



UNIVERSIDADE FEDERAL DE MATO GROSSO
CAMPUS UNIVERSITÁRIO DE SINOP
INSTITUTO DE CIÊNCIAS AGRÁRIAS E AMBIENTAIS
PROGRAMA DE PÓS - GRADUAÇÃO EM ZOOTECNIA

Avaliação da cobertura de gordura de novilhas e vacas
usando visão computacional.

Elton Fernandes dos Santos

Dissertação apresentada ao Programa de Pós-Graduação em Zootecnia da Universidade Federal de Mato Grosso, *Campus* Universitário de Sinop, como parte das exigências para a obtenção do título de Mestre em Zootecnia.

Área de concentração: Produção Animal

Sinop, Mato Grosso

Julho de 2021

ELTON FERNANDES DOS SANTOS

**Avaliação da cobertura de gordura de novilhas e vacas
usando visão computacional.**

Dissertação apresentada ao Programa de Pós-Graduação em Zootecnia da Universidade Federal de Mato Grosso, *Campus* Universitário de Sinop, como parte das exigências para a obtenção do título de Mestre em Zootecnia.

Área de concentração: Produção Animal

Orientador: Prof. Dr. Luciano Bastos Lopes

Coorientadora: Dr. Laurimar Gonçalves Vendrusculo

Sinop, Mato Grosso

Julho de 2021

Dados Internacionais de Catalogação na Fonte.

S237a Santos, Elton fernandes dos.
Avaliação da cobertura de gordura de novilhas e vacas usando
visão computacional / Elton fernandes dos Santos. -- 2021
3 f. : il. color. ; 30 cm.

Orientador: Luciano Bastos Lopes.
Co-orientadora: Laurimar Gonçalves Vendrusculo.
Dissertação (mestrado) - Universidade Federal de Mato Grosso,
Instituto de Ciências Agrárias e Ambientais, Programa de Pós-
Graduação em Zootecnia, Sinop, 2021.
Inclui bibliografia.

1. Carcaça. 2. automação. 3. Processamento de imagem. I.
Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

Permitida a reprodução parcial ou total, desde que citada a fonte.



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE MATO GROSSO
PRÓ-REITORIA DE ENSINO DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA
FOLHA DE APROVAÇÃO

TÍTULO: "AVALIAÇÃO DA COBERTURA DE GORDURA DE NOVILHA E VACAS USANDO VISÃO COMPUTACIONAL"

AUTOR: MESTRANDO Elton Fernandes dos Santos

Dissertação defendida e aprovada em 20/07/2021.

COMPOSIÇÃO DA BANCA EXAMINADORA

1. Doutor(a) Luciano Bastos Lopes (Presidente Banca / Orientador)
INSTITUIÇÃO: EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA, AGROSSILVIPASTORIL - EMBRAPA MATO GROSSO
2. Doutor(a) Paulo Sérgio Andrade Moreira (Examinador Externo)
INSTITUIÇÃO: UNIVERSIDADE FEDERAL DE MATO GROSSO
3. Doutor(a) Angelo Polizel Neto (Examinador Externo)
INSTITUIÇÃO: UNIVERSIDADE FEDERAL DE RONDONÓPOLIS
4. Pós-Doutor(a) Laurimar Gonçalves Vendrusculo (Examinador Externo)
INSTITUIÇÃO: EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA, AGROSSILVIPASTORIL - EMBRAPA MATO GROSSO
5. Doutor(a) Dalton Henrique Pereira (Examinador Suplente)
INSTITUIÇÃO: UNIVERSIDADE FEDERAL DE MATO GROSSO

SINOP, 20/07/2021.



Documento assinado eletronicamente por **PAULO SERGIO ANDRADE MOREIRA, Docente da Universidade Federal de Mato Grosso**, em 22/07/2021, às 16:29, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Laurimar Gonçalves Vendrusculo, Usuário Externo**, em 23/07/2021, às 11:25, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Luciano Bastos Lopes, Usuário Externo**, em 23/07/2021, às 15:58, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **ANGELO POLIZEL NETO, Docente da Universidade Federal de Mato Grosso**, em 26/07/2021, às 09:39, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufmt.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3722139** e o código CRC **E018CA7E**.

AGRADECIMENTOS

Agradeço a Deus, pela vida.

