ JR, OBERST, E. R.; BARCELLOS, J. O. J. Infrared

thermography as a noninvasive method to assess scrotal insulation on sperm production in beef bulls. *First International Journal of Andrology*, p.3-8, 2018.

MILAN, H. F. M.; MAIA, A. S. C.; GEBREMEDHIN, K. G. Technical note: Device for measuring respiration rate of cattle under field conditions. *Journal of Animal Science*, v. 94, n.12, p. 5434– 5438, 2016.

MORÃO, R.P.; ALMEIDA, A.C.; MOURTHÉ, M.R.F.; MARCELO, N.A.; MAIA, P.H. B.B.; GOMES, L.V.; SILVA, F.E.G.; MATOS, A.S.F. Efeito de antisséptico contendo óleo essencial de alecrim pimenta (*Lippia origanoides* Cham.) nos tetos de vacas leiteiras e qualidade do leite. *Unimontes científica*, v.19, n.2, p.68-82, 2018.

MOROTA, G.; VENTURA, R.V.; SILVA, F.F. et al. Machine learning and data mining advance predictive big data analysis in precision animal agriculture. *Journal of Animal Science*, v.96, n.4, p.1540-1550, 2018.

MOTA, R. G.; MARÇAL, W. S. Comportamento e bem-estar animal de bovinos confinados: Alternativas para uma produção eficiente, rentável e de qualidade: Revisão bibliográfica. *Brazilian Journal of Hygiene and Animal Sanitary*, v.13, n.1, p. 125 – 141, 2019.

NASCIMENTO, S. T.; FONSECA, V. F. C.; MAIA, A. S. C.; SANTOS, V. M.; OLIVEIRA, E. M.; MÓS, J. V. N. Zootecnia de precisão e os desafios da ambiência na produção animal no Nordeste brasileiro. *Revista Científica de Produção Animal*, v.19, n.2, p.103-112, 2017.

NASCIMENTO, S. T.; MAIA, A. S. C.; GEBREMEDHIN, K. G.; NASCIMENTO, C.C.S. Metabolic-heat production and evaporation of poultry. *Poultry Science*, v. 96, n.8, p.2691-2698, 2017.

NASCIMENTO, S. T.; ROSSETTO, Y. P.; SILVA, A. A.; MAC-LEAN, P. A. B.; TENÓRIO, J. P. L. Influência da temperatura ambiente no verão na produção de leite de vacas holandesas. *Pubvet*, v.11, n.3, p.217-223, 2017.

NORMAN, H. D.; MILLER, R. H.; RIGHT, J. R. & WIGGANS, C. R. Herd and state means and somatic cell count from dairy herd improvement. *Journal of Dairy Science*. v. 83, p. 2805-2809, 2000.

NG, Y. E. K. A review of thermography as promising non-invasive detection modality for breast tumor. *International Journal of Thermal Sciences*, v. 48, p. 849-859, 2009.

OLIVEIRA JÚNIOR, Arilson José et al. Development of an android APP to calculate thermal comfort indexes on animals and people. *Computers and electronics in agriculture*, v. 151, p. 175-184, 2018.

PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. *Computers and electronics in agriculture*, Cambridge, v. 153, p. 69-81, 2018.

PANDORFI, H.; ALMEIDA, G. L. P.; GUISELINI, C. Zootecnia de precisão: princípios básicos e atualidades na suinocultura. *Revista Brasileira de Saúde e Produção Animal*, v. 13, n. 2, 2012.

PANDORFI, H.; SILVA, I.J.O.; GUISELINI, C. et al. Uso da lógica fuzzy na caracterização do ambiente produtivo para matrizes gestantes. *Engenharia Agrícola*, v.27, n.1, p.83-92, 2007.

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

POSSENTI, C.G.R.; HORN, R.C.; MORI, N.C.; RIBAS JÚNIOR, V., GOLLE, D.P.; KOEFENDER, J. Avaliação de Estresse Oxidativo no Plasma de Bovinos Leiteiros com mastite. *Ciência animal brasileira*, v.19, p. 1-9, 2018.

PRAGNA, P.; ARCHANA, P.R.; ALEENA, J.; SEJIAN, V.; KRISHNAN, G.; BAGATH, M.; MANIMARAN, A.; BEENA, V.; KURIEN, E.K.; VARMA, G.; BHATTA, R. Heat stress and dairy cow: impact on both milk yield and composition. *Journal of Dairy Science*, v.12, n.1, p. 1-11, 2017.

PRATAP, T.; KOHIL, P. Diagnóstico de catarata auxiliado por computador usando aprendizagem de transferência profunda. *Biomed Signal Process Control*, v. 53, p. 101533, 2019.

PULIDO-RODRÍGUEZ, L. F.; TITTO, E. A. L.; HENRIQUE, F. L.; LONGO, A. L. S.; HOOPER, H. B.; PEREIRA, T. L.; PEREIRA, A. M. F.; TITTO, C. G. Termografia infravermelha da superfície ocular como indicador de estresse em suínos na fase de creche. *Pesquisa Veterinária Brasileira*, v.37, n.5, p.453-458, 2017.

REZENDE, S. R.; MUNHOZ, S. K.; NASCIMENTO, M. R. B. M.; GUIMARÃES, J. L. N. Características de termorregulação em vacas leiteiras em ambiente tropical: revisão. *Veterinária Notícias*, v.21, p. 18-29, 2016.

RING, E.F.J. The discovery of infrared radiation in 1800. *Imaging Science Journal*. v.48, n.1, p.1-8, 2000.

RUEGG, P. L. A 100-year review: mastitis detection, management, and prevention. *Journal Dairy Science*. v.100, p. 10381–10397, 2017.

SANTOS, M. V; FONSECA, L. F. L. Controle da Mastite e Qualidade do Leite: Desafios e Soluções. Pirassununga: Edição dos Autores, 2019. 301 p.

SOUZA, J.D. de; da SILVA, B.B. Correção atmosférica para temperatura da superfície obtida com imagem tm – landsat. *Revista Brasileira de Geofísica*, n. 23, v.4, 2005.

SANTANA, M. A. de; PEREIRA, J. M. S.; SILVA, F. L. da; LIMA, N. M. de; SOUSA, F. N. de; ARRUDA, G. M. S. de.; LIMA, R. de C. F. de.; SILVA, W. W. A. da; SANTOS, W. P. dos. Breast cancer diagnosis based on mammary thermography and extreme learning machines. *Research on Biomedical Engineering*, 34(1), 45–53, 2018.

SÁ, J.P.N.; FIQUEIREDO, C.H.A.; NETO, O.L.S.; ROBERTO, S.B.A.; VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: Proceedings of the XXIX Conference on Graphics, Patterns and Images. [S.l.: s.n.], 2016.

SAKAMOTO, C.A., FIORITI, C. F. Study of relevant parameters in obtaining thermograms for diagnosis of pathological problems. REEC – Revista Eletrônica de Engenharia Civil, v. 13, n. 2, 2017.

SOUZA, J.D.; SILVA, B.B. Correção atmosférica para temperatura da superfície obtida com imagem TM – Landsat 5. Revista Brasileira de Geofísica, v.23, n.4, 2005.

SILVA, I.J. da; NÄÄS, Irenilza de Alencar. Zootecnia de Precisão: um novo conceito e um desafio para a Ambiência na engenharia agrícola. In: Notesalq, n.2., 1998.

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

SILVA, R. A. B. da; LIMA, J. P. S. do M.; PANDORFI, H.; ALMEIDA, G. L. P. de. Thermal Image Thresholding for Automatic Detection of Bovine Mastitis. International Journal of Computer Applications, n.183, v.14, p. 29–33, 2021.

SMITH, WM. Applications of thermography in veterinary medicine. Annals of the New York Academy of Sciences, n.121, v.1, p.248-54, 1964.

TAO, S. H. A. RIVAS, R. M. O.; MARINS, T. N.; CHEN, Y. C.; GAO, J., BERNARD, J. K. Impact of heat stress on lactational performance of dairy cows. Theriogenology, 150, p. 437-444, 2020.

TULLO, E. et al. Application note: labelling, a methodology to develop reliable algorithm in PLF. Computers and electronics in agriculture, Cambridge, v. 142, p. 424-428, 2017.

VALA, M. H. J.; BAXI, A. A. review on otsu image segmentation algorithm. International Journal of Advanced Research in Computer Engineering & Technology (IJARCET), v. 2, n. 2, p.387, 2013.

VIGUIER, C.; ARORA, S.; GILMARTIN, N.; WELBECK, K.; O’KENN Mastitis detection: current trends and future perspectives. Trends Biotechnol. v. 27, p. 486–493, 2009.

WANG, D.; TANG, J.; ZHU, W.; LI, H., XIN, J.; HE, D. Dairy goat detection based on faster R-CNN from surveillance video. Comput. Electron. Agric. v. 154, p. 443–449, 2020.

WATZ, S.; PETZI, W.; ZERBE, H.; RIEGER, A.; GLAS, A.; SCHROTER, W.; LANDGRAT, T.; METZNER, M. Automatic evaluation of infrared thermal images by computerized active shape modeling of bovine udders challenged with Escherichia coli. Journal Dairy Science, v. 102, p. 4541–4545, 2019.

WEISS, C.V da C.; CAMARGO, D.C.S.; ROSCA, E.H.; ESPINOZA, J. Análise comparativa entre métodos de correção atmosférica em imagens do sensor Operational Land Imager (OLI), plataforma Landsat 8. Scientia Plena, v.11, n. 2, 2015.

WHEELOCK, J.B., RP Rhoads , MJ Vanbaale , SR Sanders , LH Baumgard.Effects of heat stress on energetic metabolism in lactating Holstein cows. Journal Of Dairy Science, v. 93, n. 2, p.644-655, 2010.

WILLIAM HERSCHEL LL.D. F.R.S.Experiments on the refrangibility of the invisible rays of the sun , Philosophical Magazine Series 1, v.8, n.9, p. 9-15, 1800.

WOLFENSON, D.; ROTH, Z. Impact of heat stress on cow reproduction and fertility. Animal Frontiers, v.9, n. 1, p. 32-38, 2019.

ZANINELLI, M.; REDAELLI, V.; LUZI, F.; BRONZO, V.; MITCHELL, M.; DELL'ORTO, V.; BONTEMPO, V.; CATTANEO, D.; SAVOINI, G. First evaluation of infrared thermography as a tool for the monitoring of udder health status in farms of dairy cows. Sensors, v. 18, p.862, 2018.

CAPÍTULO II

Limiarização de imagens térmicas para detecção automática de mastite bovina

LIMIARIZAÇÃO DE IMAGENS TÉRMICAS PARA DETECÇÃO AUTOMÁTICA DE MASTITE BOVINA

RESUMO

Tecnologias disruptivas possuem grande importância para o avanço da ciência animal. A bovinocultura de leite é uma atividade de suma importância no cenário mundial, porém, entraves como a mastite ocasiona muitas perdas neste setor. Objetivou-se com este estudo desenvolver algoritmo para segmentação por limiarização e classificação automática de quadros clínicos de mastite bovina, bem como a sua validação. A pesquisa foi realizada em duas unidades de produção de leite, localizada no município de Capoeiras e Pesqueira, Pernambuco. A quantidade de amostras foi determinada conforme os critérios de seleção e totalizaram 24 animais (8 animais saudáveis, 8 com mastite subclínica e 8 com mastite clínica). As imagens térmicas do úbere dos animais foram obtidas a partir de uma câmera termográfica por infravermelho, nos enquadramentos anterolateral esquerdo, anterolateral direito, posterior e inferior, quatro imagens por animal, totalizando 96 imagens térmicas para análise de seus respectivos quartos mamários. As imagens foram submetidas à estatística descritiva. As medidas extraídas das imagens foram média, mediana, moda e desvio padrão da temperatura de superfície do úbere dos animais. O critério adotado para determiná-las foi a área de cobertura de cada úbere, constituindo uma matriz irregular definida a partir da seleção de pontos com o software FLIR Tools. Para a segmentação automática das imagens, foi desenvolvido um algoritmo em linguagem C++ utilizando a biblioteca OpenCV, para identificação da temperatura referente a cada pixel da imagem através da interpolação pela técnica de limiarização e quantificação de pixels do intervalo analisado de cada imagem. A segmentação automática indicou representatividade da área segmentada de 19, 15, 37 e 36% do total de pixels para animais saudáveis $[32,933,86 \text{ °C}] \pm 0,99$. Para o quadro de mastite subclínica, a representação percentual variou de 21,84 a 69,5% do total de pixels $[34,45 - 34,98 \text{ °C}] \pm 0,87$. A representação dos animais com mastite clínica variou de 78,5 a 85,85% $[35,34 - 35,75 \text{ °C}] \pm 0,67$. O algoritmo para segmentação automática permitiu diferenciar as imagens dos animais saudáveis e com mastite subclínica e clínica. A rotina implementada para determinar a temperatura de cada pixel da imagem foi coerente quando se comparou os resultados obtidos pelo software FLIR Tools auxiliando no diagnóstico referente ao quadro clínico dos animais.

Palavras-chave: análise de imagem, bovinocultura de leite, imagens térmicas

THERMAL IMAGE THRESHOLD FOR AUTOMATIC BOVINE MASTITE DETECTION

ABSTRACT

Disruptive technologies have great importance for the advancement of animal science. The dairy cattle farming is an activity of great importance in the world scenario, however, obstacles such as mastitis cause many losses in this sector. The objective of this study was to develop an algorithm for segmentation by thresholding and automatic classification of clinical pictures of bovine mastitis, as well as its validation. The research was carried out in two milk production units, located in the municipalities of Capoeiras and Pesqueira, Pernambuco. The number of samples was determined according to the selection criteria and totaled 24 animals (8 healthy animals, 8 with subclinical mastitis and 8 with clinical mastitis). Thermal images of the udder of the animals were obtained from an infrared thermographic camera, in the left anterolateral, right anterolateral, posterior and inferior frames, four images per animal, totaling 96 thermal images for analysis of their respective mammary quarters. The images were submitted to descriptive statistics. The measures extracted from the images were mean, median, mode and standard deviation of the udder surface temperature of the animals. The criterion used to determine them was the area of coverage of each udder, constituting an irregular matrix defined from the selection of points with the FLIR Tools software. For the automatic image segmentation, an algorithm was developed in C++ language using the OpenCV library, to identify the temperature referring to each image pixel through interpolation by the thresholding technique and pixel quantification of the analyzed interval of each image. The automatic segmentation indicated representativeness of the segmented area of 19, 15, 37 and 36% of the total pixels for healthy animals [32.9 - 33.86 °C] ± 0.99. For the subclinical mastitis picture, the percentage representation ranged from 21.84 to 69.5% of total pixels [34.45 - 34.98 °C] ± 0.87. The representation of animals with clinical mastitis ranged from 78.5 to 85.85% [35.34 - 35.75 °C] ± 0.67. The algorithm for automatic segmentation allowed differentiating the images of healthy animals and those with subclinical and clinical mastitis. The routine implemented to determine the temperature of each pixel of the image was coherent when compared to the results obtained by the FLIR Tools software, helping in the diagnosis regarding the clinical picture of the animals.

Keywords: image analysis, dairy cattle, thermal imaging

1. INTRODUÇÃO

A bovinocultura de leite é uma atividade de grande relevância no cenário mundial, porém, entraves como a mastite ocasiona muitas perdas neste setor. O impacto econômico da sua ocorrência no sistema de produção de leite reúne um conjunto de fatores responsáveis pelos prejuízos, com perda produtiva do rebanho, custo associado ao tratamento de casos clínicos, descarte e morte prematura de animais, perda de qualidade e rendimento industrial do leite in natura e derivados (LANGONI et al., 2017).

A mastite é uma inflamação decorrente de patógenos contagiosos ou ambientais que colonizam o teto de vacas em período de lactação, que se apresenta de forma clínica e subclínica. Na forma clínica os sinais são perceptíveis, geralmente sensibilidade ao toque no úbere e alterações nas características do leite. Na forma subclínica, os sinais são imperceptíveis e sua detecção pode ser realizada por testes práticos de campo ou laboratoriais (SÁ et al., 2018).

Exames não-invasivos como a termografia por infravermelho (TIV) podem ser utilizados para obter dados confiáveis, pois, gera uma imagem térmica ou termograma e através dela é possível avaliar e então, estabelecer o significado fisiológico e/ou patológico de uma variação da temperatura da superfície do úbere dos animais (CHACUR et al., 2016).

A detecção precoce de sintomas é essencial para lidar com maior eficácia com o desafio da mastite em bovinos de leite. Como resultado, a maioria das pesquisas sobre detecção de mastite é baseada na medição da temperatura de superfícies, por meio de câmeras térmicas (ZHANG et al., 2020; MARRERO et al., 2020; ZANINELLI et al., 2018; WATZ et al., 2019).

A partir da obtenção de uma imagem digital, por meio da visão computacional, é possível extrair informações por protocolos de operações e/ou transformações, que pode originar uma nova representação da imagem até a obtenção de sinais e padrões que auxiliam no processo de tomada de decisão (GARCÍA et al., 2015). Neste contexto, a segmentação de imagens consiste na divisão de uma imagem em um conjunto de pixels com base na semelhança compartilhada pelos pixels dessa imagem.

A identificação de seções nas imagens com base em pixels semelhantes em termos de valores de intensidade constitui os métodos baseados na limiarização. Essa

tem sido utilizada em imagens térmicas (SHAIKH et al., 2016; HOUSSEM, EMAM e ALI, 2021; ETEHADTAVAKOLA, NGB & KAABOUCH, 2017).

Dessa forma, objetivou-se com este estudo desenvolver algoritmo para segmentação por limiarização de imagens térmicas e classificação automática de quadros clínicos de mastite bovina, bem como a sua validação.

2. MATERIAL E MÉTODOS

A pesquisa foi realizada em duas unidades de produção de leite, localizada no município de Capoeiras e Pesqueira, ambos na mesorregião Agreste, Microrregião do Vale do Ipojuca, estado de Pernambuco. A precipitação pluviométrica média da região é de 620,3 mm (APAC, 2019), com temperatura média anual de 20,3 °C (INMET, 2019). Conforme a classificação climática de Köppen, o clima é caracterizado como Bsh – semiárido (ALMEIDA et al., 2011). No verão de 2009 a temperatura média baseada em uma série histórica de 30 anos foi de 22,8 °C e no inverno de 20,3 °C (INMET, 2019) .

A quantidade de amostras foi determinada de acordo com os critérios de seleção, animais de mesma ordem de parto, estágio de lactação, escore corporal, produção, grau sanguíneo e totalizaram 24 animais (8 animais saudáveis, 8 com mastite subclínica e 8 com mastite clínica).

A condição clínica dos animais foi estabelecida pelo *California Mastitis Test* (CMT), antes da ordenha (depois do descarte dos primeiros jatos de leite), pois neste momento o teor de gordura do leite é baixo e não interfere nos resultados visuais de escore do CMT.

Para a detecção dos casos de mastite clínica foi realizado o teste da caneca de fundo preto. Neste teste foi possível detectar alterações visíveis no leite (menor volume secretado, grumos, pus ou aspecto aquoso). Além disso, verificou-se nos animais a sensibilidade ao toque no úbere e tetos, pela presença do quadro inflamatório. As imagens térmicas do úbere dos animais foram obtidas a partir de uma câmera termográfica por infravermelho, com resolução de 0,01 °C, distância focal de 1,0 m e emissividade ajustada para 0,98 (da Silva et al., 2019). As imagens foram registradas no turno da manhã, antes da primeira ordenha dos animais, entre às 05 e 07h00 no primeiro local, onde foram capturadas nos enquadramentos anterolateral esquerdo, anterolateral direito, posterior e inferior, quatro imagens por animal e, entre às 10 e 12h00 no segundo local, onde foram obtidas imagens posteriores e inferiores. Para os demais enquadramentos (anterolateral esquerdo e direito) não foram obtidas imagens, pois, no

segundo local, a sala de ordenha possuía estrutura na qual só era possível capturar as imagens dos enquadramentos posteriores e inferiores, totalizando 96 imagens térmicas para análise de seus respectivos quartos mamários (Figura 1).

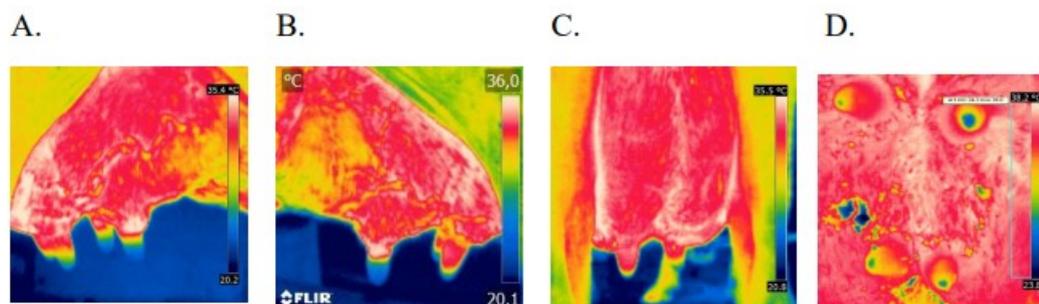


Figura 1: Imagens térmicas dos enquadramentos anterolateral direito (A), esquerdo (B), posterior (C) e inferior (D).

As imagens foram submetidas a estatística descritiva visando verificar a variabilidade das temperaturas entre as condições clínicas. As medidas extraídas das imagens foram média, mediana, moda e desvio padrão. O critério adotado para determinar as medidas estatísticas foi a área de cobertura de cada úbere, constituindo uma matriz irregular definida a partir da seleção de pontos com o software FLIR Tools (Figura 2).

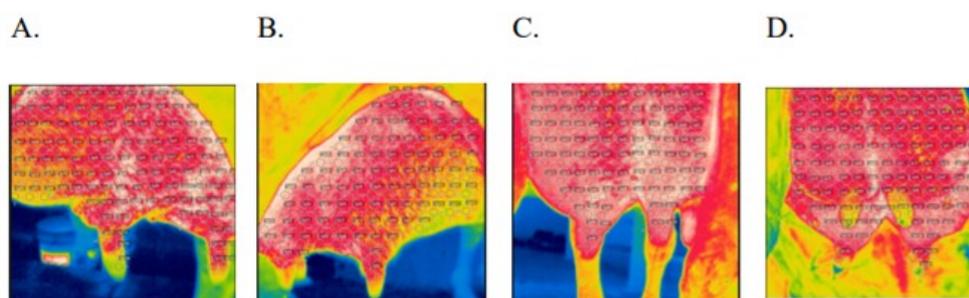


Figura 2: Seleção de pontos com o software FLIR Tools.

Para a segmentação automática das imagens foi desenvolvido um algoritmo em linguagem C++ utilizando a biblioteca OpenCV, que é uma biblioteca multiplataforma utilizada para processamento de imagens. O emprego do algoritmo visa encontrar a temperatura referente a cada pixel da imagem por meio de interpolação a partir de uma imagem em escala de cinza (Figura 3).

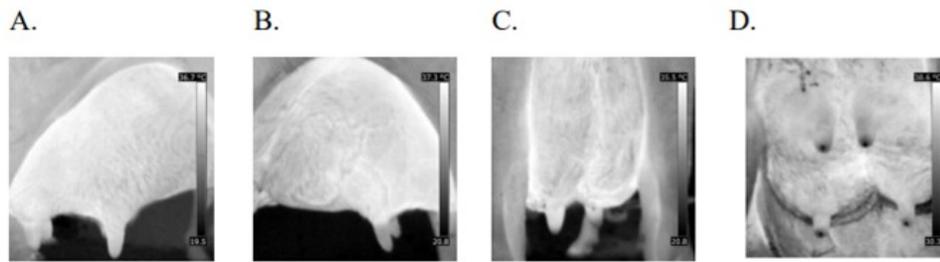


Figura 3: Imagens térmicas em escala de cinza para os enquadramentos anterolateral direito (A), anterolateral esquerdo (B), posterior (C) e inferior (D).

Conforme o fluxograma de funcionamento do algoritmo (Figura 4), após a leitura de uma imagem em escala de cinza são definidos os parâmetros da interpolação que são: t_{max} e t_{min} que se referem a temperatura máxima e mínima referente a região de interesse (úbere), t_{med} que é a temperatura média da região e os fatores $\alpha = (t_{max} - t_{min}) / 255.0$ e $\beta = t_{min}$ que são fatores de escala (Equação 1).

Após a definição dos parâmetros necessários, a imagem é convertida em matriz de ponto flutuante. Em seguida é aplicada a limiarização, e há uma nova conversão da imagem para matriz de canal único. Por fim, são calculados o total de pixels na região de interesse, subtraídos os pixels com valor 1 e obtidos os pixels com valor 0.