À minha família, minha mãe Rita de Cassia Amaral Santos e meu pai José da Paixão Santos que me apoiaram durante toda jornada acadêmica. Ao meu orientador Dr. Luciano Bastos Lopes por aceitar esse desafio, pela confiança e amizade. A Dra. Laurimar Gonçalves Vendrusculo pelas orientações e apoio durante todo processo. As amizades construídas decorrente do mestrado em especial, a Scheila Geiele Kamchen e Kássila Fernanda Bertogna pela parceria e apoio. Ao colaborador Janderson Oliveira que se colocou à disposição para nós auxiliarmos durante todo processo de coleta de imagem e classificação de carcaças.

BIOGRAFIA

Elton Fernandes dos Santos, filho de José da Paixão Santos e Rita de Cássia Amaral Santos, nasceu em 5 de abril de 1990 na cidade de Colíder, Mato Grosso. Em 2014 iniciou a graduação de bacharelado em engenharia elétrica na Universidade Estadual do Estado de Mato Grosso – *Campus Sinop*, com conclusão em 2019. Foi bolsista da FAPMAT onde trabalhou no projeto “Correção de Erro na Geração de Atraso Digitalmente Controlado de Alta Precisão” entre 19/10/2018 a 28/09/2019. Em agosto de 2019, iniciou o programa de Pós-graduação em Zootecnia pela Universidade Federal de Mato Grosso – *Campus Sinop*, com linha de pesquisa em produção animal.

RESUMO

SANTOS, Elton Fernandes. Dissertação de Mestrado (Zootecnia), Universidade Federal de Mato Grosso, *Campus* Universitário de Sinop, fevereiro de 2021, 58f. **Avaliação da cobertura de gordura de novilhas e vacas usando visão computacional.** Orientador: Prof. Dr. Luciano Bastos Lopes. Coorientadora: Dr. Laurimar Gonçalves Vendrusculo.

Embora haja procura por carne magra, essa não se sobrepõe à importância da cobertura de gordura em sua função de preservar as características organolépticas da carne durante o processo de resfriamento. Mudanças estruturais e processos bioquímicos que acontecem nas primeiras 24h post morte impactam diretamente a qualidade da carne, e a cobertura de gordura subcutânea minimiza esse impacto, agregando valor ao produto final. Porém, os métodos de avaliação classificam as carcaças de acordo a qualidade de acabamento, não quanto ao percentual da carcaça protegida pela cobertura de gordura. O objetivo deste estudo foi avaliar métodos de visão computacional para estimar a cobertura de gordura em carcaças bovinas, além de verificar a relação da cobertura de gordura com o sistema de classificação SEUROP. Uma rotina de processamento de vídeo em tempo real foi proposta para calcular o percentual de cobertura de gordura subcutânea. O método conseguiu mapear as regiões da carcaça coberta com gordura com 98% de precisão. As classificações apresentaram baixa correlação com o percentual de cobertura de gordura ($R^2 = 0,3$ para o sistema do frigorífico e $R^2 = 0,6$ sistema SEUROP), também houve baixa concordância entre as avaliações dos quatro especialistas ($Kappa < 0,3$). Por fim, foi proposto um modelo de *deep learning* para realizar a classificação do frigorífico, modelo apresentou 82% de acurácia.

Palavras-chave: Acabamento, automação, processamento de imagem.

ABSTRACT

SANTOS, Elton Fernandes. Dissertação de Mestrado (Zootecnia), Universidade Federal de Mato Grosso, *Campus* Universitário de Sinop, fevereiro de 2021, 58f. **Evaluation of heifer and cow fat coverage using computer vision.** Orientador: Prof. Dr. Luciano Bastos Lopes. Coorientadora: Dr. Laurimar Gonçalves Vendrusculo

Although there is a demand for lean meat, this does not outweigh the importance of fat coverage in its function of preserving the organoleptic characteristics of the meat during the cooling process. Structural changes and biochemical processes that take place in the first 24 hours after death directly impact meat quality, and subcutaneous fat coverage minimizes this impact, adding value to the final product. However, the evaluation methods classify the carcasses according to the quality of finish, not the percentage of the carcass protected by the fat coating. The aim of this study was to evaluate computer vision methods to estimate fat coverage in bovine carcasses, in addition to verifying the relationship of fat coverage with the SEUROP classification system. A real-time video processing routine was proposed to calculate the percentage of subcutaneous fat coverage. The method was able to map the regions of the carcass covered with fat with 98% accuracy. The ratings showed low correlation with the percentage of fat coverage ($R^2 = 0.3$ for the refrigerator system and $R^2 = 0.6$ SEUROP system), there was also low agreement between the assessments of the four experts ($Kappa < 0.3$). Finally, a deep learning model was proposed to carry out the classification of the slaughterhouse, a model showing 82% accuracy.

Key words: Cow finishing, automation, image processing.

Sumário

Sumário

1 INTRODUÇÃO GERAL

2 REVISÃO BIBLIOGRÁFICA

2.1 Resfriamento de carcaça bovinas

2.2 Classificação de carcaça

2.3 Classificação computadorizada

2.4 Visão computacional

2.5 Segmentação de imagem

2.6 Transformação morfológica

2.7 Processamento de vídeo

2.8 Subtração de plano de fundo

3 REFERÊNCIAS

CAPÍTULO 1 – DETERMINAÇÃO DO PERCENTUAL DE COBERTURA DE GORDURA EM CARCAÇAS BOVINAS USANDO VISÃO COMPUTACIONAL

1 INTRODUÇÃO

2 MATERIAL E MÉTODOS

2.1 Localização

2.2 Coleta de dados

2.4 Processamento de vídeo

2.5 Segmentação de fundo

2.6 Segmentação de gordura

2.7 Classificação pelos avaliadores

2.8 Classificação pelo frigorífico

2.9 Análise estatística

3 RESULTADOS

3.1 Estimativa do percentual de cobertura da carcaça

3.2 Classificação pelo frigorífico

3.3 Comparação das avaliações entre os técnicos.

4 DISCUSSÃO

4.1 Estimativa do percentual de cobertura da carcaça

4.2 Classificação pelo frigorífico

4.3 Comparação das avaliações entre os técnicos.

5 CONCLUSÃO

6 REFERÊNCIAS

1 INTRODUÇÃO GERAL

O surgimento de novas tecnologias promoveu otimizações significativas em vários setores da agricultura nas últimas décadas, mas apesar dessa onda de tecnificação, a pecuária brasileira pouco tem se beneficiado dessa evolução tecnológica, onde os métodos tradicionais caracterizados pela baixa adoção de tecnologias ainda são uma realidade (Neves et al. 2014, Ribas, 2017, Santos et al. 2018, Mandarino et al. 2019).

No cenário competitivo atual, a informação, seja ela científica, social, produtiva, técnica ou econômica, é considerada um insumo básico para tomadas de decisão (Ribas et al. 2017). Segundo Luciane (2010), o gerenciamento de informação é um instrumento estratégico necessário para auxiliar os tomadores de decisões, permitindo controle por meio de análise consolidada de informações. Nesse aspecto, o processo de obtenção de dados torna-se uma tarefa fundamental. O estudo de Davenport (1998) reforça essa abordagem, enfatizando que para uma gestão mais eficaz, é necessário a integração de sistemas de aquisição de dados contínuos.

A pecuária de precisão, assim como a agricultura de precisão, é um conceito cada vez mais abordado no mundo do agronegócio (Garcia et al. 2020). O avanço do conhecimento e a disponibilidade de sensores e equipamentos propiciam o aumento da automação na produção animal. Todavia, os processos de monitoramento e controle só terão impacto no manejo animal se forem projetados dentro da realidade dos produtores, apresentando pouca exigência técnica para operação e viabilidade econômica.

No entanto, a baixa tecnificação na pecuária, não está só no campo, mas toda cadeia produtiva, incluindo abatedouros. Apesar de sua importância para o agronegócio, ainda são empregados métodos de avaliação visual para várias tarefas complexas em frigoríficos. Tarefas como, classificação por acabamento e avaliação de conformação de

carcaças podem ser aprimoradas empregando métodos de visão computacional. A falta de profissionais qualificados, e principalmente baixa eficácia, em conjunto com o aumento dos rebanhos comparado com as vantagens dos sistemas computadorizados, preconizam uma necessidade de automatizar tarefas repetitivas realizadas por humanos.

Este estudo pretende contribuir para o processo de automação das atividades relacionadas à avaliação de carcaças no frigorífico, utilizando métodos de visão computacional para estimar a cobertura de gordura subcutânea em bovinos no *post mortem*. Também foi proposto um modelo computacional para realizar a predição das classificações realizadas pelo frigorífico.

2 REVISÃO BIBLIOGRÁFICA

2.1 Resfriamento de carcaça bovinas

O processo de refrigeração das carcaças influencia na qualidade da carne. Mudanças estruturais e processo bioquímico que acontecem durante as primeiras 24h post morte estão diretamente relacionados com a cobertura de gordura subcutânea (Ricardo, 2010). Essa camada de gordura é responsável por proteger a carcaça durante o resfriamento, reduzindo a perda de água e o encurtamento da carcaça, por consequência evitando a perda de peso.