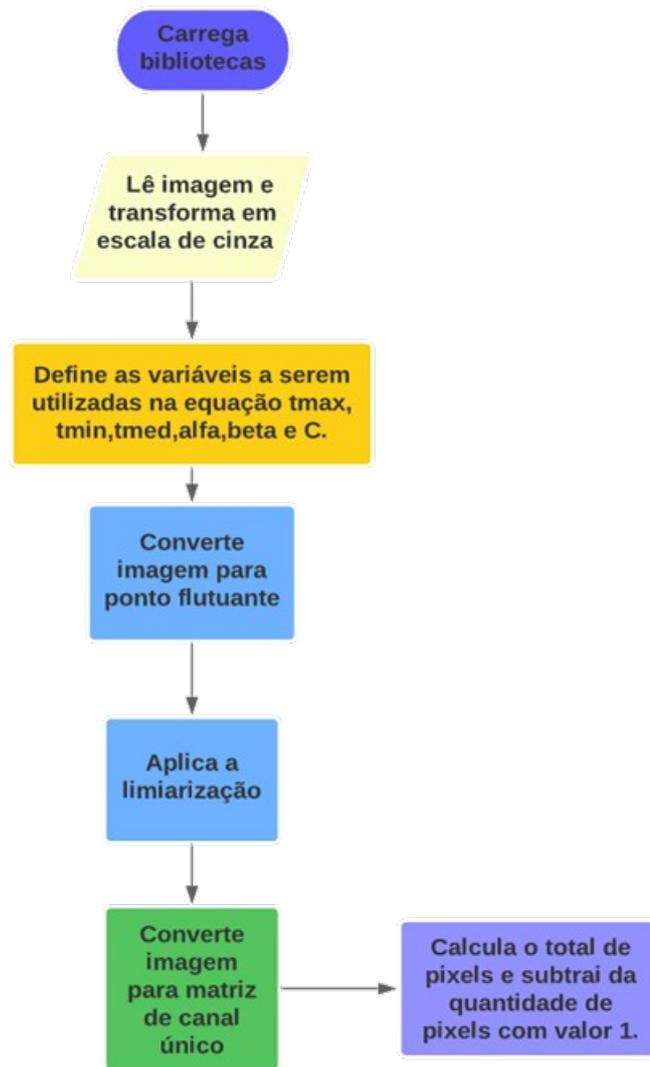


Figura 4: Fluxograma do funcionamento do algoritmo proposto.

$$t = \frac{t_{max} - t_{min}}{255} * C + t_{min} \quad (1)$$

em que:

t – limiar (°C);

tmax – intervalo máximo de temperatura na imagem (°C);

tmin – intervalo mínimo de temperatura na imagem (°C);

C – (tmed - tmin) / ((tmax - tmin) / 255.0).

Para validação do algoritmo foram realizadas comparações entre as temperaturas obtidas através dele com os resultados obtidos pelo software FLIR Tools.

3. RESULTADOS E DISCUSSÃO

O CMT foi realizado para cada quarto mamário, com atribuição de notas de 0 a 5; na pontuação 0, nenhum precipitado se formou (saudável); no escore 1, houve um leve precipitado (traço de infecção); no escore 2, houve precipitado moderado (mastite subclínica); no escore 3, havia um precipitado claro, mas sem formação de gel (mastite subclínica); no escore 4, havia uma nítida formação de gel (mastite subclínica); e no escore 5, havia uma formação de gel pronunciada (mastite subclínica). Para limitar a subjetividade na interpretação dos resultados, apenas escores de 2 a 5 foram considerados para seleção de animais com mastite subclínica.

Os valores médios de temperatura variaram de 32,42 a 33,86°C ± 0,99 para as imagens cujos enquadramentos foram classificados como saudáveis pelo teste CMT. De 34,45 a 34,98°C ± 0,87 para os enquadramentos onde foi detectada presença de mastite subclínica e de 35,34 a 35,75°C ± 0,67 para enquadramentos onde houve presença de mastite clínica (Tabela 1).

Tabela 1: Valores referentes à estatística descritiva das temperaturas dos quartos

	Saudável (°C)				Subclínico (°C)				Clínico (°C)	
	AD	AE	POST	INF	AD	AE	POST	INF	POST	INF
Média	33,86	32,42	32,55	33,4	34,42	34,98	34,65	34,34	36,34	36,75
Mediana	34	32	33	33	35	35	35	34	36	37
Moda	34	32	33	33	34	35	35	34	36	37
Desvio Padrão	0,99	1,21	0,98	0,78	0,87	0,88	0,89	0,96	0,82	0,98

AD – anterolateral direito; AE – anterolateral esquerdo; POST – posterior; INF - inferior

Neste estudo as temperaturas dos enquadramentos foram respectivamente 1,12°C (mastite subclínica) e 2,89°C(mastite clínica) maior que os enquadramentos saudáveis. Da Silva et al. (2019) ao estudarem a dependência espacial da temperatura da superfície do úbere para detecção de mastite encontraram diferenças de 5,3 a 4,55°C acima da temperatura de superfície de úberes saudáveis. Polat et al. (2010), quartos com mastite subclínica apresentaram temperatura de superfície 2,35°C maior do que quartos saudáveis. Estudos como o de Pezeshki et al. (2011) notaram que a variação da dinâmica inflamatória da mastite, utilizando a termografia, ocorreu variação na temperatura da superfície da pele do úbere de 2 a 3 °C.

Com o conhecimento sobre a variabilidade das temperaturas superficiais no úbere dos animais foram definidos os parâmetros para o desenvolvimento do algoritmo de segmentação (Figura 5).

```
#include <opencv2\opencv.hpp>
#include <vector>
#include <iostream>

using namespace cv;
using namespace std;

int main() {

    //Ler imagem em tom de cinza
    Mat image = imread("cli1.png", CV_LOAD_IMAGE_GRAYSCALE);
    Mat image2;
    Mat image3;
    //definir os parâmetros da interpolação
    // t, tmax e tmin
    // alpha = (tmax - tmin)/255 e beta = tmin
    double tmax =
    double tmin =
    double tmed =
    double alpha = (tmax-tmin) / 255.0;
    double beta = 36.1;
    double c = (tmed-tmin) / ((tmax-tmin) / 255.0);

    image.convertTo (image2, CV_32F, alpha, beta);
    threshold(image2, image3, tmed, 255, CV_THRESH_BINARY_INV);
    Mat image4;
    image3.convertTo(image4, CV_8UC1);
    int TotalNumberOfPixels = image4.rows * image4.cols;
    int ZeroPixels = TotalNumberOfPixels-countNonZero(image4);
    cout << "The number of pixels that are zero is " << ZeroPixels << endl;
    namedWindow("image", CV_WINDOW_AUTOSIZE);
    imshow("image", image4);
    waitKey();
    return 0;
}
```

Figura 5: Código desenvolvido para segmentação das imagens térmicas de mastite bovina.

As mudanças térmicas em corpos biológicos, como os dos animais utilizados, por meio das imagens térmicas, permitiram a visualização do grau de suavidade de transição de uma cor, frequência, para outra. A limiarização, por se tratar de um processo de segmentação, se baseia nestas diferenças que compõem os objetos numa imagem. Através dela pode-se isolar grupos de pixels com níveis de cinza abaixo e acima do limiar (RESMINI et al., 2012; MELO et al., 2014; BAFFA et al., 2016; SHAIKH et al., 2016).

O algoritmo para segmentação das imagens permitiu agrupar os pixels acima e abaixo do limiar de acordo com os limites de temperatura da região de interesse (úbere dos animais) (Figura 6). Também permitiu determinar a área referente aos pixels com valor 0 (pixels pretos) visando diferenciar as imagens dos animais saudáveis, com mastite subclínica e clínica, por meio da função CountNonZero do OpenCV.

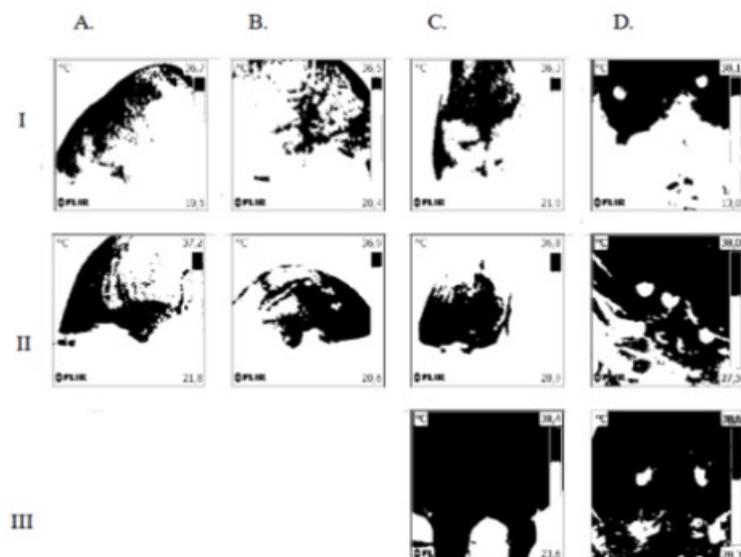


Figura 6: Resultado da segmentação com base na temperatura da região de interesse para os animais saudáveis (AI, BI, CI, DI), com mastite subclínica (AII, BII, CII, DII) e clínica (CIII, DIII).

Os animais saudáveis apresentaram variação de 11.034 a 13.570 pixels para os quartos posteriores (Figura 6CI), 12.940 a 13.113 para anterolaterais direitos (Figura 6BI), 10.345 a 11.279 para os anterolaterais esquerdos (Figura 3AI) e para os inferiores 20.345 a 21.521 (Figura 6DI). Esses valores correspondem de 19, 15 a 37, 36% do total de pixels da imagem (240x240 pixels).

Para o quadro de mastite subclínica verificou-se variação de 12.582 a 15.678 pixels para os enquadramentos posteriores (Figura 6CII), 13.433 a 14.567 para enquadramentos anterolaterais direitos (Figura 6BII), 13.456 a 14.532 para os anterolaterais esquerdos (Figura 6AII), 38.791 a 40.032 para o enquadramento inferior (Figura 3DII). A representação percentual variou de 21,84 a 69,5% do total de pixels (57.600).

Os animais com mastite clínica, a média de pixels variou de 45.223 a 46.487 para os enquadramentos posteriores (Figura 6CIII). Para os enquadramentos inferiores variou de 48.824 a 49.451 (Figura 6DIII). A representação percentual foi de 78,5 a 85,85% do total de pixels. Dessa forma, o algoritmo desenvolvido para a segmentação das imagens contribuiu para a visualização do grau de infecção e quadro clínico dos animais (saudáveis, com mastite subclínica e mastite clínica).

Para validação do algoritmo de segmentação foram selecionadas regiões nas imagens e verificação dos intervalos de temperatura no FLIR Tools e se correspondiam ao mesmo intervalo obtido pelo algoritmo (Figura 7). Assim, foi possível a validação através da comparação entre a metodologia utilizada e o software da câmera térmica.

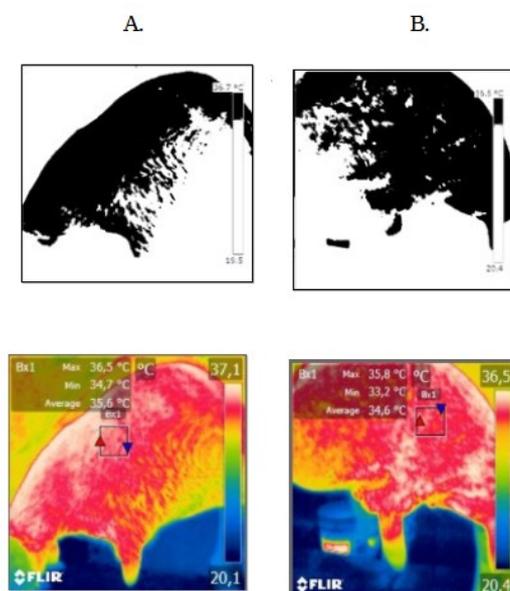


Figura 7: Imagens obtidas pelo algoritmo de segmentação e imagens térmicas utilizadas para validação pelo software FLIR Tools para os enquadramentos anterolateral direito (A), esquerdo (B).

4. CONCLUSÃO

O algoritmo para segmentação por limiarização identificou automaticamente a temperatura de cada pixel, o que permitiu a classificação do quadro clínico de mastite em bovinos de leite.

O ângulo de captura das imagens e o posicionamento do operador durante o registro das imagens foram considerados fatores de interferência no estudo das imagens, sendo possível melhorar os critérios de validação da técnica empregada com a atenuação desses fatores.

A segmentação automática possui custo computacional reduzido, pois utiliza poucas imagens para a classificação comparativamente aos métodos de aprendizagem de máquina.

REFERÊNCIAS

ALMEIDA, G. L. P. de.; PANDORFI, H.; GUISELINI, C.; HENRIQUE, H. M.; ALMEIDA, G. A. P. de. Uso do sistema de resfriamento adiabático evaporativo no

conforto térmico de 83 vacas da raça girolando. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 15, n. 7, p. 754-760, 2011.

AGÊNCIA PERNAMBUCANA DE ÁGUAS E CLIMA – APAC. Monitoramento pluviométrico. 2019. Disponível em: . Acesso em: 07 mar. 2019.

BAFFA, M.F.O.; CHELONI, D.J.M.; LATTARI, L.G.; COELHO, M.A.N. Segmentação Automática de Mamas em Imagens infravermelhas utilizando limiarização com refinamento adaptativo em bases multivariadas. *Revista de Informática Aplicada*, v. 12, n.2, 2016.

CHACUR, M.G.M.; SOUZA, C.D.; ANDRADE, I. B.; BASTOS, G.P.; DEAK. F.L.G.; SOUZA, M.G.R.; CORNACINI, G.F.; MARQUES JÚNIOR, A.P. Aplicações da termografia por infravermelho na reprodução animal e bem-estar em animais domésticos e silvestres. *Revista Brasileira de Reprodução Animal*, Belo Horizonte, v.40, n.3, p.88-94, 2016.

ETEHADTAVAKOLA , M., NG, E.Y.K., KAABOUCH, N. Automatic segmentation of thermal images of diabetic-at-risk feet using the snakes algorithm *Infrared Physics & Technology*, v.86 , pg. 66-76, 2017.

GARCÍA, G. B. et al. *Learning Image Processing with OpenCV*. [S.l.]: Packt Publishing Ltd, 2015.

HOUSSEIN, E.H.; EMAN, MM.; ALI, A.A. An efficient multilevel thresholding segmentation method for thermography breast cancer imaging based on improved chimp optimization algorithm. *Expert Systems with Applications*, v.185, 2021.

INMET. BDMEP - Banco de Dados Meteorológicos para Ensino e Pesquisa. 2019. Disponível em: [.<https://www.gov.br/agricultura/pt-br/assuntos/inmet?r=bdmep/bdmep>](https://www.gov.br/agricultura/pt-br/assuntos/inmet?r=bdmep/bdmep) Acesso em: 23 fev. 2019

LANGONI, H.; SALINA, A.; OLIVEIRA, G.C.; JUNQUEIRA, N.B.; MENOZZI, B.D.; JOAQUIM, S.F. Considerações sobre o tratamento das mastites. *Pesquisa Veterinária Brasileira* v.37, n.11, p.1261-1269, 2017.

MARRERO, M.G.; RIJOS-FERNANDÉZ, C.; VÉLEZ-ROBLES, Y.; ORTÍZCOLÓN, G.; SANCHÉZ-RODRÍGUES, H.; JIMENÉZ-CABÁN, E.; CURBELORODRÍGUEZ, J. Short-milking-tube infrared temperature as a subclinical mastitis detection tool in tropical dairy farms. *Applied Animal Science*, v.36, p. 329-334, 2020.

MELO, G.J.A.; NETO, B.A.M.; GOMES, V.; ALMEIDA, L.A.L.; LIMA, A.C.C. Método de limiarização automática para a contagem de células somáticas em imagens microscópicas. *Revista GEINTEC*. v. 4,n.3, p.1283 -1291, 2014.

PEZESHKI, A.; STORDEUR, P.; WALLEMACQ, H.; SCHYNTS, F.; STEVENS, M.; BOUTET, P.; PEELMAN, L.J.; SPIEGELEER, B.; DUCHATEAU, L.; BUREAU, F.; BURVENICH, C. Variation of inflammatory dynamics and mediators in primiparous

cows after intramammary challenge with *Escherichia coli*. *Veterinary Research*, v.42, n.15, 2011.

POLAT, B.; COLAK, A.; CENGIZ, M.; YANMAZ, L.E.; ORAL, H.; BASTAN, A.; KAYA, S.; HAYIRLI, A. Sensitivity and specificity of infrared thermography in detection of subclinical mastitis in dairy cows. *Journal Dairy Science*. Source: *Journal of dairy science*. v.93, n.8 p. 3525-3532, 2010.

RESMINI, R.; CONCI, A.; BORCHARTT, T.B.; DE LIMA, R.C.F.; MONTENEGRO, A.A.; PANTALEÃO, C.A. Diagnóstico precoce de doenças mamárias usando imagens térmicas e aprendizado de máquina. *Revista eletrônica do Vale do Itajaí*, v.1, n.1, p. 55-67, 2012.

SÁ, J.P.N.; FIQUEIREDO, C.H.A.; NETO, O.L.S.; ROBERTO, S.B.A.; GADELHA, 313 H.S.; ALENCAR, M.C.B. Os principais microorganismos causadores da mastite bovina e suas consequências na cadeia produtiva de leite. *Revista Brasileira de Gestão 315 Ambiental*. v. 12, n.1, p.01- 13, 2018.

SHAIKH, S. MANZA, R.; HANUMANT, G.; KALE, K. Segmentation of Thermal Images Using Thresholding-Based Methods for Detection of Malignant Tumours, *International Journal of Intelligent Systems Technologies and Applications*,v. 530, p. 131-146, 2016.

da SILVA, R.A.B.; PANDORFI, H.; ALMEIDA, G.; MONTENEGRO, A. A. A.; SILVA, M.V. Spatial Dependence of Udder Surface Temperature Variation in Dairy Cows with Healthy Status and Mastitis *Revista Brasileira de Saúde e Produção Animal*, v. 20, p. 01 – 15, 2019.

WATZ, S.; PETZI, W.; ZERBE, H.; RIEGER, A.; GLAS, A.; SCHROTER, W.; LANDGRAT, T.; METZNER, M. Automatic evaluation of infrared thermal images by computerized active shape modeling of bovine udders challenged with *Escherichia coli*. *Journal Dairy Science*, v. 102, p. 4541–4545, 2019.

ZANINELLI, M.; REDAELLI, V.; LUZI, F.; BRONZO, V.; MITCHELL, M.; DELL'ORTO, V.; BONTEMPO, V.; CATTANEO, D.; SAVOINI, G. First evaluation of infrared thermography as a tool for the monitoring of udder health status in farms of dairy cows. *Sensors*, v. 18, n. 862, 2018.

ZHANG, X.; KANG, X.; FENG, N.; LIU, G. Automatic recognition of dairy cow mastitis from thermal images by a deep learning detector. *Computers and Electronics in Agriculture*, v. 178, 2020.

CAPÍTULO III

Aprendizagem de máquina por transferência sequencial para detecção automática de mastite bovina a partir de imagens térmicas

APRENDIZAGEM DE MÁQUINA POR TRANSFERÊNCIA SEQUENCIAL PARA DETECÇÃO AUTOMÁTICA DE MASTITE BOVINA A PARTIR DE IMAGENS TÉRMICAS

RESUMO

A bovinocultura de leite é uma atividade em franco crescimento no Brasil e no mundo. No entanto, este setor enfrenta um grande entrave, a mastite bovina, que ocasiona inúmeras perdas na produção de leite e na longevidade do rebanho. Alguns métodos de diagnóstico de mastite vêm sendo utilizados ao longo dos anos, porém, além da subjetividade, apresentam custo elevado, sendo de grande importância o desenvolvimento de ferramentas que ofereçam diagnóstico precoce, seguro, não invasivo e de baixo custo, como o diagnóstico por imagens térmicas. Dessa forma, este estudo foi conduzido visando desenvolver uma metodologia preditiva baseada em transferência de conhecimento sequencial para detecção automática de mastite subclínica bovina, por meio da visão computacional. O banco de imagens utilizado na pesquisa foi constituído por 165 imagens de 360 x 360 pixels, referente ao banco de dados de 55 bovinos com diagnóstico prévio de mastite subclínica e saudável, provenientes de três unidades de produção, localizadas nos municípios de Capoeiras e Pesqueira, estado de Pernambuco e município de Russas, estado do Ceará, Brasil. As imagens utilizadas na transferência sequencial de aprendizado foram *MammoTherm* (detecção de câncer de mama em mulheres). Os modelos preditivos desenvolvidos foram baseados em ResNet50, sendo inicializados com pesos do ImageNet e pesos aleatórios para comparação, utilizando o conjunto de imagens *MammoTherm* (600 imagens) e das imagens térmicas do úbere das vacas. Os melhores modelos (STL_ResNet50 e Mastitis - ResNet50) apresentaram desempenho superior aos demais modelos (Mammo_mast_ImageNet - ResNet50 e Mammo_mast - ResNet50), com acurácia de 88,03 e 86,1%, respectivamente, podendo ser considerados promissores para a detecção automática de condições clínicas saudáveis e de mastite subclínica para bovinos de leite.

Palavras-chave: análise de imagem, bovinocultura de leite, rede neural convolucional, termografia infravermelho

SEQUENTIAL TRANSFER MACHINE LEARNING FOR AUTOMATIC DETECTION OF BOVINE MASTITIS FROM THERMAL IMAGES

ABSTRACT

Dairy farming is a fast-growing activity in Brazil and worldwide. However, this sector faces a major obstacle, bovine mastitis, which causes numerous losses in milk production and herd longevity. Some methods of mastitis diagnosis have been used over the years, however, in addition to subjectivity, they are expensive, and it is of great importance to develop tools that offer early, safe, non-invasive, and low-cost diagnosis, such as a diagnosis by thermal imaging. Thus, this study was conducted to develop a predictive methodology based on sequential knowledge transfer for the automatic detection of subclinical bovine mastitis using computer vision. The image bank used in the research was constituted of 165 images of 360 x 360 pixels, referring to the database of 55 cattle with a previous diagnosis of subclinical and healthy mastitis, from three production units, located in the municipalities of Capoeiras and Pesqueira, state of Pernambuco and municipality of Russas, state of Ceará, Brazil. The images used in the sequential learning transfer were MammoTherm (breast cancer detection in women). The predictive models developed were based on ResNet50, being initialized with ImageNet weights and random weights for comparison, using the MammoTherm image set (600 images) and the cows' udder thermal images. The best models (STL_ResNet50 and Mastitis - ResNet50) outperformed the other models (Mammo_mast_ImageNet - ResNet50 and Mammo_mast - ResNet50), with an accuracy of 88.03 and 86.1%, respectively, and can be considered promising for automatic detection of healthy clinical conditions and subclinical mastitis for dairy cattle.

Keywords: image analysis, dairy cattle, convolutional neural network, infrared thermography

1. INTRODUÇÃO

O Brasil ocupa posição de destaque no cenário mundial da produção de leite. No entanto, esse setor enfrenta muitas perdas econômicas e um dos fatores que mais contribuem nesse sentido é a mastite bovina. Caracterizada como a inflamação da glândula mamária em bovinos de leite que leva a diminuição da produção e da qualidade do leite, além do empobrecimento no bem-estar animal e na rentabilidade da indústria de laticínios (POSSENTI et al., 2018; RUEGG, 2017; WONG et al., 2016).

A mastite subclínica causa o maior impacto econômico aos produtores, porque nesse estágio, o animal não apresenta sinais visíveis da doença e quando ocorre, a resposta inflamatória local demonstra alterações no fluxo sanguíneo no nível tecidual (WATZ et al., 2019; McMANUS et al., 2016), promovendo o aumento da temperatura da superfície da pele do úbere de vacas de leite (BORTOLAMI et al., 2015).

Os métodos de detecção da mastite bovina têm se desenvolvido intensamente ao longo dos anos, mas os métodos tradicionais de padrão ouro, contagem de células somáticas (CCS) e cultura microbiana (VIGUIER et al., 2009) apresentam alto custo, são trabalhosos, invasivos e dependem de intervenção humana.

Para mastite subclínica, os testes de triagem na fazenda são realizados com o *California Mastitis Test* (CMT) procedimento de baixo custo, rápido e de fácil diagnóstico (RUEGG, 2017), no entanto, é subjetivo, por depender da interpretação humana, oferecendo menos precisão e confiabilidade (LIMA et al., 2018).

Nesse contexto, a medição da temperatura da superfície da pele do úbere por termografia infravermelha apresenta-se como método não invasivo e capaz de detectar alterações de temperatura proveniente de quadro inflamatório, sendo utilizado no diagnóstico da mastite subclínica em bovinos de leite (POLAT et al., 2010; da SILVA et al., 2019; ZANINELLI et al., 2019; WATZ et al., 2019).

Os diagnósticos automáticos baseados em imagens térmicas são cada vez mais utilizados na detecção de mastite (ZANINELLI et al., 2019; XUDONG et al., 2020) como na produção animal em geral, na detecção do peso vivo (WANG et al., 2018; CAO et al., 2020), condição corporal do animal (RODRÍGUEZ ALVAREZ et al., 2018) e detecção de outras doenças (SWATI et al., 2019).

Dessa forma, o emprego da inteligência artificial no auxílio à tomada de decisão, nos mais variados sistemas de produção, destaca-se as redes convolucionais, capazes de aprender a extrair características relevantes das imagens, o que permitem a classificação de elementos em uma cena, com desempenho equivalente ou superior à

capacidade humana, permitindo sua aplicação no ajuste do manejo de animais de produção.

O principal desafio para o diagnóstico preciso relacionado à mastite é a indisponibilidade de um grande conjunto de imagens de animais em diferentes estágios da infecção. Tal dificuldade é devida ao rápido encaminhamento do animal ao tratamento, inviabilizando a localização de um número substancial de animais doentes no rebanho.

Para minimizar os impactos negativos dessa indisponibilidade de dados, a transferência de conhecimento tem se mostrado eficaz na classificação automática de imagens. Tal técnica consiste em utilizar o conhecimento obtido por uma rede neural em um determinado domínio, para ser aplicado a outro domínio (BOUMARAF et al., 2021; DAS et al., 2016; PORTER, WIELAND and BASRAN, 2021; SWATI et al., 2019).

Esta técnica é utilizada quando o conjunto de dados disponível para o treinamento do modelo possui poucas imagens, onde o processo de transferência de aprendizado consiste em utilizar os pesos de um modelo de treinamento em um domínio similar (com muitas imagens) e, então, é feito o ajuste fino dos pesos para o problema alvo.

A maior dificuldade é que as grandes bases disponíveis envolvem situações de classificação com características diferentes do problema da mastite, não sendo tão eficaz na aplicação de imagens térmicas quando realizado o processo de transferência de aprendizado.

O ideal, quando se utiliza a transferência de aprendizado, é que a rede profunda tenha uma boa inicialização. Isso contribui para garantir o sucesso na classificação, pois, as camadas convolutivas são responsáveis por extrair as características das novas classes de imagens (YOSINSKI et al., 2014).

A transferência de aprendizado é realizada em duas etapas e consiste na adaptação da rede às imagens de um determinado domínio e as imagens do domínio alvo. Comparada com a abordagem tradicional, ela representa um ganho de desempenho da rede por levar a um desempenho mais estável e menos tendencioso, quando se trata de diferenciação entre categorias de imagens (SIEMON, SHIHAVUDDIN e RAVNHAREN, 2021).

Dessa forma, objetivou-se com esta pesquisa, desenvolver metodologia preditiva baseada em transferência de conhecimento para detecção automática de mastite subclínica bovina, por meio da visão computacional.

2. TRABALHOS RELACIONADOS

A detecção automática de mastite consiste na classificação binária entre animal saudável e doente (VAN DER VOORT et al., 2021). Existem alguns estudos baseados em processamento de dados utilizando diversas técnicas de aprendizagem de máquinas, como os estudos de Addis et al. (2016), Jensen et al. (2016), Khatun et al. (2017) e Dalen et al. (2019) definindo um valor limite aplicado aos dados brutos, filtrados ou transformados para classificar o animal como saudável ou doente.

As pesquisas de Nielen et al. (1995a), Nielen et al. (1995b), Cavero et al. (2008), Sun et al. (2010) e Ankinakatte et al. (2013) os autores utilizaram redes neurais artificiais para o processamento de dados em sua forma mais básica. Miekley et al. (2013a) e Huybrechts et al. (2014) utilizaram a soma cumulativa (CUSUM). Soyeurt et al. (2012) e Miekley et al. (2013c) utilizaram análise de componentes principais no conjunto de dados na detecção de mastite.

No contexto de detecção de mastite por análise de imagem, existem poucas abordagens, muitas delas utilizam imagens RGB, como Silva et al. (2022) que estudaram a atividade da lactoperoxidase para avaliar a mastite usando imagens RGB gravadas de uma cubeta e Marrero et al. (2020) que analisaram imagens térmicas de tetos, como um estimador da temperatura do leite de quartos mamários com ou sem a presença de mastite.

Poucos estudos utilizam imagens térmicas do úbere associado ao processamento de imagem. Silva et al. (2021) desenvolveram um método automático baseado em limiarização para diferenciar imagens térmicas de animais saudáveis, com mastite subclínica e clínica. Zaninelli et al. (2019) desenvolveram um software para calcular, de forma automática e padronizada, índices termográficos do úbere de vacas em lactação e os resultados obtidos confirmaram relação significativa entre a temperatura da superfície da pele do úbere e as classes de contagem de células somáticas para identificação de quadros clínicos de mastite. Watz et al. (2019) realizaram comparação entre um software de reconhecimento automático de imagem e a avaliação manual na detecção de *Escherichia coli* clínica.

Com base nas redes convolutivas, o estudo de Xudong et al. (2020) desenvolveu um detector de objeto com YOLO como proposta de melhorar a velocidade de detecção de mastite. A técnica de transferência de aprendizagem com redes convolutivas foi reportada no estudo desenvolvido por Porter, Wieland e Basran (2020) que utiliza imagens digitais do teto para a classificação e identificação da mastite bovina, no

entanto, são escassos os estudos abordando esta técnica aplicada a imagens térmicas do úbere dos animais, assumindo que a mastite afeta a integridade da glândula mamária.

Porém, ainda não existe uma abordagem utilizando conhecimento obtido em outros domínios (transfer learning) como alternativa para resolução da questão do diagnóstico automático precoce, extraindo informações das imagens usando banco reduzido de imagens, com inicialização dos pesos pré-treinados em um banco de dados como o ImageNet, fazendo com que a otimização comece com os pesos em uma região mais próxima de uma condição aceitável para o diagnóstico.

3. MATERIAL E MÉTODOS

O banco de imagens utilizado na pesquisa é oriundo de estudo preliminar aprovado pelo Comitê de Ética no Uso de Animais da Universidade Federal Rural de Pernambuco, licença n.º 138/2018, aprovado em 19 de dezembro de 2018, formado a partir do registro de imagens térmicas do úbere de animais com diagnóstico prévio de mastite subclínica e saudável. As imagens térmicas do úbere do gado leiteiro são provenientes de três bases, obtidas em diferentes unidades de produção, no município de Capoeiras (latitude: 8° 36' 33" S, longitude: 36° 37' 30" W e altitude de 733 m), Pesqueira (Latitude: 8° 21' 35" S, Longitude: 36° 41' 42" W e altitude de 652 m) estado de Pernambuco e município de Russas, Ceará, Brasil (04° 56' 25" S, 37° 58' 33" W e altitude de 20 m).

O número de amostras foi determinado segundo os critérios de seleção, animais de mesma ordem de parto, estágio de lactação, escore corporal, produção, grau sanguíneo (vacas Girolando). A condição clínica dos animais foi estabelecida pelo *California Mastitis Test* (CMT), antes da ordenha (após descartar os primeiros jatos de leite), pois, neste momento o teor de gordura do leite é baixo e não interfere nos resultados visuais de pontuação do CMT.

As imagens foram adquiridas por um termovisor FLIR i60, com distância focal de 1 m entre a câmera e o animal, e emissividade (ϵ) indicada para tecidos biológicos de 0,98 (SILVA et al., 2019). As imagens foram registradas no turno da manhã, antes da primeira ordenha dos animais, entre 05:00 e 07:00h, nos enquadramentos anterolateral esquerdo, anterolateral direito e posterior, três imagens por animal (Figura 1).

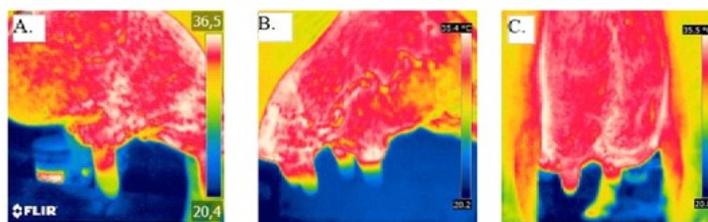


Figura 1: Imagens térmicas dos enquadramentos anterolateral direito (A), esquerdo (B) e posterior (C).

Foram utilizadas 165 imagens de 360 x 360 pixels, referente ao banco de dados de 55 bovinos, classificados em grupos distintos "Saudável" e "Mastite Subclínica", ou seja, positivo e negativo para a fase de treinamento, teste e validação.

3.1. Conjunto de dados

Para o treinamento da rede e análise comparativa dos modelos (Mastitis — ResNet50; Mammo_Mast_ImageNet — ResNet50; Mammo_Mast — ResNet50; STL — ResNet50) foi utilizado um banco de imagens maior, com problema semelhante (MammoTherm). O banco MammoTherm consiste em imagens térmicas para detecção de câncer de mama em mulheres, da Universidade Federal de Pernambuco, as imagens apresentavam 640 x 480 pixels utilizadas no Hospital das Clínicas da mesma instituição.

O conjunto de treinamento, teste e validação contou com 600 imagens do banco de imagens MammoTherm, em que se considerou as imagens dos grupos “Sem Lesão” e “Lesão Benigna” (Figura 2).

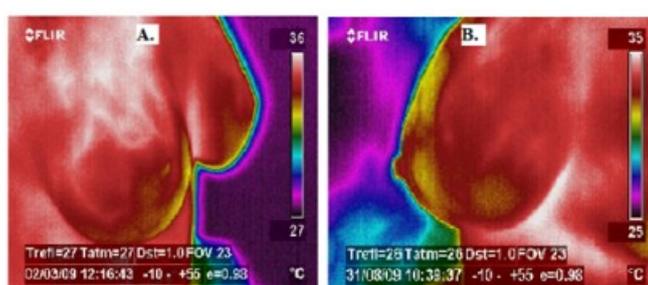


Figura 2: Imagens térmicas de mamografia com lesão benigna (A) e sem lesão (B), utilizadas na fase de treinamento da rede.

Fonte: (Bezerra et al., 2020; Rodrigues et al., 2019; Santana et al., 2018; de Vasconcelos et al., 2018; Araújo et al., 2017).

Posteriormente, o aprendizado foi transferido para o banco de dados menor (imagens de bovinos leiteiros saudáveis e com mastite subclínica). A proporção de

imagens utilizadas na fase de treinamento, teste e validação foi de 70, 15 e 15%, respectivamente, para o banco de imagens de mamografia e a mesma proporção para o banco de imagens de mastite bovina.

No problema de classificação das imagens térmicas do úbere de vacas de leite, a rede foi pré-treinada na base ImageNet (o conjunto de dados abrange 1.000 classes de objetos e contém 1.281.167 imagens de treinamento, 50.000 imagens de validação e 100.000 imagens de teste) primeiro domínio e, posteriormente foi adaptado para a tarefa de classificação de imagens MammoTherm (segundo domínio). Por fim, a rede transferida foi adaptada e treinada para classificar imagens térmicas de mastite bovina (domínio alvo) (Figura 3).

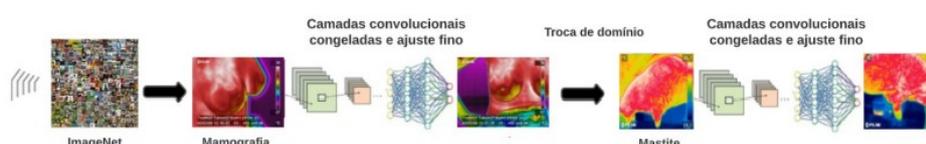


Figura 3: Procedimento geral do aprendizado por transferência sequencial proposto.

3.2. Pré-processamento de imagem

O pré-processamento consistiu em redimensionar as imagens para 224×224 pixels e na utilização da técnica de *data augmentation* que consistiu na ampliação do *dataset*. Para todos os bancos de imagens foram utilizadas a mesma quantidade de imagens para cada classe (animal saudável e animal com mastite subclínica). Para isso, algumas transformações foram realizadas, sendo feitas apenas uma vez, a fim de criar um excedente de imagens para a rede, sendo normalmente utilizado para evitar o *overfitting* e estender o sistema força (WILSON et al., 2018).

Em aprendizado de máquinas, o desempenho dos algoritmos pode ser melhorado conforme o aumento no número de instâncias numa base de dados. No entanto, está sujeito ao número de exemplos disponíveis, pois, na maioria das vezes, isso não ocorre. O *data augmentation* (DA) utiliza técnicas computacionais para aumentar o conjunto de treinamento supervisionado para se obter algoritmo com maior capacidade de predição e, conseqüentemente, melhores resultados (TAYLOR e NITSCHKE, 2017).

Nesta etapa foi utilizado o método geométrico, que consiste em transformações que alteram a geometria da imagem mapeando os valores de pixel individuais para novos destinos. A forma subjacente da classe representada na imagem é preservada, mas

alterada para algumas novas posições e orientações. Foram utilizados 30.º de rotação, 20º de ampliação, 10º de recorte, 20º de deslocamento horizontal aleatório e vertical, sendo criadas 2.500 novas imagens (Figura 4).

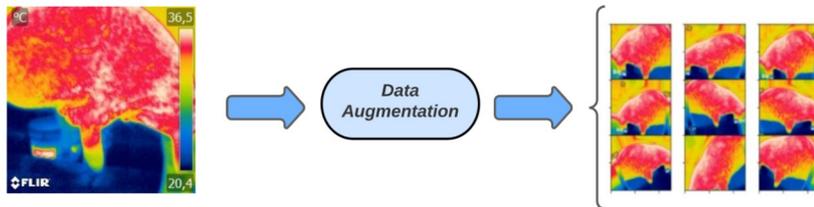


Figura 4: Resultados da imagem após o uso do aumento de dados.

3.3. Análise Comparativa dos modelos

Neste estudo foram estudadas três técnicas de transferência de aprendizado e uma estratégia de transferência de aprendizagem sequencial, utilizando ResNet50, com o emprego de pesos do ImageNet e pesos aleatórios para comparação. Os quatro modelos de aprendizagem por transferência foram implementados utilizando ResNet50 (Mastitis – ResNet50; Mammo_Mast_ImageNet – ResNet50; Mammo_Mast – ResNet50; STL – ResNet50).

A arquitetura da ResNet50 possui duas características principais: uma estratégia de “atalhos” ou “conexões de salto”, que pulam pares de grupos de camadas convolucionais, *batch normalization*, método usado para tornar o treinamento de redes neurais artificiais mais rápido e estável, por meio da normalização das entradas das camadas por recentralização e redimensionamento (Figura 5).

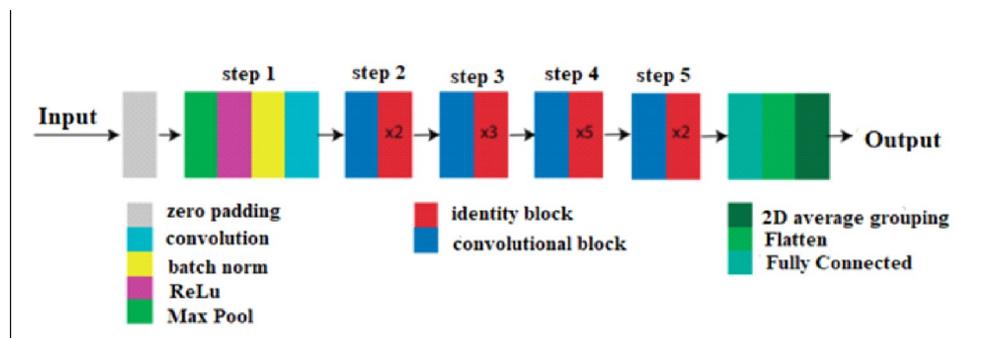


Figura 5: Arquitetura da rede ResNet (SILVA et al., 2019).

É aplicada na entrada um bloco de preenchimento zero de (3,3). No Estágio 1, a convolução 2D contou com 64 filtros de forma (7,7). O *batchnorm* foi aplicado ao eixo

dos canais da entrada. O *MaxPooling* usou uma janela (3,3) e uma passada (2,2). No Estágio 2, o bloqueio convolucional usou três conjuntos de filtros. Os filtros são convoluções que identificam os traços mais marcantes na imagem. Após passar pela imagem inteira, por cada um dos canais, forma no final um *feature map*. Os 2 blocos de identidade aplicaram três conjuntos de filtros convolucionais. Estágio 3, o bloqueio convolucional usou três conjuntos de filtros. Os 3 blocos de identidade usaram três conjuntos de filtros convolucionais. No Estágio 4, o bloco convolucional usou três conjuntos de filtros de tamanho. Os 5 blocos de identidade usaram três conjuntos de filtros convolucionais. Estágio 5, o bloqueio convolucional usou três conjuntos de filtros convolucionais. Os 2 blocos de identidade usaram três conjuntos de filtros convolucionais. O *Average Pooling* (Agrupamento médio) 2D usou uma janela de forma (2,2). O *flatten* (nivelamento da camada) não possui nenhum hiperparâmetro ou nome e a camada totalmente conectada (Densa) reduz sua entrada para o número de classes usando ativação *Softmax* (HE et al., 2016).

Sendo assim, a rede convolucional pode ser descrita em duas partes: uma base convolucional e um classificador, como mostrado na Figura 6. A base convolucional extraiu características das imagens e o classificador utilizou essas características para classificar corretamente a imagem.

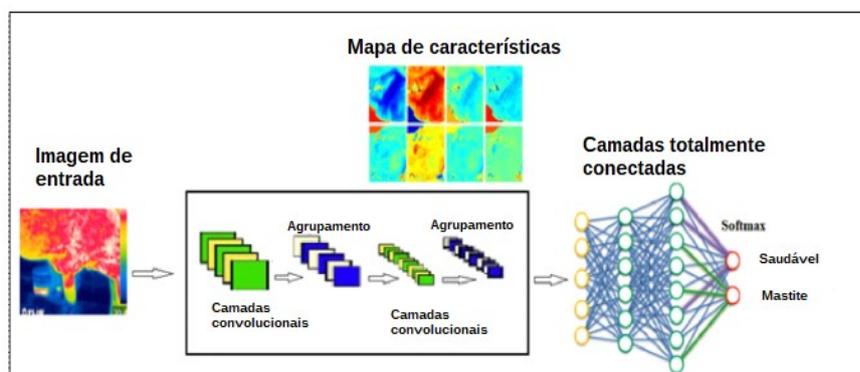


Figura 6: Arquitetura da rede convolucional.

Existem diferentes maneiras de aplicar o aprendizado por transferência. Uma delas é transferir o aprendizado como extrator de recursos e classificador. Nesse caso, os modelos de aprendizado profundo são arquiteturas multicamadas que aprendem diferentes recursos em vários níveis, eventualmente associadas a um conjunto de camadas totalmente conectadas para obter a saída final (SUBRAMANIAN et al., 2022).

Essa arquitetura em camadas permite usar uma rede pré-treinada, como ResNet50, sem sua camada final como extrator de recursos fixos para outras tarefas e adaptar a última camada, ou seja, a camada *softmax* para ter dois neurônios conforme as classes utilizadas.

Assim, em todos os modelos congelou-se toda a base convolucional e treinou-se somente o classificador, pois, neste caso, o modelo pré-treinado serviu como um extrator de características fixas para o conjunto de dados utilizado (mamografia e mastite).

As camadas convolucionais da rede foram responsáveis por extrair as características das imagens. Elas reconheceram o objeto procurando primeiro por características de baixo nível, como bordas, linhas e curvas e assim construíram características mais abstratas, por meio de uma série de camadas convolucionais (KRIZHEVSKY, SUTSKEVER e HINTON, 2017). Dessa forma, elas conseguiram reconhecer padrões extremamente complexos, adaptáveis a distorções e variações das imagens.

O emprego da ResNet50 neste estudo, deve-se ao fato de que a profundidade e a largura da rede neural são dois fatores importantes que determinam a complexidade da rede. Neste sentido, o erro de treinamento aumenta com o aumento da profundidade. Para resolver este problema, foi proposto o ResNet. A precisão do ResNet supera as redes tradicionais porque resolve o problema de dificuldade de treinamento causado pela profundidade da rede (HAN et al., 2019) por se tratar de uma das melhores redes para as tarefas de classificação de imagens (SOUZA et al., 2020).

3.4. Utilização dos pesos ImageNet para inicialização da rede e treino nas imagens de mastite (Mastitis – ResNet50)

Neste modelo, os pesos da ImageNet foram usados para treinamento diretamente na base de imagens térmicas do úbere de bovinos. Como o conjunto de dados é muito pequeno e bastante diferente do modelo pré-treinado, empregaram-se os pesos da ImageNet mantendo todas as camadas convolucionais congeladas (Figura 7).

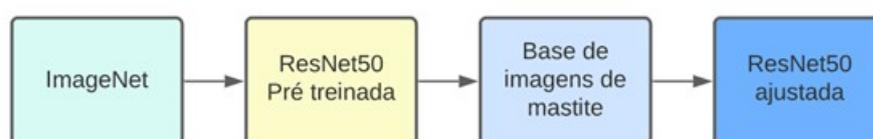


Figura 7: Fluxograma do modelo Mastitis – ResNet50.

As camadas de convolução que foram congeladas para o treinamento desse modelo aprendeu as características representativas das entradas. A camada de convolução foi composta por vários *kernels* de convolução, também conhecidos como filtros, usados para calcular diferentes mapas de características. Especificamente, cada neurônio de um mapa de características foi conectado a uma região de neurônios vizinhos na camada anterior. Tal vizinhança, refere-se ao campo receptivo do neurônio na camada anterior. Os mapas de características intermediárias foram obtidos usando diferentes filtros.

Matematicamente, o valor da característica na localização (I, j) referente ao k-ésimo mapa de características da l-ésima camada, $z_{i,j,k}^l$ (Eq. 1).

$$Z_{i,j,k}^l = w_k^l \cdot x_{i,j}^l + b_k^l \quad (1)$$

em que, $x_{i,j}^l$ é o fragmento da entrada centrada na posição (I, j) referente à l-ésima camada; w_k^l e b_k^l é o vetor de pesos e o termo de bias do k-ésimo filtro da l-ésima camada, respectivamente.

Observa-se que o filtro w_k^l que gera o mapa de característica $z_{i,j,k}^l$ foi compartilhado. Tal mecanismo de compartilhamento de pesos tem várias vantagens, como a redução da complexidade do modelo e a facilitação da etapa de treinamento da rede. O mapa de características final foi calculado em duas etapas: primeiro, a entrada foi convoluída com um filtro já aprendido e, em seguida, foi aplicada a função de ativação não-linear aos resultados da convolução.

Para esta abordagem, utilizou-se as camadas ResNet-50 pré-treinadas no conjunto de dados ImageNet sendo transferidas para o modelo Mastitis - ResNet50, substituindo as camadas fc (fully connected) por uma camada densa adequada para classificação binária das imagens térmicas do úbere de vacas de leite. Uma camada totalmente conectada tomou todos os neurônios na camada anterior e os conectaram a cada neurônio da camada atual. Em geral, os filtros da primeira camada convolucional são projetados para detectar características de baixo nível, enquanto os filtros das camadas superiores detectam características mais abstratas. Então, ao empilhar várias camadas convolucionais e de *pooling*, pode-se extrair gradualmente características com um maior nível de abstração. As camadas totalmente conectadas que seguiram as camadas convolucionais e de *pooling* interpretou essas características de alto nível de

abstração efetuando funções do raciocínio complexo. Por exemplo, a classificação de objetos em uma imagem.

Os hiperparâmetros utilizados no treinamento neste modelo foram: função de ativação da camada de saída (Softmax); camada de *pooling* médio, tamanho do lote (batch) – 32; função de ativação nas camadas ocultas (ReLU, Rectified Linear Units); otimizador (RMSprop); quantidade de épocas (100); dropout (0.2); taxa de aprendizado (0,0001) recomendada por Watz et al. (2019), Macedo et al. (2021) e Mehrotra et al. (2020); função de custo (entropia cruzada); *pooling* médio e camada densa de 50 neurônios.

3.5. Utilização dos pesos ImageNet, treino com as imagens de mamografia e ajuste fino para as imagens de mastite (Mammo_Mast_ImageNet – ResNet50)

Para esta abordagem, utilizou-se as camadas ResNet-50 pré-treinadas no conjunto de dados ImageNet, sendo transferidas para o modelo Mammo_Mast_ImageNet - ResNet50 (Figura 8).



Figura 8: Fluxograma do modelo Mammo_Mast_ImageNet – ResNet50.

Os hiperparâmetros utilizados no treinamento da base *MammoTherm* neste modelo foram: função de ativação da camada de saída (Softmax); camada de *pooling* médio, tamanho do lote (batch) – 32; função de ativação nas camadas ocultas (ReLU, Rectified Linear Units); otimizador (RMSprop); quantidade de épocas (100); dropout (0.2); taxa de aprendizado (0,001); função de custo (entropia cruzada); *pooling* médio e camada densa de 100 neurônios. Após treinar e armazenar o conhecimento aprendido, ele foi transferido para a base de imagens térmicas do úbere de vacas de leite, repetindo o treinamento para uma taxa de aprendizado menor (0,0001) usando o otimizador RMSprop.

3.6. Utilização de pesos aleatórios para inicialização da rede e ajuste fino para treino na base de imagens de mamografia e transferência para a base de imagens de mastite (Mammo_mastitis – ResNet50).

O modelo foi implementado inicializando a rede com pesos iniciais aleatórios e congelando as camadas convolucionais treinadas, para que não fossem alteradas ao treinar o restante do classificador (Figura 9).



Figura 9: Fluxograma do modelo Mammo_mastitis – ResNet50.

Os hiperparâmetros utilizados no treinamento neste modelo foram: função de ativação da camada de saída (Softmax); tamanho do lote (batch) – 32; função de ativação nas camadas ocultas (ReLU, Rectified Linear Units); otimizador (RMSprop); quantidade de épocas (100); *dropout* (0.2); taxa de aprendizado (0,001); função de custo (entropia cruzada); *pooling* médio e camada densa de 100 neurônios.

Após o treinamento e armazenamento do conhecimento aprendido, ele foi transferido para o banco de imagens do domínio final e repetido o treinamento com uma taxa de aprendizado menor (0,0001) usando o otimizador RMSprop com com 100 épocas cada.