A gordura de cobertura realiza um isolamento térmico que além de evitar a perda de água e o ressecamento, desacelera a oxidação das mioglobinas controlando a concentração de sais minerais (Lawrie, 2005). As regiões dos cortes superficiais são os que apresentam maior ressecamento e escurecimento por estar expostas a baixas temperaturas. A cobertura de gordura adequada preserva a qualidade da carne mantendo as características desejadas pelo consumidor (Ima, 2010).

2.2 Classificação de carcaça

Entende-se como carcaça o animal abatido, sangrado, esfolado, eviscerado, com as seguintes partes removidas: cabeça, patas, gordura peri-renal e inguinal, órgãos genitais externos, medula espinhal, diafragma e pilares, feridas de sangria (Santos, 2018). A classificação consiste em agrupar carcaças com características semelhantes, maturidade e sexo. Já a tipificação é dada pela combinação da classificação de forma hierárquica, com restrições de conformação, acabamento e outras características que permite tipificá-las de acordo com a qualidade (Silva et al. 2018).

A classificação de carcaça foi desenvolvida no início dos anos 70 pelo Reino Unido e pela França. Posteriormente a União Europeia e a Nova Zelândia também adotaram sistemas de classificação inspirados no modelo desenvolvido por estes países precursores. No Brasil, um sistema de classificação tipificação foi apresentado em 1989, com os parâmetros: sexo, maturidade, conformação e acabamento. Entretanto, a implantação não aconteceu de forma efetiva, devido à complexidade e difícil aplicação (Pereira et al, 2004).

Em maio de 2004 foi apresentado uma nova normativa que regulamenta a classificação de carcaça bovinas em todo território Brasileiro tendo como base as características indicativas de qualidades: sexo, maturidade, peso e acabamento.

Quanto ao sexo estabelece as seguintes categorias:

- Macho inteiro (M);
- Macho castrado (C)
- Novilha (F)
- Vaca de descarte (FV)

Quanto à maturidade, avalia-se pelo total de dentes incisivos.

- Dente de leite (d) Animais com apenas o primeiro dente, sem perda das pinças.
- Dois dentes (2d) animais com até 2 dentes definitivos, sem perdas dos primeiros médios das primeiras dentições.

- Quatro dentes (4d) - Animais com até 4 dentes definitivos, sem queda dos segundos médios das primeiras dentições
- Seis dentes (6d) - Animais com até 6 dentes definitivos, sem queda dos cantos da primeira dentição.
- Oito dentes (8d) - Animais com mais de 6 dentes definitivos.

O acabamento de carcaça é verificado mediante a observação da quantidade de gordura de cobertura e sua distribuição na carcaça. Uma das formas de aferição é medir a espessura na região lombar e no coxão, (altura da 6^a, 9^a, 12^a costela), classificadas em:

- Magra (1) - gordura ausente
- Gordura escassa (2) - 1 a 3 mm de espessura.
- Gordura mediana (3) - acima de 3 e até 6 mm de espessura.
- Gordura uniforme (4) acima 6 e até 10 mm de espessura.
- Gordura excessiva (5) - acima de 10 mm de espessura.

Atualmente o sistema de classificação Brasileira, não tem relação direta com a comercialização ou qualidade da carne, contrariamente seu objetivo é voltado para produção de animais com terminação precoce, incentivando o pecuarista a produzir animais mais jovens com acabamento adequado. Parâmetros importantes para o comércio como grau de marmoreio, cor, textura, maciez, sabor e suculência não são considerados pelo sistema de classificação (Santos et al, 2018).

Embora haja métodos quantitativos para avaliar o acabamento de carcaça, como a medição da espessura de gordura, durante o processo de abate, essa medição manual é inviável em função da quantidade animais abatidos diariamente no frigorífico. Na prática a avaliação é realizada empiricamente por inspeção visual. Esse é um dos processos que adiciona a classificação nível de discordância entre os avaliadores. Stinga et al. (2020), relatou uma discrepância considerável entre classificadores com experiência maior ou menor que 5 anos.