3.7. Utilização dos pesos ImageNet com ajuste fino para o treino na base de imagens de mamografia e transferência de aprendizado com ajuste fino para a base de imagens de mastite (STL – ResNet50)

Este modelo foi primeiramente pré-treinado com o banco de dados ImageNet para obtenção do peso; em seguida, o peso foi transferido para o modelo ResNet50 aprimorado e o banco de dados *MamoTherm* foi usado para o treinamento e ajuste dos pesos. Por fim, o banco de dados de imagens térmicas do úbere de vacas de leite foi utilizado para treinar o modelo com o novo peso (Figura 10).



Figura 10: Processo de formação de aprendizagem por transferência sequencial (STL – ResNet50).

Os hiperparâmetros utilizados no treinamento neste modelo foram: função de ativação da camada de saída (Softmax); camada de *pooling* médio, tamanho do lote (batch) – 32; função de ativação nas camadas ocultas (ReLU, Rectified Linear Units); otimizador (RMSprop); quantidade de épocas (100); *dropout* (0.2); taxa de aprendizado (0,001); função de custo (entropia cruzada); e camada densa de 100 neurônios.

Esta etapa foi realizada congelando os pesos das primeiras camadas convolucionais e adicionando camadas densamente conectadas após as camadas convolucionais. A função de perda usada durante o refinamento foi a entropia cruzada.

Na camada densa, para as imagens térmicas do úbere de vacas de leite foi usado *average pooling*, adicionando duas camadas densas com 50 neurônios, com função de ativação *relu*, duas camadas *Dropout* com taxa de 50 e 20% e uma camada densa (saída) de 2 neurônios e função de ativação *softmax*. A função de perda usada durante o refinamento foi entropia cruzada.

3.8. Métricas de avaliação

Seguindo as mesmas métricas de desempenho nas referências relacionadas por Abiwinanda et al. (2019); Macedo et al. (2021) e Mehrotra et al. (2020) o desempenho da rede foi avaliado com base nas métricas: acurácia (Eq. 2), F1 score (Eq. 3) e visualização pela matriz de confusão.

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$F1 = \frac{2 \times \text{precisão} \times \text{recall}}{\text{precisão} + \text{recall}} \quad (3)$$

em que: TP - Verdadeiro Positivo; TN - Verdadeiro Negativo; FP - Falso Positivo; FN - Falso Negativo.

4. RESULTADOS

As curvas de acurácia e perda para os resultados de classificação das imagens obtidas nas redes de transferência de aprendizado foram apresentadas na Figura 11. Na simulação o conjunto de dados foi dividido em duas classes, balanceado utilizando 70% das imagens para treinamento 15% para validação e 15% para teste. A rede inicializada com pesos aleatórios (Mammo_mastitis — ResNet50) apresentou menor desempenho menor do que os demais modelos de transferência de aprendizado, com acurácia de 55,02% (Figura 11C).

A abordagem da rede inicializada com pesos do ImageNet (Mammo_mast_ImageNet — ResNet50) apontou resultados melhores, acurácia de 83,22% (Figura 11A). Valor mais elevado foi encontrado ao transferir diretamente para o banco de imagens de mastite (Mastitis — ResNet50) com acurácia de 86,1% (Figura 11B). Além disso, quando se utilizou o aprendizado por transferência sequencial (STL — ResNet50), o desempenho da rede foi superior, comparativamente aos demais modelos, com acurácia de 88,03% (Figura 11D).

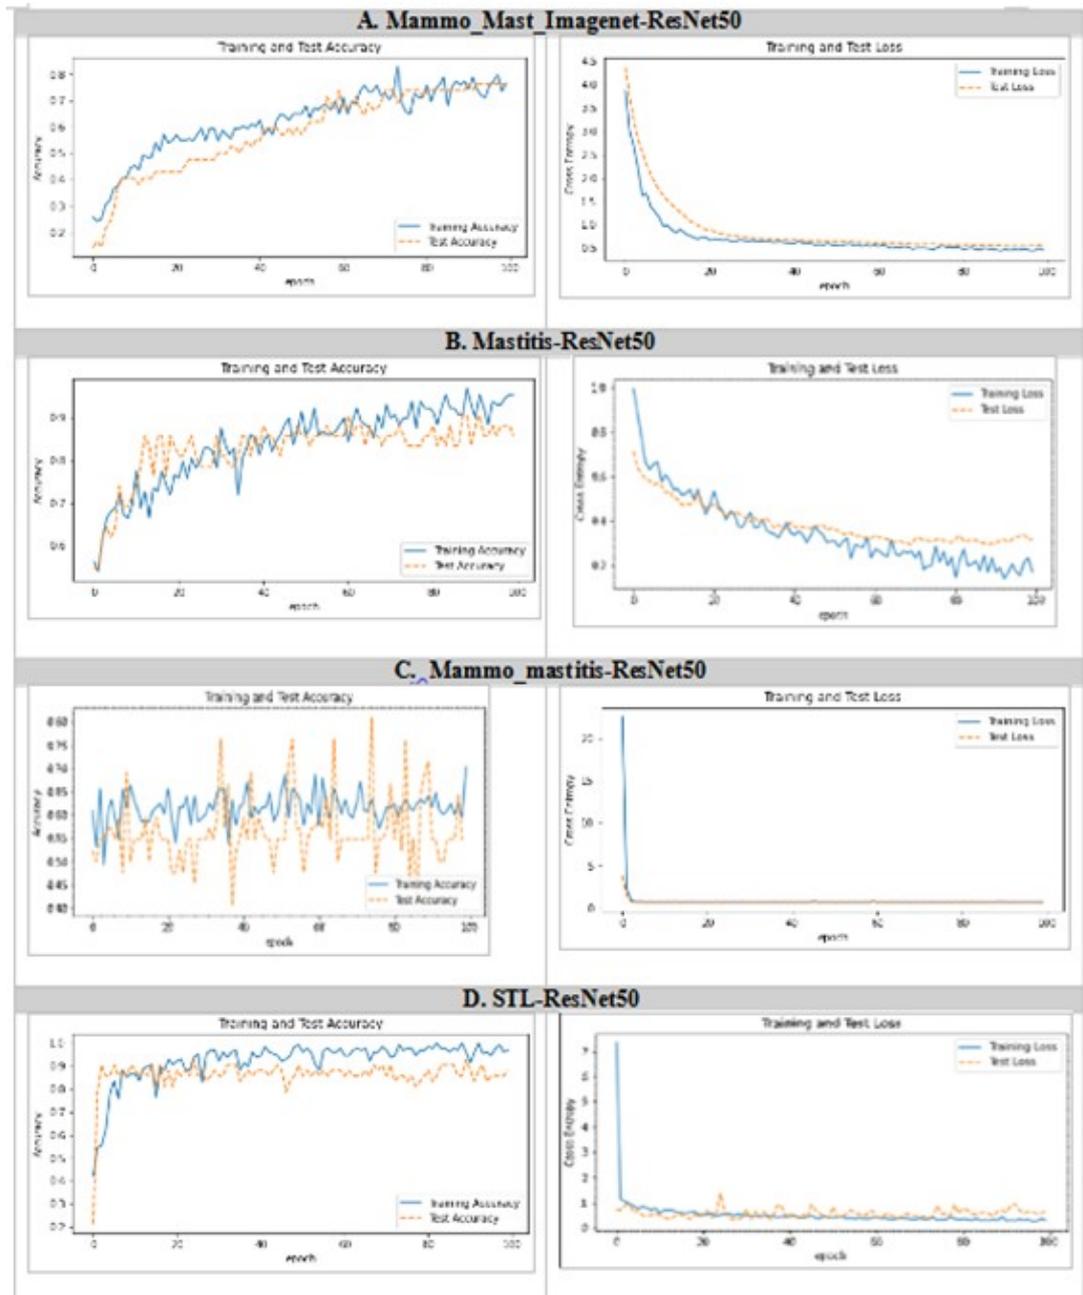


Figura 11: Curvas de acurácia e perda no treinamento e teste para os modelos utilizados nas redes.

A F1 score considera abrangentemente a precisão e o recall, o seu resultado juntamente com o da acurácia pode refletir melhor a superioridade do desempenho do modelo, pois a diminuição de falsos positivos tem melhora a produtividade como maior confiabilidade, diminui os custos para tratamento da enfermidade, promove o maior valor pago ao produtor pelo leite, em função da melhoria na qualidade. De uma forma geral, uma boa acurácia auxilia o produtor a agir precisamente quanto a incidência da mastite

subclínica, gerando menor descarte de animais com potencial de produção de leite, melhora a sanidade e o bem-estar do rebanho.

Ao comparar os resultados dos modelos, eles mostram diferenças consideráveis. A acurácia do modelo em que foi realizada a transferência sequencial foi superior aos demais. Comparado com os modelos em que os pesos da rede pré-treinada no ImageNet foram usados para o treinamento da rede (Mammo_Mast_ImageNet — ResNet50 e Mastitis — ResNet50) foi 5,68% e 2,27% maior, respectivamente e, 26,14% maior, quando comparado ao modelo em que foram usados pesos aleatórios para inicialização da rede (Mammo_mast — ResNet50). Isso porque, quando a simulação é inicializada com os pesos pré-treinados da rede, acima de 1000 classes (ImageNet), significa que a rede aprendeu vários recursos dessas imagens.

4.1. Desempenho dos modelos na classificação

O desempenho dos quatro modelos na tarefa de classificação de imagens térmicas do úbere de vacas de leite (animais saudáveis e animais com mastite subclínica) foi comparado usando a visualização da matriz de confusão (Figura 12).

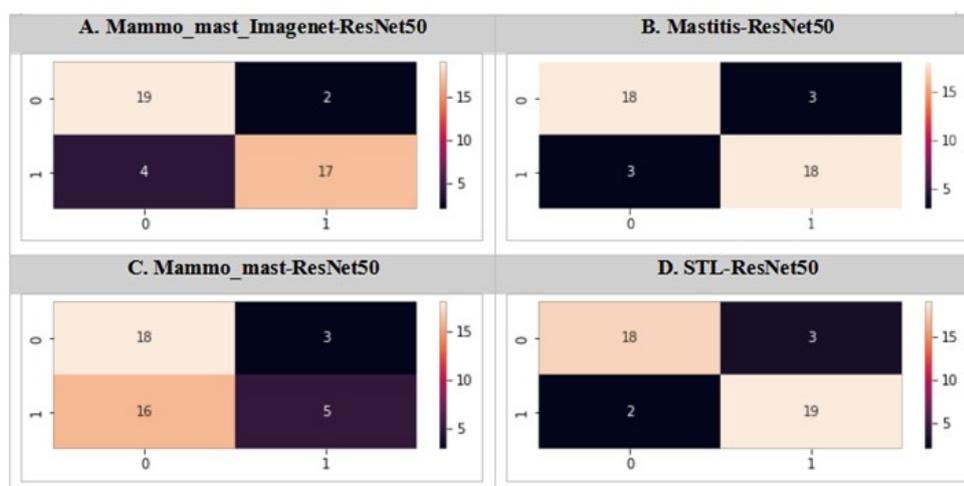


Figura 12: Matrizes de confusão dos quatro modelos empregados na classificação das imagens (0 – animal saudável; 1 – animal com mastite subclínica).

Com base nos resultados da matriz de confusão da classificação binária e os resultados calculados através dela: taxa positiva verdadeira (proporção de resultados corretamente classificados como positivo no resultado do modelo), taxa negativa verdadeira (proporção de resultados classificados como negativos fora de todas as

instâncias que não eram originalmente negativo), taxa de falsos positivos e taxa de falsos negativos, observa-se na Figura 12D que a proporção de identificação (taxa positiva verdadeira e taxa negativa verdadeira) do STL — ResNet50 foi maior do que a dos outros modelos. A proporção de acertos na identificação atingiu 88% para animais saudáveis e animais com mastite subclínica. Isso ocorreu principalmente porque o uso de ajuste fino nas imagens de treinamento, primeiro adaptou a rede às novas classes utilizadas e, posteriormente, a rede foi adaptada às imagens de mastite, obtendo bom desempenho.

Quando os conjuntos de dados de destino são muito menores do que os conjuntos de dados de origem, o ajuste fino ajuda a melhorar a capacidade de generalização dos modelos.

Verificou-se proporção de erros (taxa de falsos positivos e taxa de falsos negativos) maior nos modelos Mammo_mast_ImageNet — ResNet50 (19 e 17%) (Figura 12A) e Mastitis — ResNet50 (18 e 17%) (Figura 12B), seguidos pelo modelo Mammo_mast — ResNet50 (18 e 5%) (Figura 12C). O uso de pesos aleatórios no modelo (Mammo_mast — ResNet50) influenciou a proporção identificação das taxas de acerto e erro.

5. DISCUSSÃO

O diagnóstico de mastite subclínica por imagem térmica, geralmente é apontado pela observação de mudanças de temperatura na região da glândula mamária, bem como pela detecção de mastite bovina em estágio inicial (POLAT et al., 2010; SILVA et al., 2020). Assim, o sucesso da classificação automática por transferência de recursos entre um domínio (MamoTherm — detecção de câncer de mama em humanos) e o domínio alvo (mastite subclínica bovina) pode estar associado à semelhança entre as tarefas referentes às duas bases.

Para se treinar um classificador de imagens de mastite, foi necessário um banco de dados grande o suficiente para obter resultados confiáveis; no entanto, quando os animais são diagnosticados, passam rapidamente por tratamento, dificultando sua obtenção. Nesse contexto, o uso do banco de dados de mamografia auxiliou no processo de aprendizagem para detecção de mastite bovina (STL — ResNet50).

Em relação à transferibilidade da aprendizagem, esta pode ser afetada pela distância entre as tarefas. Neste estudo, a proximidade das tarefas deveu-se ao uso de

imagens térmicas com dois problemas semelhantes (YOSINSKI et al., 2014). O uso dos pesos da ImageNet nos modelos também contribuiu para o sucesso da classificação.

A justificativa do uso dos pesos do ImageNet para inicialização foi a existência de pesos otimizados para resolver o problema de classificação, por se tratar de uma base de 1000 classes (ImageNet), então foi pertinente usar esses pesos para resolver o problema alvo.

Como as camadas iniciais da rede são responsáveis por aprender a detectar formas geométricas básicas e padrões simples, então ela pode ser reutilizada para qualquer tipo de problema. Mas os pesos das camadas finais devem ser retreinados por dependerem da natureza do problema. Uma rede pré-treinada sempre convergirá mais rápido, pelo fato dos pesos serem iniciados em uma região mais promissora do espaço de busca.

O desempenho do modelo STL — ResNet50 foi superior em acurácia, mesmo com o menor número de parâmetros. Comparado aos demais modelos, o método de busca proposto possui o maior número de amostras corretas e no desempenho geral, o método proposto neste trabalho apresenta mais vantagens.

No aprendizado de transferência sequencial, o ajuste fino, que faz parte do processo, foi realizado sucessivamente, treinando as camadas finais da rede para se adaptarem, tanto às imagens da mamografia, quanto ao problema alvo (mastite). Essas sucessivas etapas de ajuste fino permitiram ganhos de precisão, devido à inicialização dos pesos, adaptando melhor a rede a classificação das imagens térmicas de animais saudáveis e com mastite subclínica.

As camadas iniciais da rede extraíram os recursos básicos da imagem. Na base de pré-treinamento, as camadas finais identificaram a classe correta. Quando a base mudou, essa parte final precisou ser retreinada, para a rede aprender a detectar a nova classe.

6. CONCLUSÕES

As metodologias preditivas propostas, baseadas em transferência de conhecimento para detecção automática de mastite subclínica bovina, classificaram corretamente as imagens, porém, o modelo de aprendizagem por transferência sequencial (STL_ResNet50) apresentou melhor desempenho (88,03%) em relação aos demais modelos estudados (Mammo_mast_ImageNet — ResNet50, Mastitis — ResNet50, Mammo_mast — ResNet50) 83,22, 86,1 e 55,02%, respectivamente,

contribuindo significativamente para a detecção automática de animais saudáveis e com mastite subclínica, a partir de imagens térmicas do úbere de vacas de leite.

As abordagens nas quais os pesos da ImageNet foram usados (Mastitis – ResNet50, Mammo_mast_ImageNet – ResNet50 e STL — ResNet50), tiveram melhor desempenho em comparação com o modelo em que os pesos aleatórios foram empregados.

REFERÊNCIAS

ABIWINANDA, N.; HANIF, M.; HESAPUTRA, S. T.; HANDAYANI, A.; MENGKO, T. R. Brain Tumor Classification Using Convolutional Neural Network. World Congress on Medical Physics and Biomedical Engineering 2018, Springer, Singapore, p. 183-189, 2019

ADDIS, M. F.; TEDDE, V.; PUGGIONI, G. M. G.; PISANU, S.; CASULA, A.; LOCATELLI, C.; ROTA, N.; BRONZO, V.; MORONI, P.; UZZAU, S. Evaluation of milk cathelicidin for detection of bovine mastitis. Journal of Dairy Science, n.99, v.10, p. 8250–8258, 2016.

ANKINAKATTE, S.; NORBERG, E.; LOVENDAHL, P.; EDWARDS, D.; HOJSGAARD, S. Predicting mastitis in dairy cows using neural networks and generalized additive models: A comparison. Computers and Electronics in Agriculture, 99, p. 6, 2013.

ARAÚJO, M. C.; SOUZA, R. M. C. R.; LIMA, R. C. F.; FILHO, T. M. S. An interval prototype classifier based on a parameterized distance applied to breast thermographic images. Medical & Biological Engineering & Computing, n.55, v.6, p.873–884., 2017.

BEZERRA, L. A.; RIBEIRO, R. R.; LYRA, P. R. M.; LIMA, R. C. F. An empirical correlation to estimate thermal properties of the breast and of the breast nodule using thermographic images and optimization techniques. International Journal of Heat and Mass Transfer, n. 149, p. 119215, 2020.

BORTOLAMI, A.; FIORE, E.; GIANESELLA, M.; CORRÓ, M.; CATANIA, S.; MORGANTE, M. Evaluation of the udder health status in subclinical mastitis affected dairy cows through bacteriological culture, somatic cell count and thermographic imaging. Polish Journal of Veterinary Sciences, n.18, v.4, 799–805, 2015.

BOUMARAF, S.; LIU, X.; ZHENG, Z.; MA, X.; FERKOUS, C. A new transfer learning based approach to magnification dependent and independent classification of breast cancer in histopathological images. Biomedical Signal Processing and Control, v. 63, p.102192, 2021.

Brain Tumor MRI Dataset. <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>

CAO, S.; ZHAO, D., LIU, X.; SUN, Y. Real-time robust detector for underwater live crabs based on deep learning. *Computers and Electronics in Agriculture*, 172, 105339, 2020.

CAVERO, D.; TOLLE, K.-H.; RAVE, G.; BUXADÉ, C.; KRIETER, J. Analysing serial data for mastitis detection by means of local regression. *Livestock Science*, n.110, v.1–2, p.101–110, 2007

DAS, R.,;SAILO, L.; VERMA, N.; BHARTI, P.; SAIKIA, J.; IMTIWATI, KUMAR, R. Impact of heat stress on health and performance of dairy animals: A review. *Veterinary World*, n. 9, v. 3, p. 260–268, 2016.

DALEN, G.; RACHAH, A.; NORSTEBO, H.; SCHUKKEN, Y. H.; REKSEN, O. The detection of intramammary infections using online somatic cell counts. *Journal of Dairy Science*, n.102, v.6, p. 5419–5429, 2019.

DA SILVA, R. A. B.; PANDORFI, H.; DE ALMEIDA, G. L. P.; DE ASSUNÇÃO Montenegro, A. A.; DA SILVA, M. V. Spatial dependence of udder surface temperature variation in dairy cows with healthy status and mastitis. *Revista Brasileira de Saude e Produção Animal*, 20, 2019.

DE VASCONCELOS; J. H., DOS SANTOS, W. P.; DE LIMA, R. C. F. Analysis of Methods of Classification of Breast Thermographic Images to Determine their Viability in the Early Breast Cancer Detection. *IEEE Latin America Transactions*, n.16, v.6, p.1631–1637, 2018.

DIABETIC RETINOPATHY 2015 DATA COLORED RESIZED.
<https://www.kaggle.com/datasets/sovitath/diabetic-retinopathy-2015-data-colored-resized>

HAN, L.; YU, C.; XIAO, K.; ZHAO, X. A New Method of Mixed Gas Identification Based on a Convolutional Neural Network for Time Series Classification. *Sensors*, n.19, v.9, p. 1960, 2019.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), p. 770–778, 2016.

HUYBRECHTS, T.; MERTENS, K.; DE BAERDEMAEKER, J.; DE KETELAERE, B.; SAEYS, W. Early warnings from automatic milk yield monitoring with online synergistic control. *Journal of Dairy Science*, n.97, v. 6, p. 3371–3381, 2014.

JENSEN, D. B.; HOGVEEN, H.; DE VRIES, A. Bayesian integration of sensor information and a multivariate dynamic linear model for prediction of dairy cow mastitis. *Journal of Dairy Science*, 99(9), 7344–7361, 2016.

KHATUM, M.; CLARK, C. E. F.; LYONS, N. A.; THOMPSEON, P. C.;KERRISK, K. L.; GARCIA, S. C. Early detection of clinical mastitis from electrical conductivity data in an automatic milking system. *Animal Production Science*, n.57, v.7, 1226, 2017.

- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, n. 60, v.6, p.84–90, 2017.
- LIMA, R. S.; DANIELSKI, G. C.; PIRES, A. C. S. Mastitis Detection and Prediction of Milk Composition Using Gas Sensor and Electrical Conductivity. *Food and Bioprocess Technology*, n. 11, v.3, p. 551–560, 2018.
- MACÊDO, D.; DREYER, P.; LUDEMIR, T.; ZANCHETTIN, C. Training Aware Sigmoidal Optimizer. *arXiv preprint arXiv: 2102.08716v1*, 2021.
- MAMMOTHERM. Disponível em: <https://github.com/Biomedical-Computing-UFPE/MammoTherm>. Acesso em 29/04/2022.
- MARRERO, M. G.; RIJOS-FERNADÉZ, C.; VÉLEZ-ROBLES, Y.; ORTIZ-COLÓN, G.; SÁNCHEZ-RODRIGUEZ, H.; JIMENÉZ-CABÁN, E.; CURBELO-RODRIGUEZ, 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.
- MEHROTRA, R.; ANSARI, M. A.; AGRAWAL, R.; ANAND, R. S. A Transfer Learning approach for AI-based classification of brain tumors. *Machine Learning with Applications*, n. 2, p. 100003, 2020.
- 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*, n. 123, p. 10–16, 2016.
- MIEKLEY, B.; TRAULSEN, I.; KRIETER, J. Mastitis detection in dairy cows: the application of support vector machines. *The Journal of Agricultural Science*, n.151, v.6, p. 889–897, 2013.
- NIELEN, M.; SCHUKKEN, Y. H.; BRAND, A.; HARING, S.; FERWERDA-VAN ZONNEVELD, R. T. Comparison of Analysis Techniques for On-Line Detection of Clinical Mastitis. *Journal of Dairy Science*, n.78, v.5, p.1050–1061, 1995.
- POLAT, B.; COLAK, A.; CENGIZ, M.; YANMMAZ, L. E.; ORAL, H.; BASTAN, A.; KAYA, S.; HAYIRLI, A. Sensitivity and specificity of infrared thermography in detection of subclinical mastitis in dairy cows. *Journal of Dairy Science*, n.93, v.8, p. 3525–3532, 2010.
- PORTER, I. R.; WIELAND, M.; BASRAN, P. S. Feasibility of the use of deep learning classification of teat-end condition in Holstein cattle. *Journal of Dairy Science*, n.104, v.4, p. 4529–4536, 2021.
- POSSENTI, C. G. R.; HORN, R. C.; MORI, N. C.; RIBAS JÚNIOR, V.; GOLLE, D. P.; KOEFENDER, J. Avaliação de Estresse oxidativo no plasma de bovinos leiteiros com mastite. *Ciência Animal Brasileira*, n.19, 2018.

RODRIGUES, A. L.; DE SANTANA, M. A.; AZEVEDO, W. W.; BEZERRA, R. S.; BARBOSA, V. A. F.; DE LIMA, R. C. F.; DOS SANTOS, W. P. Identification of mammary lesions in thermographic images: feature selection study using genetic algorithms and particle swarm optimization. *Research on Biomedical Engineering*, n. 35, v.3–4, p. 213–222, 2019.

RODRIGUEZ ALVAREZ, J.; ARROQUI, M.; MANGUDO, P.; TOLOZA, J.; JATIP, D.; RODRIGUEZ, J. M.; TEYSEYRE, A.; SANZ, C.; ZUNINO, A. MACHADO, C.; MATEOS, C. Body condition estimation on cows from depth images using Convolutional Neural Networks. *Computers and Electronics in Agriculture*, n.155, p. 12–22, 2018.

RUEGG, P. L. A 100-Year Review: Mastitis detection, management, and prevention. *Journal of Dairy Science*, n.100, v.12, p. 10381–10397, 2017.

SANTANA, M. A. de; PEREIRA, J. M. S.; SILVA, F. L. da; LIMA, N. M. de; SOUSA, F. N. de; ARRUDA, G. M. S. de; LIMA, R. C. F. De; SILVA, W. W. A. da; SANTOS, W. P. dos. Breast cancer diagnosis based on mammary thermography and extreme learning machines. *Research on Biomedical Engineering*, n. 34, v.1, p. 45–53, 2018.

SIEMON, M. S. N.; SHIHAVUDDIN, A. S. M.; RAVN-HAREN, G. Sequential transfer learning based on hierarchical clustering for improved performance in deep learning based food segmentation. *Scientific Reports*, n.11, v.1, 813, 2021.

SILVA, L.; ARAÚJO, L.; SOUZA, V.; SANTOS, A.; NETO, R. Redes Neurais Convolucionais Aplicadas na Detecção de Pneumonia Através de Imagens de Raio-X. *Anais Do 14. Congresso Brasileiro de Inteligência Computacional*, p.1–8, 2020.

SILVA, E. P. E.; MORAES, E. P.; ANAYA, K.; SILVA, Y. M. O.; LOPES, H. A. P.; ANDRADE NETO, J. C.; OLIVEIRA, J. P. F.; OLIVEIRA, J. B.; RANGEL, A. H. N. Lactoperoxidase potential in diagnosing subclinical mastitis in cows via image processing. *PLOS ONE*, n. 17, v.2, e0263714, 2022.

SILVA, R. A. B. da, LIMA, J. P. S. do M., PANDORFI, H.; ALMEIDA, G. L. P. de. Thermal Image Thresholding for Automatic Detection of Bovine Mastitis. *International Journal of Computer Applications*, n.183, v. 14, p. 29–33, 2021.

SOUZA, V.; SILVA, L.; SANTOS, A.; ARAÚJO, L. Análise Comparativa de Redes Neurais Convolucionais no Reconhecimento de Cenas. *Anais Do XI Computer on the Beach - COTB '20*, p. 419–426, 2020.

SOYEURT, H.; BASTIN, C.; COLINET, F. G.; ARNOUD, V. M. R.; BERRY, D. P.; WALL, E.; DEHARENG, F.; NGUYEN, H. N.; DARDENNE, P.; SCHEFERS, J.; VANDENPLAS, J.; WEIGEL, K.; COFFEY, M.; THÉRON, L.; DETILLEUX, J.; REDING, E.; GENGLER, N.; McPARLAND, S. Mid-infrared prediction of lactoferrin content in bovine milk: potential indicator of mastitis. *Animal*, n.6, v.11, p. 1830–1838, 2012.

SUN, Z.; SAMARASINGHE, S.; JAGO, J. Detection of mastitis and its stage of progression by automatic milking systems using artificial neural networks. *Journal of Dairy Research*, n.77, v.2, p. 168–175, 2010.

SUBRAMMANIAN, M., NARASIMHA PRASAD, L.V.; JANAKIRAMAIAH, B.; MOHAN, B.; SATHISHKUMAR, V. Hyperparameter Optimization for Transfer Learning of VGG16 for Disease Identification in Corn Leaves Using Bayesian Optimization. *Big Data*, n.10, v.3, p. 215–229, 2022.

SWATI, Z. N. K.; ZHAO, Q.; KABIR, M.; ALI, F.; ALI, Z.; AHMED, S.; LU, J. Brain tumor classification for MR images using transfer learning and fine-tuning. *Computerized Medical Imaging and Graphics*, n. 75, p.34–46, 2019.

TAYLOR, L.; NITSCHKE, G. Improving Deep Learning using Generic Data Augmentation. *arXiv preprint arXiv:1708.06020*, 2017.

THE INTERNATIONAL SKIN IMAGING COLLABORATION (ISIC) Website, "ISIC 2018: Skin Lesion Analysis Towards Melanoma Detection," <https://challenge2018.isic-archive.com/>.

VAN DER VOORT, M.; JENSEN, D.; KAMPHUIS, C.; ATHANNASIADIS, I. N.; DE VRIES, A.; HOGEVEEN, H. Invited review: Toward a common language in data-driven mastitis detection research. *Journal of Dairy Science*, n.104, v.10, p.1 0449–10461, 2021.

VIGUIER, C.; ARORA, S.; GILMARTIN, N.; WELBECK, K.; O'KENNEDY, R. Mastitis detection: current trends and future perspectives. *Trends in Biotechnology*, n.27, v.8, p.486–493, 2009

WANG, D.; TANG, J.; ZHU, W.; LI, H.; XIN, J.; HE, D. Dairy goat detection based on Faster R-CNN from surveillance video. *Computers and Electronics in Agriculture*, 154, 443–449, 2018.

WATZ, S.; PETZL, W.; ZERBE, H.; RIEGGER, A.; GLAS, A.; Schröter, W.; LANDGRAF, T.; METZNER, M. Technical note: Automatic evaluation of infrared thermal images by computerized active shape modeling of bovine udders challenged with *Escherichia coli*. *Journal of Dairy Science*, n.102, v.5, p. 4541–4545, 2019.

WONG, S. C.; GATT, A.; STAMATESCU, V.; McDONNELL, M. D. Understanding data augmentation for classification: when to warp? In *2016 international conference on digital image computing: techniques and applications (DICTA)*, p. 1–6, 2016.

WILSON, A.C.; ROELOFS, R.; STERN, M.; SREBRO, N.; RECHT, B. The marginal value of adaptive gradient methods in machine learning. In *Advances in Neural Information Processing Systems*, In *Neural Information Processing Systems*, p. 4148–4158, 2017.

YOSINSKI, J.; CLUNE, J.; BENGIO, Y.; LIPSON, H. How transferable are features in deep neural networks? In: *Advances in neural information processing systems*. 3320–3328, 2014.

XUDONG, Z.; XI, K.; NINGNING, F.; GANG, L. Automatic recognition of dairy cow mastitis from thermal images by a deep learning detector. *Computers and Electronics in Agriculture*, n. 178, p. 105754, 2020.

ZANINELLI, M.; REDAELLI, V.; LUZI, F.; BRONZO, V.; MITCHELL, M.; DELL'ORTO, V.; BONTEMPO, V.; CATTANEO, D.; SAVOINI, G. First Evaluation of Infrared Thermography as a Tool for the Monitoring of Udder Health Status in Farms of Dairy Cows. *Sensors*, n.18, v.3, 862, 2018.

ZHANG, Z.; LI, X. P.; YANG, F.; LUO, J. Y.; WANG, X. R.; LIU, L. H.; LI, H. S. Influences of season, parity, lactation, udder area, milk yield, and clinical symptoms on intramammary infection in dairy cows. *Journal of Dairy Science*, n.99, v.8, p.6484–6493, 2016.

ZHAO, X.; LI, K.; LI, Y.; MA, J.; Zhang, L. Identification method of vegetable diseases based on transfer learning and attention mechanism. *Computers and Electronics in Agriculture*, 193, 106703, 2022.

CAPÍTULO IV

Identificação automática de mastite bovina utilizando transferência de aprendizagem sequencial com otimização bayesiana

IDENTIFICAÇÃO AUTOMÁTICA DE MASTITE BOVINA UTILIZANDO TRANSFERÊNCIA DE APRENDIZAGEM SEQUENCIAL COM OTIMIZAÇÃO BAYESIANA

RESUMO

A bovinocultura de leite é uma atividade em franco crescimento no Brasil e no mundo, no entanto, este setor enfrenta um grande entrave, a mastite bovina, que ocasiona inúmeras perdas na produção de leite e na longevidade do rebanho. Alguns métodos de diagnóstico de mastite vêm sendo utilizados ao longo dos anos, porém, além da subjetividade, apresentam custo elevado, sendo de grande importância o desenvolvimento de ferramentas que ofereçam diagnóstico precoce, seguro, não invasivo e de baixo custo, como o diagnóstico por imagens térmicas. Dessa forma, este estudo foi conduzido com o objetivo de desenvolver uma metodologia preditiva baseada em transferência de conhecimento sequencial utilizando ResNet50 com pesos ImageNet, e otimização de hiperparâmetros bayesiana, para detecção automática de mastite subclínica bovina, por meio da visão computacional. O banco de imagens utilizado na pesquisa foi constituído por 165 imagens de 360 x 360 pixels, referente ao banco de dados de 55 bovinos com diagnóstico prévio de mastite subclínica e saudável, provenientes de três unidades de produção, localizadas nos municípios de Capoeiras e Pesqueira, estado de Pernambuco e município de Russas, estado do Ceará, Brasil. As imagens utilizadas na transferência sequencial de aprendizado foram *MammoTherm* (detecção de câncer de mama em mulheres). O melhor desempenho da rede foi o do modelo otimizado que alcançou 92,1% de acurácia comparativamente ao modelo utilizando pesquisa manual (86,1%). A acurácia neste último foi alcançada em 100 épocas, o mesmo não ocorreu no modelo otimizado que obteve o melhor desempenho utilizando 11 épocas. O melhor modelo obteve número de neurônios na camada densa personalizada de 64 e taxa de aprendizagem para treinamento no conjunto de imagens de 0,0001. A taxa utilizada na regularização l2 foi de 0,001 com função de ativação elu e taxa de dropout de 0,5. As metodologias preditivas propostas com base na transferência de conhecimento para detecção automática de mastite subclínica bovina classificaram corretamente as imagens, contribuindo significativamente para a detecção

automática de animais saudáveis e animais com mastite subclínica a partir de imagens térmicas do úbere de vacas leiteiras.

Palavras-chave: análise de imagem, bovinocultura de leite, rede neural convolucional, termografia infravermelho

AUTOMATIC IDENTIFICATION OF BOVINE MASTITIS USING SEQUENTIAL LEARNING TRANSFER WITH BAYESIAN OPTIMIZATION

ABSTRACT

Dairy cattle breeding is a fast growing activity in Brazil and in the world; however, this sector faces a great obstacle, bovine mastitis, which causes several losses in milk production and herd longevity. Some methods of mastitis diagnosis have been used over the years, however, in addition to subjectivity, they are expensive, and it is of great importance to develop tools that offer early, safe, non-invasive, and low-cost diagnosis, such as a diagnosis by thermal imaging. Thus, this study was conducted with the objective of developing a predictive methodology based on sequential knowledge transfer using ResNet50 with ImageNet weights and Bayesian hyperparameter optimization, for the automatic detection of subclinical bovine mastitis through computer vision. The image database used in the research consisted of 165 images of 360 x 360 pixels, referring to the database of 55 cattle previously diagnosed with subclinical mastitis and healthy, from three production units, located in the municipalities of Capoeiras and Pesqueira, state of Pernambuco and municipality of Russas, state of Ceará, Brazil. The images used in the sequential learning transfer were MammoTherm (breast cancer detection in women). The best performance of the network was the optimized model which achieved 92.1% accuracy, compared to the model using manual search (86.1%). The accuracy of the latter was achieved over 100 epochs, which was not the case for the optimized model, which achieved the best performance using 11 epochs. The best model obtained a number of neurons in the custom dense layer of 64 and a learning rate for training on the image set of 0.0001. The rate used in l2 regularization was 0.001 with elu activation function and dropout rate of 0.5. The proposed predictive methodologies based on knowledge transfer for automatic detection of bovine subclinical mastitis correctly classified the images, contributing significantly to the automatic detection of healthy animals and animals with subclinical mastitis from udder thermal images of dairy cows.

Keywords: image analysis, dairy cattle, convolutional neural network, infrared thermography

1. INTRODUÇÃO

A mastite bovina é a doença que mais prejudica o setor leiteiro no mundo. Detecção e diagnóstico da mastite bovina pode desempenhar um papel importante na redução das perdas econômicas devido ao tratamento precoce da doença. Por esse motivo, o desenvolvimento de métodos automáticos de detecção de mastite é cada vez mais incentivado (ZANINELLI et al., 2019; ZHANG et al., 2020; SILVA et al., 2021).

A forma de mastite que mais causa prejuízos é a forma subclínica, pois quando infectado o animal não sente dor ou outros sintomas, pois é uma infecção silenciosa e os produtores não conseguem detectá-la a olho nu, mas por métodos diagnósticos aplicados no campo como contagem de células somáticas (CCS) e cultura microbiana (VIGUIER et al., 2009).

O método mais comum é o *California Mastitis Test* (CMT) realizado na sala de ordenha, por se tratar de um procedimento barato, rápido e fácil (RUEGG, 2017), no entanto, é subjetivo, pois depende da interpretação humana, oferecendo menos precisão e confiabilidade (LIMA et al., 2018).

Assim, quando o animal adoece com mastite, ocorre um aumento da temperatura na região do úbere, o que, segundo estudos já realizados, foi detectado pela termografia. Esse aparelho é capaz de mapear a temperatura corporal de forma não invasiva, promovendo bem-estar animal, podendo detectar alterações decorrentes do estado inflamatório da mastite (POLAT et al., 2010; SILVA et al., 2019; ZANINELLI et al., 2019; WATZ et al., 2019).

Entre muitos modelos de aprendizado profundo, redes neurais convolucionais ou CNNs são as arquiteturas mais populares. Devido às suas características comparativamente simples e robustas (KERMANY et al., 2018), tem sido amplamente aplicado no desenvolvimento de sistemas de análise de imagens médicas (NEGASSI et al., 2020). No entanto, uma das principais desvantagens da rede neural convolucional é que ela requer grandes quantidades de dados para treinamento, o que às vezes é difícil de obter no campo.

Assim, a aprendizagem por transferência tornou-se recentemente uma estratégia popular entre os pesquisadores para abordar esta questão (BOUMARAF et al., 2021; PORTER, WIELAND e BASRAN, 2021; SWATI et al., 2019; DAS et al., 2016). O padrão atual de aprendizado por transferência é selecionar e usar um modelo existente, que foi originalmente treinado usando um grande conjunto de dados de imagens

naturais, como ImageNet (DENG et al., 2009) e, em seguida, ajustar o modelo usando dados limitados de imagens.

Apesar das vantagens da CNN, uma das maiores dificuldades ou desafios do uso de CNNs é como treinar ou ajustar o modelo de forma otimizada, devido ao problema dos gradientes de fuga, o que pode dificultar o processo de treinamento na identificação do “melhor” ou ótimo resultado convergente (YANG e SHAMI, 2020).

Assim, muitas arquiteturas de aprendizado profundo foram desenvolvidas e testadas recentemente. Estudos anteriores compararam muitos modelos de aprendizado profundo e descobriram que o modelo ResNet50 era a melhor arquitetura para a tarefa de classificação de imagens, com maior precisão e eficiência para treinar (BRESSEM et al., 2020).

Neste sentido, algoritmos de aprendizado de máquina possuem parâmetros específicos, também conhecidos como hiperparâmetros. Para ajustá-los deve haver a seleção da melhor configuração. Para isso, existem métodos teóricos de decisão baseados no conceito de definir um espaço de busca de hiperparâmetros e então detectar a melhor combinação (YANG e SHAMI, 2020).

A otimização Bayesiana é um dos métodos de pesquisa de hiperparâmetros que vem superando a pesquisa de grade e pesquisa aleatória, pois, ao contrário destas abordagens, ela faz uso do conhecimento de iterações anteriores do algoritmo. Ou seja, a otimização Bayesiana otimiza a tomada de decisão sobre qual a configuração de hiperparâmetro é ideal para avaliar um modelo (PELIKAN, GOLDBERG e CANTU’-PAZ, 1999; SAMEEN, PRADHAN e LEE, 2020).

Neste artigo foi estudada a técnica de transferência de aprendizado sequencial, utilizando ResNet50, com pesos do ImageNet e otimização de hiperparâmetros bayesiana.

2. MATERIAL E MÉTODOS

A abordagem por transferência de aprendizado é uma técnica utilizada para resolver uma determinada tarefa utilizando o conhecimento obtido ao resolver uma tarefa relacionada (Figura 1).

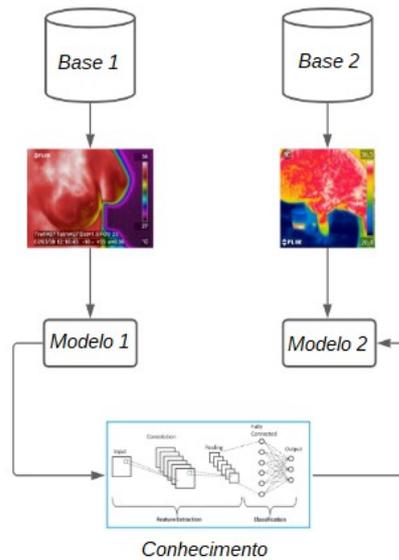


Figura 1: Abordagem de aprendizagem por transferência.

A rede profunda utilizada nesta abordagem utilizou pesos ImageNet pois isso facilita a aprendizagem de novas características referentes às novas classes, o que faz com que a rede comece o treinamento de forma otimizada (YOSINSKI et al., 2014).

Para aproveitar as vantagens do aprendizado por transferência, utilizou-se neste estudo o modelo de transferência sequencial usando a rede pré-treinada para identificar as imagens térmicas do úbere de bovinos de leite. O método de ajuste fino em redes neurais previamente treinadas foi utilizado para criar modelos no aprendizado por transferência, que teve como função principal a transferência de informações entre áreas relacionadas.

A aplicação utilizada neste estudo foi a transferência de aprendizado como extrator de recursos e classificador. Nesse caso, os modelos de aprendizado profundo, que são arquiteturas multicamadas, aprendem diferentes recursos em vários níveis (SUBRAMANIAN et al., 2022).

Essa arquitetura em camadas nos permite usar uma rede pré-treinada, como ResNet50, sem sua camada final (FC), sendo que as camadas convolucionais são utilizadas como extrator de recursos fixos e as camadas FC adaptadas para as classes utilizadas (animal saudável e animal com mastite subclínica).

2.1. Abordagem por transferência sequencial

A abordagem por transferência de aprendizado em duas etapas, implicou na extração do conhecimento entre conjuntos de imagens em uma sequência de etapas e

possibilitou o ganho de desempenho (SIEMON, SHIHAVUDDIN e RAVN - HAREN, 2021).

No problema de classificação de mastite, a rede é pré-treinada na base ImageNet (esse conjunto de dados abrange 1.000 classes de objetos e contém 1.281.167 imagens de treinamento, 50.000 imagens de validação e 100.000 imagens de teste), primeiro domínio e é posteriormente adaptado para a tarefa de classificação de imagens de mamografia humana (segundo domínio). Por fim, a rede transferida é adaptada e treinada para classificar imagens térmicas de mastite bovina (domínio alvo) (Figura 2).

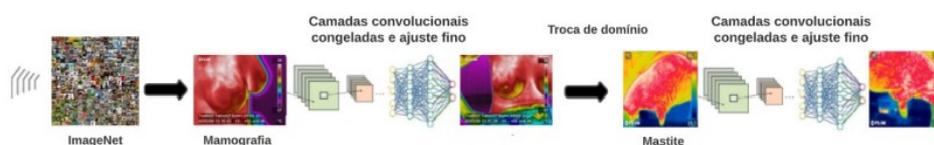


Figura 2: Procedimento geral do aprendizado por transferência sequencial.

2.2. Otimização de hiperparâmetros

Como os algoritmos de aprendizado de máquina possuem parâmetros específicos, também conhecidos como hiperparâmetros deve-se ocorrer a seleção da melhor configuração. Para isso existem métodos teóricos de decisão baseados no conceito de definir um espaço de busca de hiperparâmetros e então detectar a melhor combinação (YANG e SHAMI, 2020)

As abordagens deste estudo para ajustar os hiperparâmetros incluíram pesquisa manual e otimização Bayesiana. Na pesquisa manual, o ajuste dos hiperparâmetros consistiu na seleção para um modelo usando experiência anterior. Em seguida, o modelo foi treinado usando esses parâmetros e avaliado. Este procedimento foi repetido para um conjunto diferente de valores até que a precisão máxima fosse obtida ou o modelo tivesse atingido o erro ideal.

A otimização Bayesiana, ao contrário da abordagem manual faz o uso do conhecimento de iterações anteriores do algoritmo. Cada palpite de hiperparâmetro é independente na grade e na pesquisa aleatória. No entanto, com métodos Bayesianos, cada vez que se seleciona e testa diferentes hiperparâmetros, se aproxima da solução perfeita. Ou seja, a otimização Bayesiana otimiza a tomada de decisão sobre qual configuração de hiperparâmetro é ideal para avaliar um modelo (PELIKAN,

GOLDBERG e CANTU'- PAZ, 1999; SAMEEN, PRADHAN e LEE, 2020).3.3.

Conjunto de dados

O dataset do ImageNet contou com um conjunto de dados de mais de 15 milhões de imagens rotuladas de alta resolução pertencentes a aproximadamente 22.000 categorias. As imagens foram coletadas da web e rotuladas por rotuladores humanos usando a ferramenta de crowd sourcing Mechanical Turk da Amazon (KRIZHEVSKY, SUTSKEVER e HINTON, 2017).

Para o treinamento da rede e análise comparativa dos modelos foi utilizado um banco de dados maior, com problema semelhante (detecção de câncer de mama em mulheres) utilizando imagens térmicas. Essas imagens fazem parte do banco MammoTherm, da Universidade Federal de Pernambuco, tem 640 x 480 pixels, e atualmente estão sendo utilizadas no Hospital das Clínicas da mesma instituição. Este banco de imagens é público e foi disponibilizado para pesquisa de câncer de mama em mulheres.

O conjunto de treinamento, conjunto de teste e conjunto de validação contou com 600 imagens do banco de dados (MammoTherm), em que se considerou as imagens dos grupos "Sem Lesão" e "Lesão Benigna" (Figura 3).

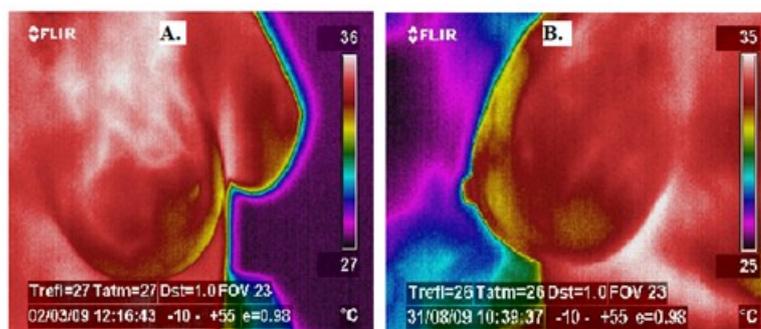


Figura 3: Imagens térmicas de mamografia lesão benigna (A) e sem lesão (B) utilizadas na fase de treinamento da rede. Fonte: Bezerra et al. (2020), Rodrigues et al. (2019), Santana et al. (2018), de Vasconcelos et al. (2018), Araújo et al., (2017)

Posteriormente, o aprendizado foi transferido para o banco de dados menor (imagens de bovinos leiteiros saudáveis e com mastite subclínica). A proporção de imagens utilizadas na fase de treinamento, teste e validação foi de 70, 15 e 15%, respectivamente para o banco de imagens de mamografia e a mesma proporção para o banco de imagens de mastite bovina.

O banco de imagens utilizado na pesquisa é oriundo de estudo preliminar aprovado pelo Comitê de Ética no Uso de Animais da Universidade Federal Rural de Pernambuco, licença n.º 138/2018, aprovado em 19 de dezembro de 2018, formado a partir do registro de imagens térmicas do úbere de animais com diagnóstico prévio de mastite clínica, subclínica e saudável. As imagens térmicas do úbere do gado leiteiro são provenientes de três bases, obtidas em diferentes unidades de produção, no município de Capoeiras (latitude: 8° 36' 33" S, longitude: 36° 37' 30" W e altitude de 733 m), Pesqueira (Latitude: 8° 21' 35" Sul, Longitude: 36° 41' 42" Oeste, 652 m) estado de Pernambuco, Brasil. E cedidas pelo NEAMBE - Núcleo de Estudos em Ambiência Agrícola e Bem-estar Animal da Universidade Federal do Ceará.

O número de amostras foi determinado conforme os critérios de seleção, animais da mesma ordem de parto, estágio de lactação, escore corporal, produção, grau sanguíneo (vacas Girolando). A condição clínica dos animais foi estabelecida pelo California Mastitis Test (CMT), antes da ordenha (após descartar os primeiros jatos de leite), pois, neste momento o teor de gordura do leite é baixo e não interfere nos resultados visuais de pontuação do CMT.

As imagens foram adquiridas por um termovisor FLIR i60, com distância focal de 1 m e emissividade (ϵ) indicada para tecidos biológicos de 0,98 (Silva et al., 2019). As imagens foram registradas no turno da manhã, antes da primeira ordenha dos animais, entre 05:00 e 07:00h, nos quadros anterolateral esquerdo, anterolateral direito e posterior, três imagens por animal (Figura 4).

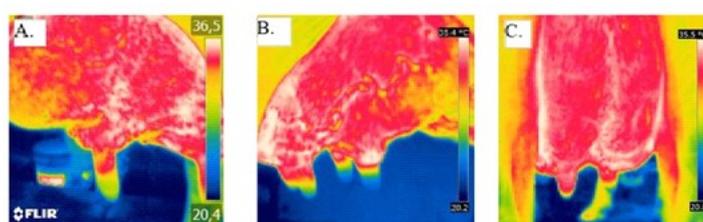


Figura 4: Imagens térmicas dos enquadramentos anterolateral direito (A), esquerdo (B) e posterior (C).

Foram utilizadas 165 imagens de 360 x 360 pixels, referente ao banco de dados de 55 bovinos, classificados em grupos distintos "Saudável" e "Mastite Subclínica", ou seja, positivo e negativo para a fase de treinamento, teste e validação.

2.3. Pré-processamento de imagem

O pré-processamento consistiu em redimensionar as imagens para 224×224 pixels e na utilização da técnica de *data augmentation* que consiste na ampliação do dataset. Para todos os bancos de imagens, foi utilizada a mesma quantidade de imagens para cada classe. Para isso, algumas transformações foram realizadas, sendo feitas apenas uma vez, a fim de criar um excedente de imagens para a rede, que é normalmente utilizado para evitar o *overfitting* e estender o sistema força (WILSON et al., 2018).

Em aprendizado de máquinas, o desempenho dos algoritmos pode ser melhorado conforme o aumento no número de instâncias numa base de dados. No entanto, está sujeito ao número de exemplos disponíveis, pois na maioria das vezes isso não ocorre. O *Data Augmentation (DA)* utiliza técnicas computacionais para aumentar o conjunto de treinamento supervisionado para se obter algoritmos com maior capacidade de predição, e conseqüentemente, melhores resultados (TAYLOR e NITSCHKE, 2017).

Nesta etapa, foi utilizado o método geométrico, que consiste em transformações que alteram a geometria da imagem mapeando os valores de pixel individuais para novos destinos. A forma subjacente da classe representada na imagem é preservada, mas alterada para algumas novas posições e orientações. Foram utilizados 30° de rotação, 20° de ampliação, 10° de recorte, 20° de deslocamento horizontal aleatório e vertical e foram criadas 1.500 novas imagens (Figura 5).

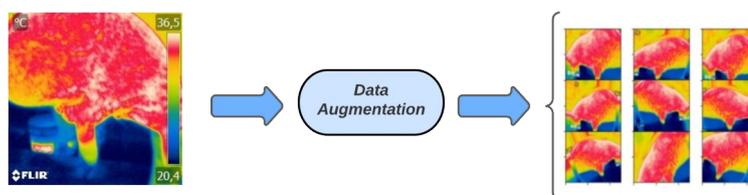


Figura 5: Resultados da imagem após o uso do aumento de dados.

2.4. Plataforma experimental

Os modelos propostos foram treinados e testados usando Google Colaboratory e a linguagem Python. O Colaboratory é um ambiente de notebook Jupyter totalmente baseado em nuvem que não requer instalação.

Keras, uma biblioteca Python de código aberto, foi utilizada para desenvolver e avaliar o modelo de aprendizado profundo, e utilizada para desenvolver o código. Como

esses modelos consomem alta potência e exigem hardware de alto desempenho, rodamos os modelos em GPU. As configurações de hardware e software usadas são apresentadas na Tabela 1.

Tabela 1: Plataforma experimental

Nome	Especificações
GPU	Nvidia V100
RAM	25 GB
IDE	Google Colaboratory
Linguagem	Python

2.5. Ajuste de hiperparâmetros utilizando otimização bayesiana

A otimização bayesiana usa um modelo substituto ajustado às observações do modelo real. Uma observação em nosso caso é um treinamento completo de um modelo CNN usando hiperparâmetros selecionados para essa observação. Para cada iteração, um conjunto de hiperparâmetros foi escolhido e uma observação feita. Utilizou-se a precisão da validação para avaliação da observação. O conjunto de hiperparâmetros foi escolhido com base em uma função de aquisição que equilibra a escolha entre explorar todo o espaço de busca e explorar áreas de bom desempenho do espaço de busca. A Figura 6 mostra o fluxo da otimização.

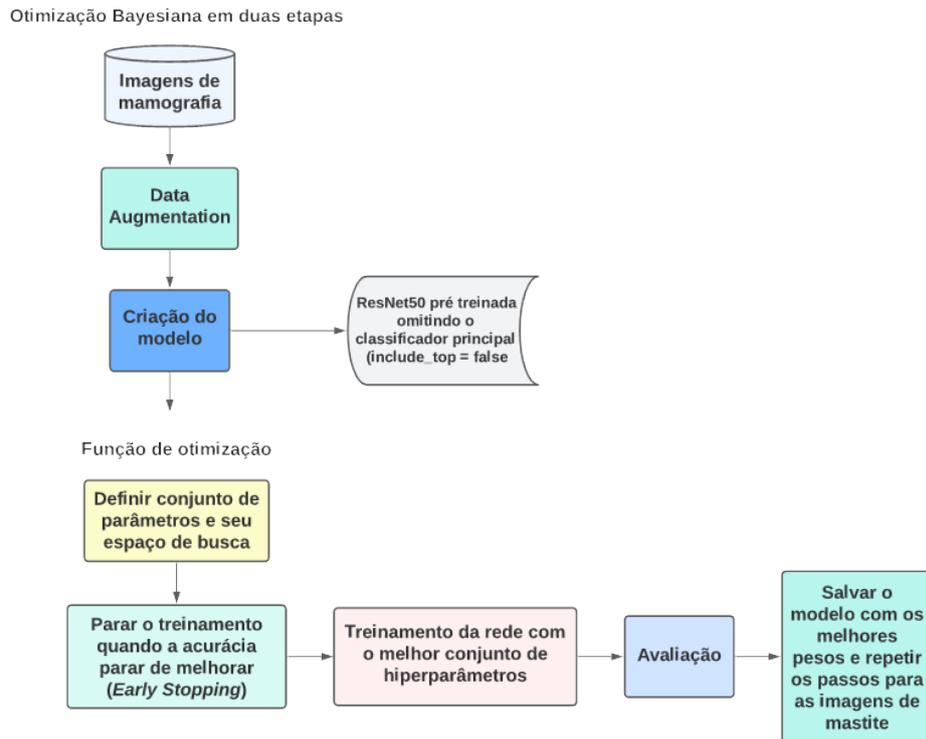


Figura 6: Otimização Bayesiana no sistema desenvolvido.

Os pesos do ImageNet foram utilizados no sistema, pois o torna mais eficiente para a transferência de um conjunto de dados relativamente pequeno e para a aceleração que a técnica apresenta em relação ao treinamento do zero. Embora as imagens utilizadas sejam diferentes das imagens do domínio ImageNet, elas compartilham a semelhança de serem imagens naturais com cores, contrastes e luz. Esses recursos de imagem compartilhados foram importantes para a classificação.

Para o desenvolvimento do sistema, utilizou-se a otimização bayesiana implementada na biblioteca Python GPyOpt, que permite diferentes parâmetros que afetam o desempenho da otimização. Foram utilizados os parâmetros padrão fornecidos pela biblioteca, pois o interesse são os possíveis ganhos de desempenho combinando-o com o aprendizado por transferência sequencial.

A abordagem foi utilizada em duas etapas, com dois conjuntos de hiperparâmetros, um para cada etapa de treinamento. Foram realizadas duas execuções de otimização bayesiana separadas. Primeiro para as imagens de mamografia, otimizando o bloco de classificação e, em seguida, o melhor modelo foi usado para a segunda etapa.

O procedimento de ajuste de hiperparâmetro tem como alvo alguns dos parâmetros mais críticos como: o número de unidades na camada densamente conectada, a taxa de aprendizado e a função de ativação (SUBRAMANIAN et al., 2022), acrescentou-se alguns outros parâmetros importantes para a regularização da rede como o parâmetro λ e a taxa de *dropout* na camada densamente conectada, utilizando o otimizador RMSprop (Tabela 2).

Tabela 2: Hiperparâmetros e espaço de busca

Parâmetro	Espaço de busca	Descrição
Número de neurônios na camada densa personalizada	64, 128, 256, 512	Para introduzir não linearidade na saída dos neurônios
Taxa de aprendizagem	0,01; 0,001; 0,0001	Para determinar o tamanho do passo em cada iteração enquanto minimiza a função de perda
λ	0,1; 0,01; 0,001	Regularização
Função de ativação	Relu, Elu, and Tanh	Para introduzir não linearidade na saída dos neurônios
Dropout	0,3; 0,5; 0,7	Garantir que o modelo seja robusto para a perda de qualquer evidência individual

2.6. Métricas de avaliação

Seguindo as mesmas métricas de desempenho nas referências relacionadas por Abiwinanda et al. (2019); Macedo et al. (2021); Mehrotra et al. (2020) o desempenho da rede foi avaliado com base nas métricas: acurácia (Eq. 1), F1 score (Eq. 2) e visualização pela matriz de confusão.

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$F1 = \frac{2 \times \text{precisão} \times \text{recall}}{\text{precisão} + \text{recall}} \quad (2)$$

em que: TP - Verdadeiro Positivo; TN - Verdadeiro Negativo; FP - Falso Positivo; FN - Falso Negativo.

3. RESULTADOS E DISCUSSÃO

Nesta seção é apresentado o desempenho da rede utilizando otimização bayesiana na tarefa de classificação das imagens de mastite. As curvas de acurácia e perda para os resultados de classificação do treinamento e teste das imagens obtidas nas redes de transferência de aprendizado foram apresentadas na Figura 7.

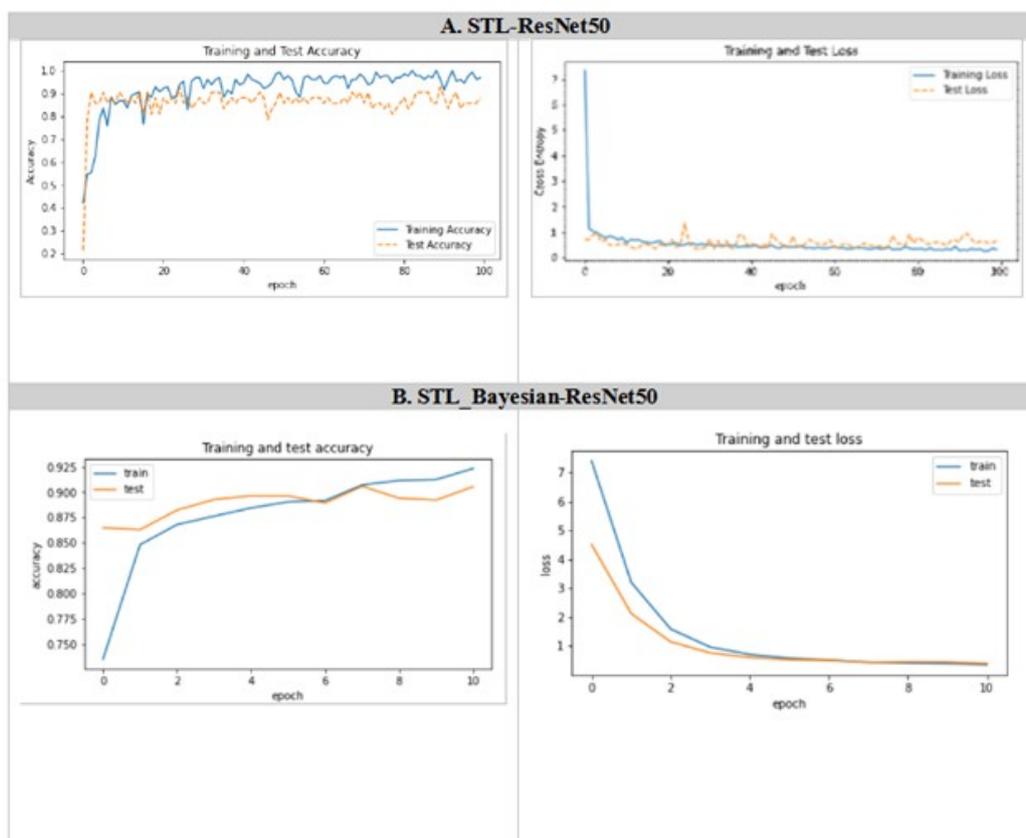


Figura 7: Curvas de acurácia e perda no treinamento e teste para os modelos ajustados.

O melhor desempenho da rede foi o modelo otimizado que alcançou 92,1% de acurácia comparativamente ao modelo utilizando pesquisa manual (88,03%). A acurácia neste último foi alcançada em 100 épocas, o mesmo não ocorreu no modelo otimizado que obteve o melhor desempenho utilizando 11 épocas.

A F1 score apresentou valor de 90 e 85,5%, respectivamente. Ela considera de forma abrangente a precisão e o recall, o seu resultado juntamente com o da acurácia pode refletir melhor a superioridade do desempenho do modelo, pois a diminuição de falsos positivos melhora a produtividade do leite e promove maior confiabilidade, diminui custos para tratamento da enfermidade e garante, maior valor do leite pago ao produtor, devido a melhoria na qualidade. De forma geral, uma boa acurácia auxilia o

produtor a agir de forma precisa quanto a incidência da mastite subclínica, gerando menor descarte de animais com potencial de produção de leite, melhor sanidade e bem-estar do rebanho.

3.1. Desempenho da classificação com otimização bayesiana

A partir da obtenção dos gráficos de otimização (Figura 8), pode-se visualizar o espaço exploratório do modelo bayesiano, que se inicia testando uma ampla gama de hiperparâmetros distantes em busca de um melhor desempenho, com o alcance de acurácia mais satisfatória.

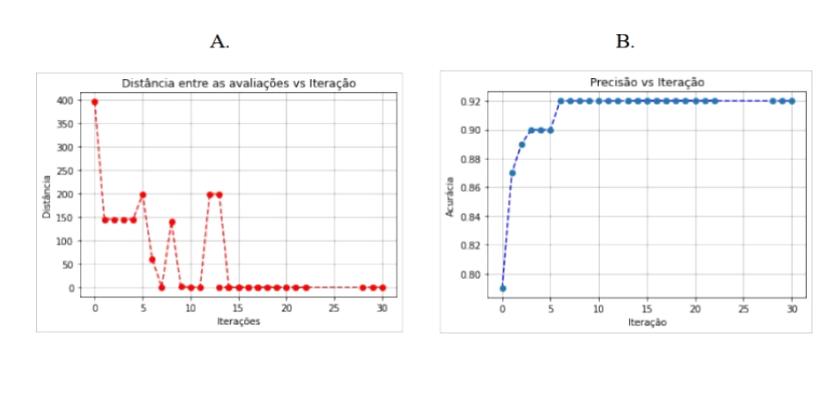


Figura 8: Gráficos da otimização Bayesiana. (A) Distância entre as avaliações consecutivas, (B) Precisão vs. iteração

A Figura 8A mostra como é executada a convergência para o valor mínimo de uma função objetivo ao longo do número de tentativas diferentes de combinações de hiperparâmetros. O eixo x mostra o número de chamadas para a função objetivo e o eixo y mostra o valor mínimo da função objetivo após várias chamadas. Verifica-se que ocorreu menor distância nas avaliações entre a décima terceira iteração em diante, pois as avaliações foram muito próximas, evidenciando que a rede achou os valores ótimos de hiperparâmetros, finalizando o treinamento. O mesmo não ocorreu entre algumas iterações como a sexta e a décima, pois apresentaram maior distância entre si (Figura 8A).

A distância apresentada pelo gráfico explica quais regiões apresentaram espaço de pesquisa avaliados com mais precisão, o que significa que elas deram melhores resultados e provavelmente estão próximas do ideal. Neste caso, através dos resultados apresentados após a décima tentativa, o algoritmo alcançou os melhores valores de precisão (Figura 8A).

Os valores de acurácia conforme as 34 tentativas executadas pelo algoritmo, entre a segunda e vigésima segunda iterações os valores permaneceram constantes e acima de 90%. Após isso o algoritmo alcançou os melhores valores (92,1%), não havendo mudanças nas próximas execuções (Figura 8B).

Dessa forma o algoritmo convergiu rapidamente para um conjunto de hiperparâmetros gerando alta precisão, havendo apenas uma ligeira melhoria incremental. Esses resultados mostram o nível de eficiência com que o modelo bayesiano pode convergir para identificar o melhor conjunto de hiperparâmetros possível, para o classificador principal construído sobre a CNN ResNet50 pré-treinada.

3.2. Performance do modelo na classificação e conjunto de hiperparâmetros

O desempenho dos modelos na tarefa de classificação de imagens térmicas do úbere de vacas de leite (animais saudáveis e animais com mastite subclínica) foi comparado usando a visualização da matriz de confusão (Figura 9).

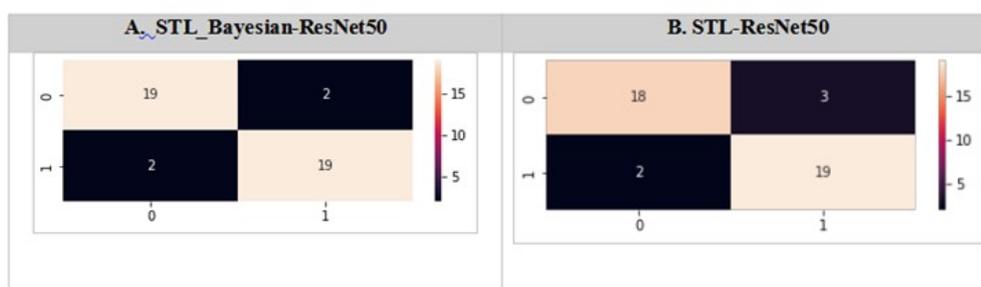


Figura 9: Matrizes de confusão dos quatro modelos empregados na classificação das imagens (0 – animal saudável; 1 – animal com mastite subclínica).

Com base nos resultados da matriz de confusão da classificação binária e os resultados calculados através dela: taxa positiva verdadeira (proporção de resultados corretamente classificados como positivo no resultado do modelo), taxa negativa verdadeira (proporção de resultados classificados como negativos fora de todas as instâncias que não eram originalmente negativo), taxa de falsos positivos e taxa de falsos negativos.

Na Figura 9A, nota-se que a proporção de identificação (taxa positiva verdadeira e taxa negativa verdadeira) do STL_Bayesian - ResNet50 foi maior. A proporção de acertos na identificação atingiu 92% para animais saudáveis e animais com mastite subclínica. Isso ocorreu principalmente devido ao uso de ajuste fino com otimização de hiperparâmetros nas imagens de treinamento que primeiro adaptou a rede às novas

classes utilizadas e, posteriormente, a rede foi adaptada às imagens de mastite, obtendo bom desempenho.

Verificou-se maior proporção de erros (taxa de falsos positivos e taxa de falsos negativos) maior no modelo STL - ResNet50 (14 e 8%) (Figura 9B), isso ocorreu principalmente por conta do ajuste, que foi manual, portanto, os valores escolhidos para hiperparâmetros influenciou na qualidade dos modelos, assim como na sua capacidade de aprendizado e de generalização.

O melhor conjunto de hiperparâmetros e melhor conjunto de pesos para o treinamento da rede conferido a partir do modelo substituto bayesiano segue na tabela 3.

Tabela 3: Melhor conjunto de hiperparâmetros inferidos pelo modelo substituto Bayesiano

Parâmetro	Espaço de busca
Número de neurônios na camada densa personalizada	64
Taxa de aprendizagem	0.0001
12	0.001
Função de ativação	Elu
Dropout	0,5

O número de neurônios na camada densa personalizada foi 64, a taxa de aprendizagem para treinamento no conjunto de imagens foi de 0,0001. A taxa utilizada na regularização 12 foi de 0,001 com função de ativação elu e taxa de *dropout* de 0,5.

4. CONCLUSÃO

As metodologias preditivas propostas com base na transferência de conhecimento para detecção automática de mastite subclínica bovina classificaram corretamente as imagens, porém, o modelo de aprendizagem por transferência sequencial (STL_Bayesian - ResNet50) apresentou melhor desempenho (92,1%) em relação ao modelo STL - ResNet50 (86,1%) contribuindo significativamente para a detecção automática de animais saudáveis e animais com mastite subclínica a partir de imagens térmicas do úbere de vacas leiteiras.

REFERÊNCIAS

ABIWINANDA, N.; HANIF, M.; HESAPUTRA, S. T.; HANDAYANI, A.; MENGKO, T. R. Brain Tumor Classification Using Convolutional Neural Network. World Congress on Medical Physics and Biomedical Engineering 2018, Springer, Singapore, p. 183-189, 2019

BOUMARAF, S.; XIABI, L.; ZHONGSHU, Z.; XIAOHONG, M.; FERKOUS, C. A. new transfer learning based approach to magnification dependent and independent classification of breast cancer in histopathological images. Biomedical Signal Processing and Control, v. 63, p.102192, 2021.

BRESSEM, K.K.; ADAMS, L.C.; ERXLEBEN, C.; HAMM, B.; NEIHUES, S.M.; VAHLDIEK, J.L. Comparing different deep learning architectures for classification of chest radiographs. Scientific. Report, 10, 13590, 2020

DA SILVA, R. A. B.; PANDORFI, H.; DE ALMEIDA, G. L. P.; DE ASSUNÇÃO MONTENEGRO, A. A.; DA SILVA, M. V. Spatial dependence of udder surface temperature variation in dairy cows with healthy status and mastitis. Revista Brasileira de Saúde e Produção Animal, 20, 2019

DAS, R.; SAILO, L.; VERMA, N.; BHARTI, P.; SAIKIA, J.; IMTIWATI; KUMAR, R. Impact of heat stress on health and performance of dairy animals: A review. Veterinary World, 9(3), 260–268, 2016.

KERMANY, D. S.; GOLDBAUM, M.; CAI, W.; VALENTIM, C. C.; LIANG, H.; BAXTER, S. L.; MCKEOWN, A.; YANG, G.; WU, X.; YAN, F.; DONG, J.; PRASADHA, M. K.; PEI, J.; TING, M. Y. L.; ZHU, J.; LI, C.; HEWETT, S.; DONG, J.; ZIYARr, I.; ZHANG, K. Identifying medical diagnoses and treatable diseases by image-based deep learning. Cell, v. 172, p. 1122–1131, 2018.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. Communications of the ACM, n. 60, v.6, p.84–90, 2017.

LIMA, R.S.; DANIELSKI, G.C.; PIRES, A.C.S. Mastitis detection and prediction of milk composition using gas sensor and electrical conductivity. Food Bioprocess Technology, 2018.

MACÊDO, D.; DREYER, P.; LUDEMIR, T.; ZANCHETTIN, C. Training Aware Sigmoidal Optimizer. arXiv preprint arXiv: 2102.08716v1, 2021.

MEHROTRA, R.; ANSARI, M. A.; AGRAWAL, R.; ANAND, R. S. A Transfer Learning approach for AI-based classification of brain tumors. Machine Learning with Applications, n. 2, p. 100003, 2020.

NEGASSI, M.; SUAREZ-IBARROLA, R.; HEIN, S.; MIEMIK, A.; REITERER, A. Application of artificial neural networks for automated analysis of cystoscopic images: A review of the current status and future prospects. World Journal of Urology, n. 38, p.1–10, 2020.

- PELIKAN M.; GOLDBERG, D.E., CANTÚ-PAZ, E. BOA: The Bayesian optimization algorithm. In: Proceedings of the Genetic and Evolutionary Computation Conference, Citeseer, p. 525–532, 1999.
- PORTER, I. R.; WIELAND, M.; BASRAN, P. S. Feasibility of the use of deep learning classification of teat-end condition in Holstein cattle. *Journal of Dairy Science*, n.104, v.4, p. 4529–4536, 2021.
- POLAT, B.; COLAK, A.; CENGIZ, M.; YANMAZ, L.E.; ORAL, H.; BASTAN, A.; KAYA, S.; HAYIRLI, A. Sensitivity and specificity of infrared thermography in detection of subclinical mastitis in dairy cows. *Journal Dairy Science*. Source: *Journal of dairy science*. v.93, n.8 p. 3525-3532, 2010.
- POSSENTI, C.G.R.; HORN, R.C.; MORI, N.C.; RIBAS JÚNIOR, V., GOLLE, D.P.; KOEFENDER, J. Avaliação de Estresse Oxidativo no Plasma de Bovinos Leiteiros com mastite. *Ciência animal brasileira*, v.19, p. 1-9, 2018.
- SAMEEN, M.I.; PRADHAN, B.; LEE, S. Application of convolutional neural networks featuring Bayesian optimization for landslide susceptibility assessment. *Catena*, n.186, p.104249, 2020.
- SILVA, R. A. B. da, LIMA, J. P. S. do M., PANDORFI, H.; ALMEIDA, G. L. P. de. Thermal Image Thresholding for Automatic Detection of Bovine Mastitis. *International Journal of Computer Applications*, n.183, v. 14, p. 29–33, 2021.
- SIEMON, M. S. N.; SHIHAVUDDIN, A. S. M.; RAVN-HAREN, G. Sequential transfer learning based on hierarchical clustering for improved performance in deep learning based food segmentation. *Scientific Reports*, n.11, v.1, 813, 2021.
- SUBRAMANIAM, M.; NARASIMA PRASAD, L.V.; JANAKIRAMAIAH, B.; MOHAN BABU, A.; SATHISHKUMAR, V. E. Hyperparameter Optimization for Transfer Learning of VGG16 for Disease Identification in Corn Leaves Using Bayesian Optimization. *Big Data*, n.10, v.3, p. 215–229, 2022.
- SWATI, Z. N. K.; ZHAO, Q.; KABIR, M.; ALI, F.; ALI, Z.; AHMED, S.; LU, J. Brain tumor classification for MR images using transfer learning and fine-tuning. *Computerized Medical Imaging and Graphics*, n. 75, p.34–46, 2019.
- TAYLOR, L.; NITSCHKE, G. Improving Deep Learning using Generic Data Augmentation. *arXiv preprint arXiv:1708.06020*, 2017.
- VIGUIER, C.; ARORA, S.; GILMARTIN, N.; WELBECK, K.; O’KENN Mastitis detection: current trends and future perspectives. *Trends Biotechnol.* v. 27, p. 486–493, 2009.
- WATZ, S. PETZL, W.; ZERBE, H.; RIEGER, A.; GLAS, A. SCHROTER, W.; LANDGRAF, T.; METZNER, M. Technical note: Automatic evaluation of infrared thermal images by computerized active shape modeling of bovine udders challenged with *Escherichia coli*. *Journal of Dairy Science*, n.102, v.5, p.4541–4545, 2019

WILSON, A.C.; ROELOFS, R.; STERN, M.; SREBRO, N.; RECHT, B. The marginal value of adaptive gradient methods in machine learning. In Advances in Neural Information Processing Systems, In Neural Information Processing Systems, p. 4148-4158, 2017.

YANG, L.; SHAMI, A. On Hyperparameter Optimization of Machine Learning Algorithms: Theory and Practice. arXiv preprint arXiv:2007.15745, 2022.

YOSINSKI, J.; CLUNE, J.; BENGIO, Y.; LIPSON, H. How transferable are features in deep neural networks? In: Advances in neural information processing systems. 3320–3328, 2014.

ZANINELLI, M.; REDAELLI, V.; LUZI, F.; BRONZO, V.; MITCHELL, M.; DELL'ORTO, V.; BONTEMPO, V.; CATTANEO, D.; SAVOINI, G. First Evaluation of Infrared Thermography as a Tool for the Monitoring of Udder Health Status in Farms of Dairy Cows. Sensors, n.18, v.3, 862, 2018.

ZHANG, Z.; LI, X. P.; YANG, F.; LUO, J. Y.; WANG, X. R.; LIU, L. H.; LI, H. S. Influences of season, parity, lactation, udder area, milk yield, and clinical symptomson intramammary infection in dairy cows. Journal of Dairy Science, n.99, v.8, p.6484–6493, 2016.

CAPÍTULO V

Desempenho da classificação de imagens de mastite bovina usando transferência de aprendizado sequencial com mecanismo de atenção e otimização bayesiana

DESEMPENHO DA CLASSIFICAÇÃO DE IMAGENS DE MASTITE BOVINA USANDO TRANSFERÊNCIA DE APRENDIZADO SEQUENCIAL COM MECANISMO DE ATENÇÃO E OTIMIZAÇÃO BAYESIANA

RESUMO

A bovinocultura de leite é uma atividade em franco crescimento no Brasil e no mundo, no entanto, o setor enfrenta um grande entrave, a mastite bovina, que ocasiona inúmeras perdas na produção de leite e na longevidade do rebanho. Alguns métodos de diagnóstico de mastite vêm sendo utilizados ao longo dos anos, porém, além da subjetividade, apresentam custo elevado, sendo de grande importância o desenvolvimento de ferramentas que ofereçam diagnóstico precoce, seguro, não invasivo e de baixo custo, como o diagnóstico por imagens térmicas. Neste contexto, objetivou-se com este estudo verificar o desempenho de um sistema de classificação utilizando o mecanismo de atenção Convolutional Block Attention Mechanism (CBAM) ao ajuste fino do modelo de transferência de aprendizado sequencial. O banco de imagens utilizado na pesquisa foi constituído por 165 imagens de 360 x 360 pixels, referente ao banco de dados de 55 bovinos com diagnóstico prévio de mastite subclínica e saudável, provenientes de três unidades de produção, localizadas nos municípios de Capoeiras e Pesqueira, estado de Pernambuco e município de Russas, estado do Ceará, Brasil. As imagens utilizadas na transferência sequencial de aprendizado foram *MammoTherm* (detecção de câncer de mama em mulheres). Para isso foi utilizado o modelo ResNet50 pré-treinado como base para construir dois modelos de aprendizado de transferência sequencial ou classificadores de imagens de mastite com e sem adicionar CBAM incorporando-o à saída do mapa de recursos. Dois novos modelos incluíram apenas dois nós de saída para representar as classes “saudável” e “mastite subclínica”. O desempenho geral da rede de atenção alcançou 97,28% de acurácia no conjunto de dados de teste comparativamente ao modelo onde não se utilizou o CBAM (92,1%). A acurácia neste último foi alcançada em 11 épocas, o mesmo não ocorreu no modelo proposto que obteve o melhor desempenho utilizando 52 épocas. As metodologias preditivas propostas com base na transferência de conhecimento para detecção automática de mastite subclínica bovina classificaram corretamente as imagens, porém, o modelo de aprendizagem por transferência sequencial (STL_Bayesian_CBAM-ResNet50) apresentou melhor desempenho.

Palavras – chave: imagens térmicas, mastite bovina, mecanismo de atenção, redes convolutivas

PERFORMANCE OF BOVINE MASTITIS IMAGE CLASSIFICATION USING SEQUENTIAL LEARNING TRANSFER WITH ATTENTION MECHANISM AND BAYESIAN OPTIMIZATION

ABSTRACT

Dairy cattle breeding is a fast growing activity in Brazil and in the world; however, the sector faces a great obstacle, bovine mastitis, which causes several losses in milk production and herd longevity. Some methods of mastitis diagnosis have been used over the years, however, in addition to subjectivity, they are expensive, and it is of great importance to develop tools that offer early, safe, non-invasive and low-cost diagnosis, such as diagnosis by thermal imaging. In this context, this study aimed to verify the performance of a classification system using the Convolutional Block Attention Mechanism (CBAM) to fine-tune the sequential learning transfer model. The image bank used in the research consisted of 165 images of 360 x 360 pixels, referring to the database of 55 cattle previously diagnosed with subclinical and healthy mastitis, from three production units, located in the municipalities of Capoeiras and Pesqueira, state of Pernambuco and municipality of Russas, state of Ceará, Brazil. The images used in the sequential learning transfer were MammoTherm (breast cancer detection in women). For this, the pre-trained ResNet50 model was used as a basis to build two sequential transfer learning models or classifiers for mastitis images with and without adding CBAM, incorporating it into the feature map output. Two new models included only two output nodes to represent the classes "healthy" and "subclinical mastitis." The overall performance of the care network achieved 97.28% accuracy on the test dataset, compared to the model where CBAM was not used (92.1%). The accuracy in the latter was achieved in 11 epochs, the same did not occur in the proposed model that obtained the best performance using 52 epochs. The proposed predictive methodologies based on knowledge transfer for automatic detection of bovine subclinical mastitis correctly classified the images, however, the sequential transfer learning model (STL_Bayesian_CBAM-ResNet50) showed better performance.

Keywords: thermal images, bovine mastitis, attention mechanism, convolutional networks

1. INTRODUÇÃO

A produção leiteira no Brasil tem crescido ao longo dos anos e passado por intensas transformações tecnológicas que melhoraram o desempenho da cadeia produtiva. No entanto um fator persistente, e que é alvo de pesquisas na área: a mastite bovina. Ela é uma doença cujo diagnóstico precoce ocasiona redução das perdas econômicas, devido a possibilidade de tratamento na fase inicial da doença, sendo muito importante o desenvolvimento de ferramentas tecnológicas para a sua detecção (ZANINELLI et al., 2019; ZHANG et al., 2020; SILVA et al., 2021).

A mastite subclínica é que mais causa perdas pois o animal não sente dor ou qualquer outro sintoma sendo necessário o uso de métodos diagnósticos como o *California Mastitis Test* (CMT) realizado na sala de ordenha e fornece um procedimento barato, rápido e fácil (RUEGG, 2017), no entanto, é subjetivo, pois depende da interpretação humana, oferecendo menos precisão e confiabilidade (LIMA et al., 2018).

Modelos de Deep Learning ou aprendizado profundo de máquina, que incluem técnicas como as redes neurais convolucionais ou CNN, se tornaram mais populares por causa das suas características relativamente simples, mas robustas (KERMANY et al., 2018) e têm sido utilizadas para desenvolver sistemas voltados para análise de imagens (NEGASSI et al., 2020). No entanto, uma das principais desvantagens da rede neural convolucional é que ela requer grandes quantidades de dados para o treinamento, o que às vezes é difícil de obter no campo.

Assim, a aprendizagem por transferência tem sido amplamente utilizada para contornar essa questão de escassez de imagens (BOUMARAF et al., 2021; DAS et al., 2016; PORTER, WIELAND e BASRAN, 2021; SWATI et al., 2019).

Apesar das vantagens da CNN, uma das maiores dificuldades ou desafios do uso de CNNs é o ajuste de hiperparâmetros. Nesse caso utiliza-se métodos teóricos de decisão baseados no conceito de definir um espaço de busca de hiperparâmetros e então detectar o melhor modelo (YANG e SHAMI, 2022).

Por outro lado, uma nova tecnologia, a saber, os mecanismos de atenção, também se tornaram um método popular usado na análise de imagens e demonstra sua capacidade e vantagens únicas em aumentar a força representacional, enfatizando detalhes cruciais e minimizando os supérfluos (BA, MNIH & KAVUKCUOGLU, 2021).

Dado um mapa de recursos intermediário, o Convolutional Block Attention Mechanism (CBAM, que é um mecanismo de atenção, infere sequencialmente ao longo de duas dimensões separadas, canal e espacial, então os mapas de atenção são multiplicados para o mapa de recursos de entrada para refinamento de recursos adaptativo (WOO et al.,2018). Apesar das suas vantagens, o CBAM tem sido pouco utilizado em modelos de aprendizado por transferência, obtendo resultados positivos na classificação de imagens (ALIREZAZADEH, SCHIRRMANN e STOLZENBURG, 2022; ZHAO et al., 2022).

Neste contexto, este estudo foi conduzido com o objetivo de verificar o desempenho de um sistema de classificação utilizando o mecanismo de atenção CBAM ao ajuste fino do modelo de transferência de aprendizado sequencial.

2. MATERIAL E MÉTODOS

2.1. Conjunto de dados

O dataset ImageNet é um conjunto de dados de mais de 15 milhões de imagens rotuladas de alta resolução pertencentes a aproximadamente 22.000 categorias. As imagens foram coletadas da web e rotuladas por rotuladores humanos usando a ferramenta de crowd sourcing Mechanical Turk da Amazon (KRIZHEVSKY, SUTSKEVER e HINTON, 2017).

Para o treinamento da rede e análise comparativa dos modelos foi utilizado um banco de dados maior, com problema semelhante (detecção de câncer de mama em mulheres) utilizando imagens térmicas. Essas imagens fazem parte do banco MammoTherm, da Universidade Federal de Pernambuco, tem 640 x 480 pixels, e atualmente estão sendo utilizadas no Hospital das Clínicas da mesma instituição.

O conjunto de treinamento, conjunto de teste e conjunto de validação contou com 600 imagens do banco de dados (MammoTherm), em que se considerou as imagens dos grupos "Sem Lesão" e "Lesão Benigna" (Figura 1).

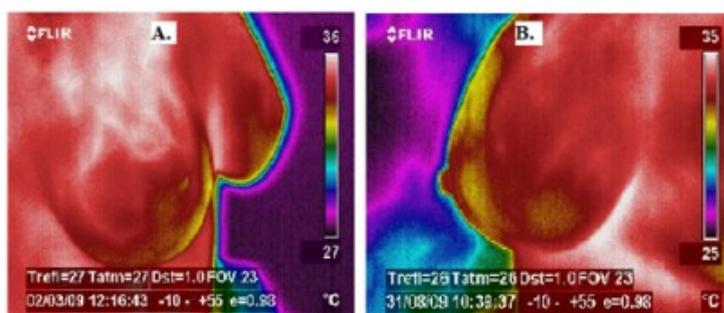


Figura 1: Imagens térmicas de mamografia lesão benigna (A) e sem lesão (B) utilizadas na fase de treinamento da rede. Fonte: Bezerra et al. (2020), Rodrigues et al. (2019), Santana et al. (2018), de Vasconcelos et al. (2018), Araújo et al., (2017)

Posteriormente, o aprendizado foi transferido para o banco de dados menor (imagens de bovinos leiteiros saudáveis e com mastite subclínica). A proporção de imagens utilizadas na fase de treinamento, teste e validação foi de 70, 15 e 15%. Respectivamente para o banco de imagens de mamografia e a mesma proporção para o banco de imagens de mastite bovina.

O banco de imagens utilizado na pesquisa é oriundo de estudo preliminar aprovado pelo Comitê de Ética no Uso de Animais da Universidade Federal Rural de Pernambuco, licença nº 138/2018, aprovado em 19 de dezembro de 2018, formado a partir do registro de imagens térmicas do úbere de animais com diagnóstico prévio de mastite clínica, subclínica e saudável. As imagens térmicas do úbere do gado leiteiro são provenientes de três bases, obtidas em diferentes unidades de produção, no município de Capoeiras (latitude: 8° 36' 33" S, longitude: 36° 37' 30" W e altitude de 733 m), Pesqueira (Latitude: 8° 21' 35" Sul, Longitude: 36° 41' 42" Oeste, 652 m) estado de Pernambuco, Brasil. E cedidas pelo NEAMBE - Núcleo de Estudos em Ambiente Agrícola e Bem-estar Animal da Universidade Federal do Ceará.

O número de amostras foi determinado de acordo com os critérios de seleção, animais da mesma ordem de parto, estágio de lactação, escore corporal, produção, grau sanguíneo (vacas Girolando). A condição clínica dos animais foi estabelecida pelo California Mastitis Test (CMT), antes da ordenha (após descartar os primeiros jatos de leite), pois, neste momento o teor de gordura do leite é baixo e não interfere nos resultados visuais de pontuação do CMT.

As imagens foram adquiridas por um termovisor FLIR i60, com distância focal de 1 m e emissividade (ϵ) indicada para tecidos biológicos de 0,98 (da SILVA et al., 2019). As imagens foram registradas no turno da manhã, antes da primeira ordenha dos animais, entre 05:00 e 07:00h, nos quadros anterolateral esquerdo, anterolateral direito e posterior, três imagens por animal (Figura 2).

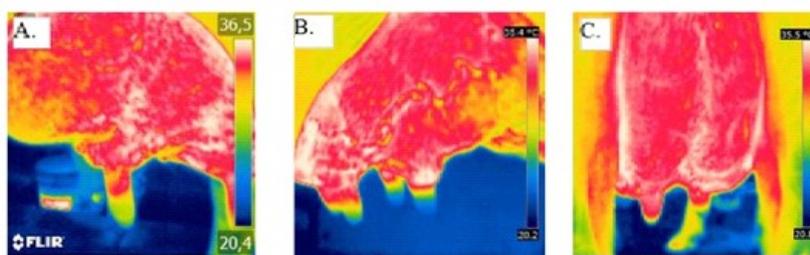


Figura 2: Imagens térmicas dos enquadramentos anterolateral direito (A), esquerdo (B) e posterior (C).

Foram utilizadas 165 imagens de 360 x 360 pixels, referente ao banco de dados de 55 bovinos, classificados em grupos distintos "Saudável" e "Mastite Subclínica", ou seja, positivo e negativo para a fase de treinamento, teste e validação.

2.2. Pré-processamento de imagem

O pré-processamento consistiu em redimensionar as imagens para 224×224 pixels e na utilização da técnica de *data augmentation* que consiste na ampliação do *dataset*. Para todos os bancos de imagens, foi utilizada a mesma quantidade de imagens para cada classe (animal saudável e animal com mastite subclínica). Para isso, algumas transformações foram realizadas, sendo feitas apenas uma vez, a fim de criar um excedente de imagens para a rede, que é normalmente utilizado para evitar o *overfitting* e estender o sistema força (WILSON et al., 2018).

Em aprendizado de máquinas, o desempenho dos algoritmos pode ser melhorado segundo o aumento no número de instâncias numa base de dados. No entanto, está sujeito ao número de exemplos disponíveis, pois na maioria das vezes isso não ocorre. Dessa forma, o *Data Augmentation* (DA) utilizar técnicas computacionais para aumentar o conjunto de treinamento supervisionado para se obter algoritmos com maior capacidade de predição, e consequentemente, melhores resultados (TAYLOR e NITSCHKE, 2017).

Nesta etapa, foi utilizado o método geométrico, que consiste em transformações que alteram a geometria da imagem mapeando os valores de pixel individuais para novos destinos. A forma subjacente da classe representada na imagem é preservada, mas alterada para alguma nova posição e orientação. Foram utilizados 30° de rotação, 20° de ampliação, 10° de recorte, 20° de deslocamento horizontal aleatório e vertical e foram criadas 1.500 novas imagens (Figura 3).

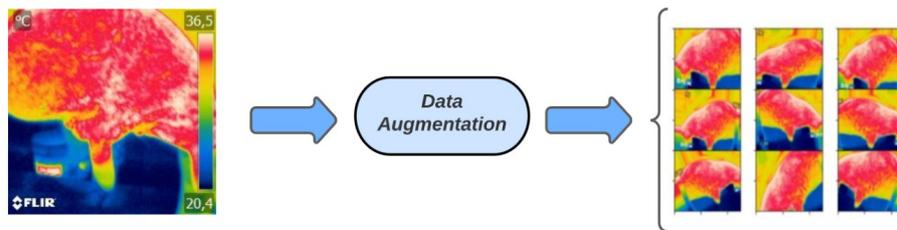


Figura 3: Resultados da imagem após o uso do aumento de dados.

2.3. Abordagem por transferência sequencial

A abordagem por transferência de aprendizado em duas etapas, implica na extração do conhecimento entre conjuntos de imagens em uma sequência de etapas e possibilita o ganho de desempenho (SIEMON, SHIHAVUDDIN e RAVN - HAREN, 2021).

No problema de classificação de mastite, a rede é pré-treinada na base ImageNet (conjunto de dados abrange 1.000 classes de objetos e contém 1.281.167 imagens de treinamento, 50.000 imagens de validação e 100.000 imagens de teste), primeiro domínio, foi adaptado para a tarefa de classificação de imagens de mamografia humana (segundo domínio). Por fim, a rede transferida foi adaptada e treinada para classificar imagens térmicas de mastite bovina (domínio alvo) (Figura 4).

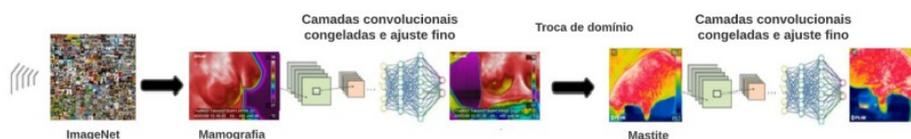


Figura 4: Procedimento geral do aprendizado por transferência sequencial utilizado neste estudo.

2.4. Módulo de atenção de bloqueio convolucional (CBAM)

O Convolutional Block Attention Module (CBAM) é um módulo de atenção eficaz para redes neurais convolucionais *feedforward* (WOO et al. (2018)). Ele possui a atenção espacial que enfatiza as localizações de perceptos com alta saliência para selecionar informações relevantes, e a atenção por canal que visa destacar os canais mais importantes (Figura 5). Ambos foram utilizados neste estudo.

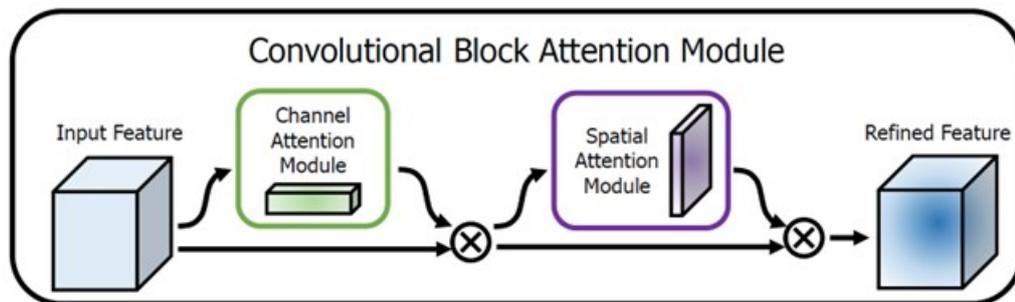


Figura 5: Diagrama de um CBAM.
 Fonte: Woo et al. (2018)

O CBAM pode ser usado em modelos desenvolvidos a partir da ResNet50. Esses dois módulos foram aplicados em uma ordem específica para examinar o mapa de recursos extraído pelas camadas inferiores. A arquitetura de ambos os módulos é mostrada na Figura 6.

Mecanismo de atenção CBAM

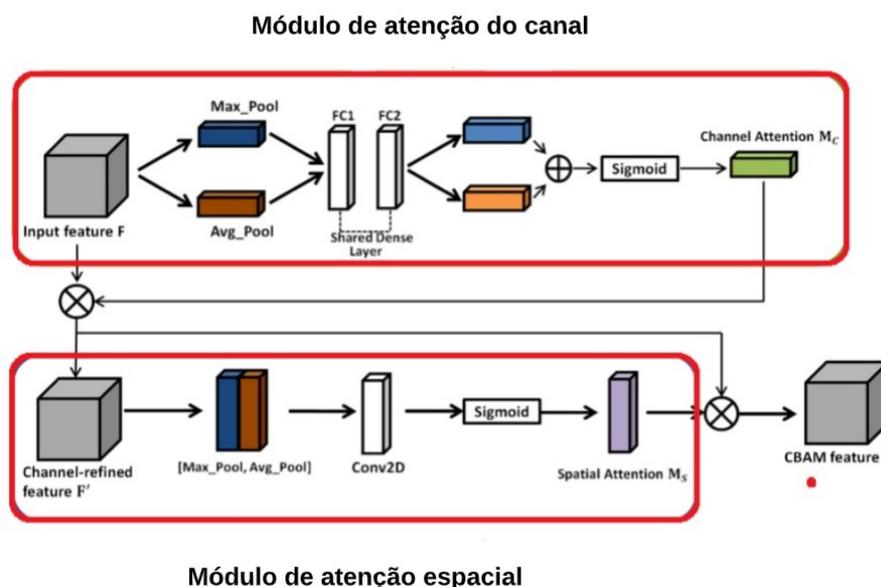


Figura 6: Diagrama de cada submódulo de atenção. O lado superior é o módulo de atenção do canal e o lado inferior é o módulo de atenção espacial.
 Fonte: Woo et al. (2018)

O mapa de recursos de entrada para o CBAM foi transferido para o mapa de recursos $F \in \mathbb{R}^{C \times H \times W}$. Onde H e C denotaram a altura e a largura do mapa de recursos e C denota o número de canais. A seguir, a dimensão espacial do mapa de entrada foi removida pelas camadas de pooling máximo e médio. A camada global average pooling

obteve as informações espaciais agregadas, enquanto a camada global max pooling capturou as características distintas do objeto para inferir uma atenção mais refinada em relação ao canal.

Usando duas camadas densas compartilhadas, o CBAM calculou um mapa de atenção do canal $M_c \in \mathbb{R}^{C \times 1 \times 1}$ do mapa reduzido (módulo de atenção do canal, lado superior da Figura 5). Então, um mapa de características refinado do canal foi obtido multiplicando o mapa de atenção do canal pelo mapa de características de entrada F , de modo que cada elemento em F é multiplicado pelo peso do canal correspondente no mapa de atenção do canal. Comparado ao módulo de atenção do canal, o módulo de atenção espacial deu mais ênfase às partes do mapa de recursos, que é complementar à atenção do canal. Para calcular o módulo de atenção espacial $M_s \in \mathbb{R}^{1 \times H \times W}$ (lado inferior da Figura 5).

2.5. Otimização de hiperparâmetros

Os algoritmos de aprendizado de máquina possuem parâmetros específicos, também conhecidos como hiperparâmetros. Para ajustá-los foi selecionada a melhor configuração através de método de otimização bayesiana com o intuito de detectar a melhor combinação (YANG e SHAMI, 2020).

Os hiperparâmetros escolhidos foram número de unidades ocultas, dropout, função de ativação, inicialização de peso, taxa de aprendizado e regularização l2, com objetivo de encontrar um conjunto ótimo de hiperparâmetros que minimize uma função de perda predefinida e produza melhores resultados.

A otimização Bayesiana, ao contrário das abordagens de grade e busca aleatória, faz o uso do conhecimento de iterações anteriores do algoritmo. Ou seja, a otimização Bayesiana otimiza a tomada de decisão sobre qual configuração de hiperparâmetro é ideal para avaliar um modelo (PELIKAN, GOLDBERG e CANTU'-PAZ, 1999; SAMEEN, PRADHAN e LEE, 2020).

2.6. Modelo proposto (STL_Bayesian_CBAM – ResNet50)

No modelo proposto utilizando ResNet50 foram utilizados pesos, que são pré-treinados usando um grande e diversificado banco de dados ImageNet para reconhecer ou classificar 1.000 objetos diferentes, que, portanto, possui 1.000 nós na última camada de classificação.

Neste estudo, foi utilizado o modelo ResNet50 pré-treinado como base para construir dois modelos de aprendizado de transferência sequencial ou classificadores de

imagens de mastite com e sem adicionar CBAM, incorporando-o à saída do mapa de recursos. Dois novos modelos incluíram apenas dois nós de saída para representar as classes “saudável” e “mastite subclínica”. Para isso, as etapas a seguir para conduzir o processo de aprendizado de transferência sequencial com mecanismo de atenção e otimização bayesiana para construir classificadores de imagens de mastite, conforme mostrado na Figura 7.

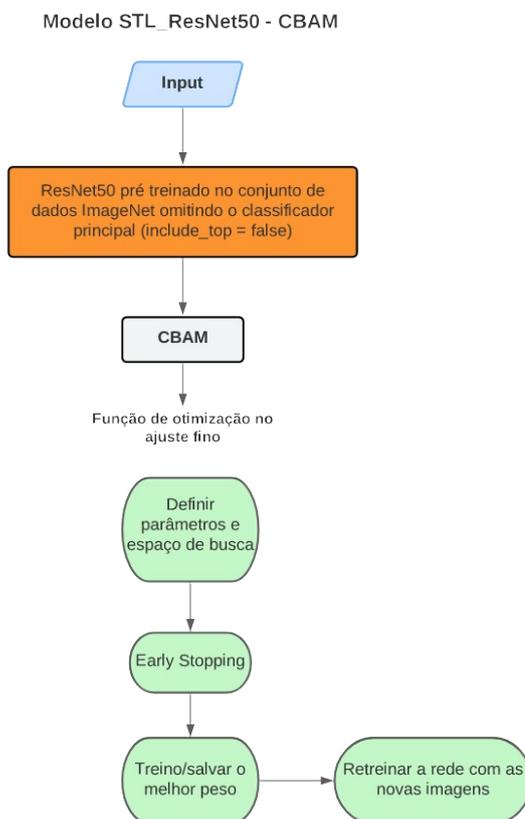


Figura 7: Modelo proposto STL_Bayesian_CBAM- ResNet50.

A ResNet50 pré-treinada foi implementada para o problema de classificação ImageNet, que inclui 1000 categorias de objetos. Portanto, utilizou-se um procedimento para gerar mapas de ativação de classe usando *global average pooling* (GAP) na CNN.

Na sequência foram incluídas as camadas *fully connected* (FC, responsáveis pela classificação, incluindo a busca por hiperparâmetros ideais com uso do otimizador bayesiano e uma camada de saída de classificação que corresponde à camada de classes do conjunto de imagens (animais saudáveis e animais com mastite subclínica). Para mostrar a eficácia do CBAM, que extrai mais recursos discriminativos e melhora no desempenho da rede pré-treinadas, conectou-se o CBAM ao mapa de recursos de saída da rede (ALIREZAZADEH, SCHIRRMANN e STOLZENBURG, 2022). Em seguida,

aplicou-se as camadas FC da mesma forma que os modelos pré-treinados. A Figura 8. fornece visões gerais do modelo pré-treinado e do modelo pré-treinado integrado às arquiteturas CBAM (pré-treinado+CBAM) em que se aplicou o CBAM ao mapa de recursos de saída do modelo pré-treinado para extrair recursos mais eficientes.

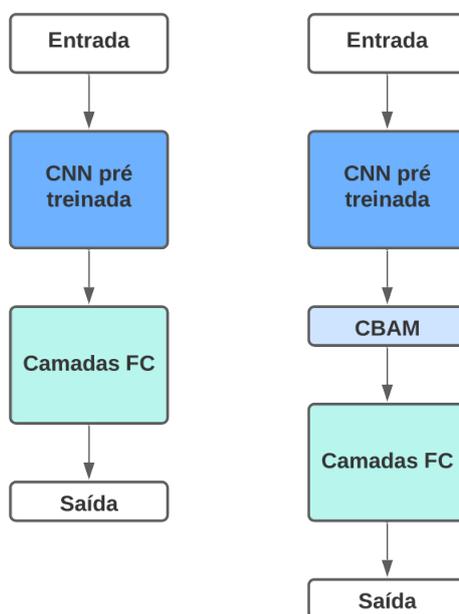


Figura 8: Arquitetura geral dos modelos usados neste estudo. O lado esquerdo (a) é o modelo pré-treinado e o lado direito (b) é o modelo pré-treinado integrado ao CBAM. Fonte: Adaptado de (Alirezazadeh, Schirrmann & Stolzenburg, 2022)

Para controlar de forma otimizada utilizou-se a otimização bayesiana implementada na biblioteca Python GPyOpt, que permite diferentes parâmetros que afetam o desempenho da otimização. Foi utilizado os parâmetros padrão fornecidos pela biblioteca, pois o principal interesse é o possível ganho de desempenho combinado ao aprendizado por transferência sequencial.

Para controlar o número de épocas de iteração no treinamento, utilizou-se o *early stopping* para reduzir o *overtraining*. Usar *early Stopping* significa automatizar a descoberta do número de épocas de um treinamento calculando a precisão destes dados, deixando ao seu encargo a função de descobrir explicitamente como o número de épocas depende dos outros hiperparâmetros.

A abordagem foi utilizada em duas etapas, com dois conjuntos de hiperparâmetros, um para cada etapa de treinamento. Foram realizadas duas execuções de otimização bayesiana separadas. Primeiro para as imagens de mamografia,

otimizando o bloco de classificação e, em seguida, o melhor modelo foi usado para a segunda etapa com imagens de mastite.

O procedimento de ajuste de hiperparâmetro teve como alvo alguns dos parâmetros mais críticos como: (1) o número de unidades na camada densamente conectada, (2) a taxa de aprendizado, (3) o parâmetro λ para a regularização, (4) a função de ativação para a camada densamente conectada e (5) a taxa de *dropout* na camada densamente conectada (Tabela 1).

Tabela 1: Hiperparâmetros e espaço de busca

Parâmetro	Espaço de busca	Descrição
Número de neurônios na camada densa personalizada	64, 128, 256, 512	Para introduzir não linearidade na saída dos neurônios
Taxa de aprendizagem	0,01; 0,001; 0,0001	Para determinar o tamanho do passo em cada iteração enquanto minimiza a função de perda
λ	0,1; 0,01; 0,001	Regularização
Função de ativação	Relu, Elu, and Tanh	Para introduzir não linearidade na saída dos neurônios
Dropout	0,3; 0,5; 0,7	Garantir que o modelo seja robusto para a perda de qualquer evidência individual

3. RESULTADOS E DISCUSSÃO

Os mapas de atenção gerados através do Convolutional Block Attention Mechanism (CBAM conectado à saída do mapa de recursos (global average pooling) da rede indicam as regiões discriminativas da imagem usadas pela CNN para identificar cada categoria (Figura 9).

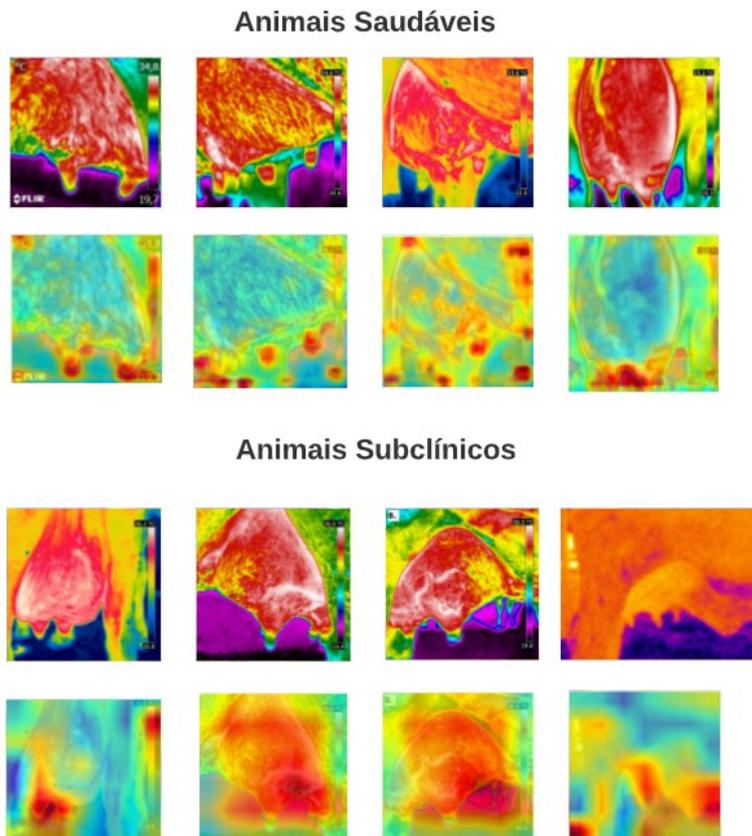


Figura 9: Os mapas de atenção destacando as regiões nas imagens que são mais discriminativas usadas para classificação de imagens de animais saudáveis (A e C) e animais com mastite subclínica (B e D).

Conforme o mapa, para os animais saudáveis a região dos tetos foi mais discriminativa. Para os animais com mastite subclínica esta região foi mais ampla com cobertura para região dos tetos e úbere. A dinâmica inflamatória da mastite se dá através do canal do teto. Quando se instala, ela desencadeia o desenvolvimento acelerado de patógenos e aumento do fluxo sanguíneo na região da glândula mamária, ou seja, do úbere, ocasionando um aumento de temperatura no local.

Com relação à implementação do CBAM conectando-o ao *global average pooling* (mapa de recursos na saída da rede), não afetou o desempenho da rede, pois alguns autores indicam utilizar o *pooling* máximo para obter essas regiões. No entanto, ao utilizá-lo gerou uma perda de informação discriminativa das imagens, o que não ocorreu utilizando o *pooling* médio, pois ao fazer a média de um mapa de recursos, o valor pode ser maximizado encontrando todos os pontos discriminativos gerando ativações em vermelho (ZHOU et al., 2015).

O desempenho geral da rede de atenção alcançou 97,28% de acurácia no conjunto de dados de teste comparativamente ao modelo em que não se utilizou o CBAM (92,1%). A acurácia neste último foi alcançada em 11 épocas, o mesmo não ocorreu no modelo proposto que obteve o melhor desempenho utilizando 52 épocas (Figura 10).

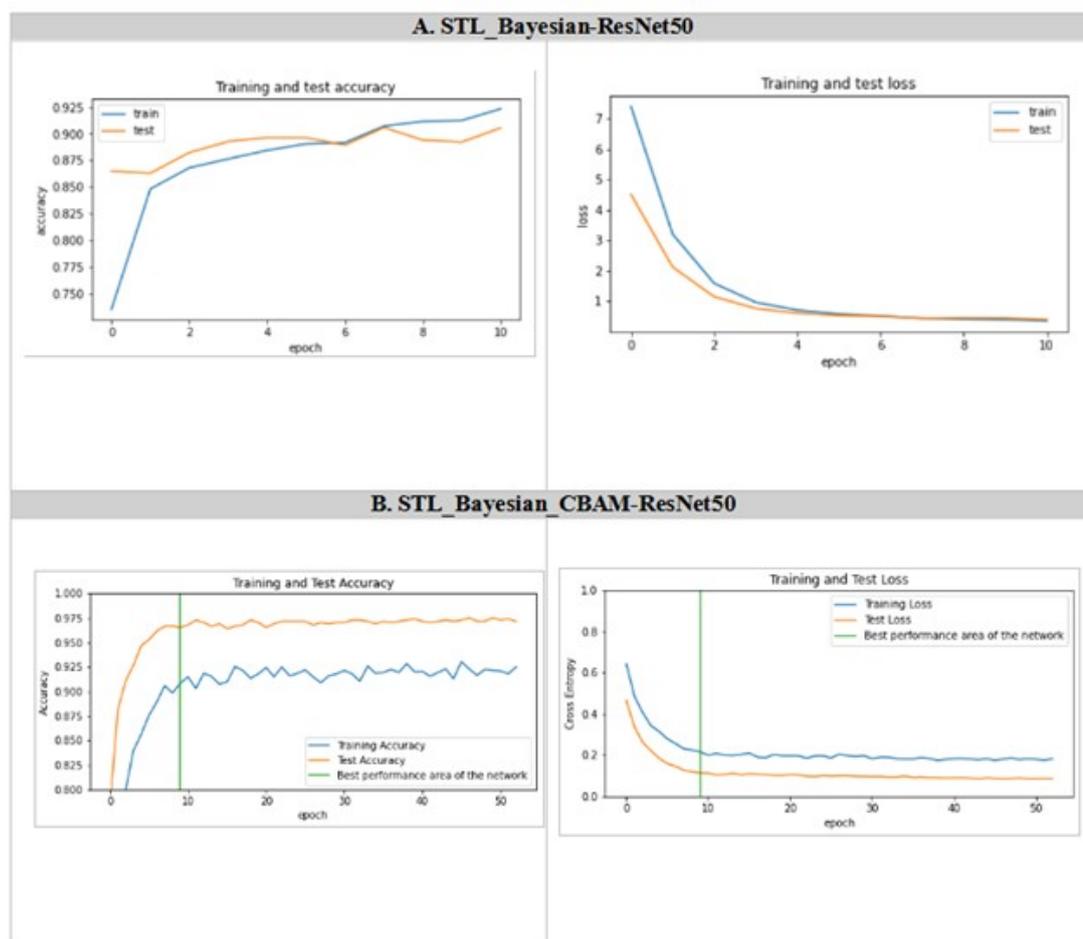


Figura 10: Curvas de acurácia e perda no treinamento e teste para os modelos ajustados.

Uma particularidade encontrada nas curvas de treinamento e teste do modelo STL_Bayesian_CBAM – ResNet50 foi que o valor da acurácia no teste apresentou valor ligeiramente maior (4,2%) do que o da acurácia de treinamento, indicando uma boa adaptabilidade da rede ao reconhecimento de novas imagens fornecidas a ela.

A F1 score apresentou valor de 96,7 e 85,5%, respectivamente. Ela considera de forma abrangente a precisão e o recall, o seu resultado juntamente com o da acurácia pode refletir melhor a superioridade do desempenho do modelo, pois a diminuição de falsos positivos pode promover melhor produtividade de leite e maior confiabilidade,

diminuição dos custos para tratamento da enfermidade, maior valor do leite pago ao produtor, em decorrência da melhoria na qualidade. De uma forma geral, uma boa acurácia auxilia o produtor a agir de forma precisa quanto a incidência da mastite subclínica, menor descarte de animais com potencial de produção de leite, melhor sanidade e bem-estar do rebanho.

3.1. Performance do modelo na classificação e conjunto de hiperparâmetros

O desempenho dos modelos na tarefa de classificação de imagens térmicas do úbere de vacas de leite (animais saudáveis e animais com mastite subclínica) pode ser visualizado através da matriz de confusão (Figura 11).

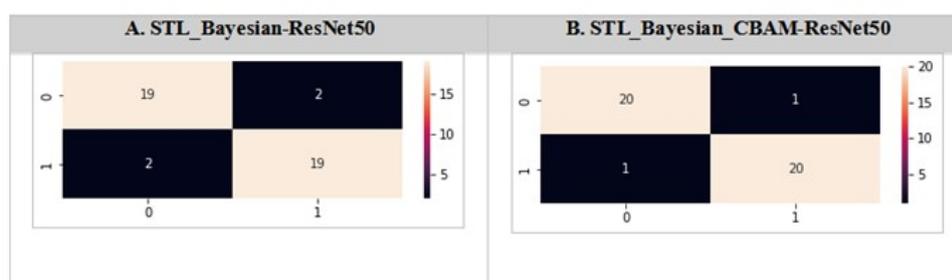


Figura 11: Matrizes de confusão dos quatro modelos empregados na classificação das imagens (0 – animal saudável; 1 – animal com mastite subclínica).

Nota-se que a proporção de identificação (taxa positiva verdadeira e taxa negativa verdadeira) do STL_Bayesian_CBAM-ResNet50 foi maior. A proporção de acertos na identificação atingiu 97% para animais saudáveis e animais com mastite subclínica. Isso ocorreu principalmente devido ao uso do mecanismo de atenção e do otimizador que realizou a busca dos melhores hiperparâmetros para o modelo de classificação, contribuindo para um ótimo desempenho (11B).

Verificou-se maior proporção de erros (taxa de falsos positivos e taxa de falsos negativos) maior no modelo STL_Bayesian – ResNet50 (Figura 11A). Este modelo obteve bom desempenho apesar de ter sido mais baixo do que o STL_Bayesian_CBAM – ResNet50, ocorrendo principalmente devido à seleção de modelos no qual foram escolhidos os melhores hiperparâmetros influenciando diretamente na sua qualidade, assim como na sua capacidade de aprendizado e de generalização.

O melhor conjunto de hiperparâmetros e melhor conjunto de pesos para o treinamento da rede conferido a partir do modelo substituto bayesiano segue na Tabela 2.

Tabela 2: Melhor conjunto de hiperparâmetros inferidos pelo modelo substituto Bayesiano

Parâmetro	Espaço de busca
Número de neurônios na camada densa personalizada	128
Taxa de aprendizagem	0.0001
12	0,01
Função de ativação	Relu
Dropout	0,3

4. CONCLUSÃO

As metodologias preditivas propostas com base na transferência de conhecimento para detecção automática de mastite subclínica bovina classificaram corretamente as imagens, porém, o modelo de aprendizagem por transferência sequencial (STL_Bayesian_CBAM-ResNet50) apresentou melhor desempenho (97,28%) em relação ao modelo STL_Bayesian-ResNet50 (92,1%) contribuindo significativamente para a detecção automática de animais saudáveis e animais com mastite subclínica a partir de imagens térmicas do úbere de vacas leiteiras.

REFERÊNCIAS

- ALIREZAZADEH, P.; SCHIRMANN, M.; STOLZENBURG, F. Improving Deep Learning-based Plant Disease Classification with Attention Mechanism. *Gesunde Pflanzen*, 2022.
- BA, J.; MNIH, V.; KAVUKCUOGLU, K. Multiple object recognition with visual attention. *arXiv arXiv:1412.7755v2*, 2014.
- BOUMARAF, S.; XIABI, L.; ZHONGSHU, Z.; XIAOHONG, M.; FERKOUS. C. A. new transfer learning based approach to magnification dependent and independent classification of breast cancer in histopathological images. *Biomedical Signal Processing and Control*, v. 63, p.102192, 2021.
- DA SILVA, R. A. B.; PANDORFI, H.; DE ALMEIDA, G. L. P.; DE ASSUNÇÃO MONTENEGRO, A. A.; DA SILVA, M. V. Spatial dependence of udder surface temperature variation in dairy cows with healthy status and mastitis. *Revista Brasileira de Saúde e Produção Animal*, 20, 2019.
- DAS, R.; SAILO, L.; VERMA, N.; BHARTI, P.; SAIKIA, J.; IMTIWATI; KUAR, R. Impact of heat stress on health and performance of dairy animals: A review. *Veterinary World*, n. 9, v.3, p.260–268, 2016.

KERMANY, D. S.; GOLDBAUM, M.; CAI, W.; VALENTIM, C. C.; LIANG, H.; BAXTER, S. L.; MCKEOWN, A.; YANG, G.; WU, X.; YAN, F.; DONG, J.; PRASADHA, M. K.; PEI, J.; TING, M. Y. L.; ZHU, J.; LI, C.; HEWETT, S.; DONG, J.; ZIYAR, I.; ZHANG, K. Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, v. 172, p. 1122–1131, 2018.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, n. 60, v.6, p.84–90, 2017.

LIMA, R.S.; DANIELSKI, G.C.; PIRES, A.C.S. Mastitis detection and prediction of milk composition using gas sensor and electrical conductivity. *Food Bioprocess Technology*, 2018.

NEGASSI, M.; SUAREZ-IBARROLA, R.; HEIN, S.; MIEMIK, A.; REITERER, A. Application of artificial neural networks for automated analysis of cystoscopic images: A review of the current status and future prospects. *World Journal of Urology*, n. 38, p.1–10, 2020.

PELIKAN M.; GOLDBERG, D.E., CANTÚ-PAZ, E. BOA: The Bayesian optimization algorithm. In: *Proceedings of the Genetic and Evolutionary Computation Conference*, Citeseer, p. 525–532, 1999.

PORTER, I. R.; WIELAND, M.; BASRAN, P. S. Feasibility of the use of deep learning classification of teat-end condition in Holstein cattle. *Journal of Dairy Science*, n.104, v.4, p. 4529–4536, 2021.

RUEGG, P. L. A 100-Year Review: Mastitis detection, management, and prevention. *Journal of Dairy Science*, n.100, v.12, p. 10381–10397, 2017.

SAMEEN, M.I.; PRADHAN, B.; LEE S. Application of convolutional neural networks featuring Bayesian optimization for landslide susceptibility assessment. *Catena*, n.186, p.104249, 2020.

SIEMON, M. S. N.; SHIHAVUDDIN, A. S. M.; RAVN-HAREN, G. Sequential transfer learning based on hierarchical clustering for improved performance in deep learning based food segmentation. *Scientific Reports*, n.11, v.1, 813, 2021.

SILVA, R. A. B. da, LIMA, J. P. S. do M., PANDORFI, H.; ALMEIDA, G. L. P. de. Thermal Image Thresholding for Automatic Detection of Bovine Mastitis. *International Journal of Computer Applications*, n.183, v. 14, p. 29–33, 2021.

SWATI, Z. N. K.; ZHAO, Q.; KABIR, M.; ALI, F.; ALI, Z.; AHMED, S.; LU, J. Brain tumor classification for MR images using transfer learning and fine-tuning. *Computerized Medical Imaging and Graphics*, n. 75, p.34–46, 2019.

TAYLOR, L.;NITSCHKE, G. Improving Deep Learning using Generic Data Augmentation. *arXiv preprint arXiv:1708.06020*, 2017.

WILSON, A.C.; ROELOFS, R.; STERN, M.; SREBRO, N.; RECHT, B. The marginal value of adaptive gradient methods in machine learning. In *Advances in Neural*

Information Processing Systems, In Neural Information Processing Systems, p. 4148-4158, 2017.

WOO, S.; PARK, J.; LEE, J.Y.; KWEON, I.S. CBAM: Convolutional Block Attention Module. In Proceedings of the European Conference on Computer Vision (ECCV), Munich, Germany, p.8–14, 2018

YANG, L.; SHAMI, A. On Hyperparameter Optimization of Machine Learning Algorithms: Theory and Practice. arXiv preprint arXiv:2007.15745, 2022.

ZANINELLI, M.; REDAELLI, V.; LUZI, F.; BRONZO, V.; MITCHELL, M.; DELL'ORTO, V.; BONTEMPO, V.; CATTANEO, D.; SAVOINI, G. First evaluation of infrared thermography as a tool for the monitoring of udder health status in farms of dairy cows. *Sensors*, v. 18, p.862, 2018.

ZHANG, X.; KANG, X.; FENG, N.; LIU, G. Automatic recognition of dairy cow mastitis from thermal images by a deep learning detector. *Computers and Electronics in Agriculture*, v. 178, 2020.

ZHAO, X.; LI, K.; LI, Y.; MA, J.; Zhang, L. Identification method of vegetable diseases based on transfer learning and attention mechanism. *Computers and Electronics in Agriculture*, 193, 106703, 2022.

ZHOU, B.; KHOSLA, A.; LAPEDRIZA, A.; OLIVA, A.; TORRALBA, A. Learning Deep Features for Discriminative Localization. arXiv:1512.04150v1, 2015.

CONSIDERAÇÕES FINAIS

A termografia por infravermelho foi uma técnica de mapeamento da temperatura da superfície do úbere de bovinos de leite, capaz de identificar alterações provenientes de quadro clínico de mastite bovina. Quando associada a técnicas de análise de imagem, com o seu processamento e segmentação, possibilitou o diagnóstico preciso de mastite subclínica, por meio do aprendizado profundo de máquina, minimizando problemas como subjetividade, custos e rapidez, quando comparado aos métodos tradicionais de diagnóstico da infecção.

Ao analisar os termogramas por meio de software desenvolvido para segmentação automática por limiarização, ele identificou automaticamente a temperatura de cada pixel, o que permitiu a classificação do quadro clínico de mastite em bovinos de leite.

O ângulo de captura das imagens e o posicionamento do operador durante o registro das imagens foram fatores altamente consideráveis para serem observados em condição de campo e interferiu diretamente no estudo com a técnica de segmentação.

A principal vantagem da técnica de segmentação automática é que ela possui custo computacional reduzido, pois utiliza poucas imagens para a classificação, comparativamente aos métodos de aprendizagem de máquina.

As metodologias preditivas utilizando aprendizado profundo e transferência de conhecimento sequencial para detecção automática de mastite subclínica bovina, permitiram a correta classificação das imagens térmicas associado ao quadro clínico de bovinos de leite, contribuindo significativamente para a detecção automática de animais saudáveis e animais com mastite subclínica a partir das imagens térmicas do úbere de vacas leiteiras. Essa metodologia preditiva contribuiu significativamente para diminuição dos falsos positivos quando comparado aos testes CMT que depende da intervenção e interpretação humana.

A utilização da otimização bayesiana, cuja motivação está ligada à escolha dos melhores parâmetros para um modelo de aprendizado profundo, interferiu significativamente no desempenho dos modelos. Comparativamente à escolha manual de parâmetros representa um ganho de tempo, pois a escolha manual é trabalhosa.

Os mecanismos de atenção aplicados às tarefas de visão computacional são inspirados nas capacidades visuais humanas, mais precisamente a atenção, que consiste em focar em determinado objeto em uma cena. Quando aplicado aos modelos de aprendizado profundo, melhoram seu desempenho por realçarem características discriminativas na imagem, ajudando na classificação.

Os resultados do presente estudo indicam que as técnicas de processamento de imagens aplicadas às imagens térmicas conseguiram extrair características que auxiliaram na classificação das imagens, no entanto, faz-se necessário mais estudos envolvendo as redes convolutivas e suas técnicas visando obter novos resultados que auxiliem o produtor na tomada de decisão.