2.3 Classificação computadorizada

As primeiras pesquisas de visão computacional para avaliação de carcaças foram realizadas por Cross et al. (1983). Seus resultados mostraram que métodos de visão computacional tinham acurácia igual ou maiores que os avaliadores da USDA (United States Department do Agriculture) para predizer a massa muscular das carcaças (Geraldo, 2018). A obtenção de parâmetros como gordura intramuscular, maciez de carne e rendimento de carcaça, por visão computacional já tem sido apresentada em diversos trabalhos tanto para bovinos (Pabiou et al. 2011, Rivaroli et al., 2017) como para suínos (Kashiha et al., 2014), ovinos (Einarsson et al., 2015) e aves (Chmiel et al., 2011).

Dentre as vantagens de avaliação computadorizada estão: baixo custo de implantação grande potencial para automação e integração com máquinas já existentes na linha de abate. Trabalhos recentes como o de Stinga (2020) reforçam as vantagens do sistema, no seu estudo foi utilizado método computacional baseado no padrão SEUROP para avaliar acabamento e conformação a qual obteve uma acurácia de 84% em relação aos avaliadores. Entretanto, foi observado discordância entre os avaliadores principalmente em relação à conformação. Segundo Stinga (2020), a discordância evidencia a necessidade de padronizar essa avaliação inserindo métodos quantitativos como uso de processamento digital de imagem.

2.4 Visão computacional

Visão computacional é a ciência que estuda e desenvolve tecnologias que atribui às máquinas a capacidade de enxergar. A capacidade de visão não só permite extrair informação reconhecendo e classificando objetos, mas envolve a compreensão de contexto, o que torna uma tarefa bem desafiadora. O contexto de uma imagem nem sempre está explícito, sua compreensão está ligada a conhecimentos a priori, podendo exigir características típicas de humanos como a criatividade, capacidade de generalização e transferência de aprendizado (Chen et al, 2020).

O processamento digital de imagens PDI é parte integrante da visão computacional e consiste em executar operações matemáticas com objetivo de melhorar a qualidade espectral permitindo extrair informação. Um algoritmo de visão computacional é dividido em várias etapas, como na Figura 1. O DPI pode ser considerado com as partes de pré-processamento e processamento digital (Almeida 2018).

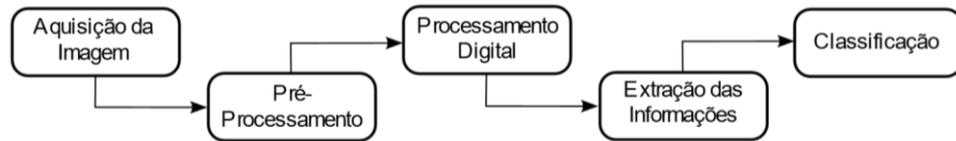


Figura 1: Rotina de um algoritmo de visão computacional.

2.5 Segmentação de imagem

O processo de segmentação separa regiões de uma imagem por contexto, isso pode ser simples como comparar valores de pixel, mas em ambientes dinâmicos pode se tornar bastante complexos. Os métodos de segmentação treináveis geralmente são alternativas que permitem resolver problemas que as técnicas determinísticas não admitem solução.

Em problemas complexos, o uso de algoritmo baseado em aprendizado profundo (Deep Learning - DL) se destaca no quesito acurácia, principalmente em tarefas de reconhecimento e localização de objetos e isso não é diferente para segmentação (Bai et al, 2021). Uma rede neural convolucional (Convolutional Neural Network - CNN), é definida como um algoritmo de DL que extrai informação de grandes quantidades de dados. Essa capacidade pode ser atribuída aos extratores de características baseadas em camadas convulsionais que são construídas por um processo denominado treinamento.

O treinamento consiste em um processo recursivo que busca minimizar a diferença da saída da rede e os rótulos (Yang et al, 2015). Os rótulos podem ser um conjunto de classes, posição de um objeto na imagem, ou uma máscara. Quando o rótulo é uma máscara, denomina-se de segmentação, as redes com essa característica tentam prever a classe em que cada pixel da imagem pertence.

O aprendizado adquirido pela rede neural convolucional no processo de treinamento é representado por pesos agrupados em matrizes denominadas de (*kernel*). O termo rede neural convolucional deriva-se da operação de convolução matemática realizada entre o *kernel* e a imagem de entrada. O conceito de convolução pode ser descrito como uma janela deslizante (*kernel*) que percorre toda imagem realizando a soma dos produtos entre os pixels sobrepostos. Para realizar uma operação de convolução temos que definir alguns parâmetros. São eles: tamanho do *kernel*, passo e a profundidade. O tamanho do *kernel* é a dimensão da matriz, o passo é a distância entre os pontos de ancoragem de cada operação e a profundidade é o total de *kernel* criado para cada camada convolucional.

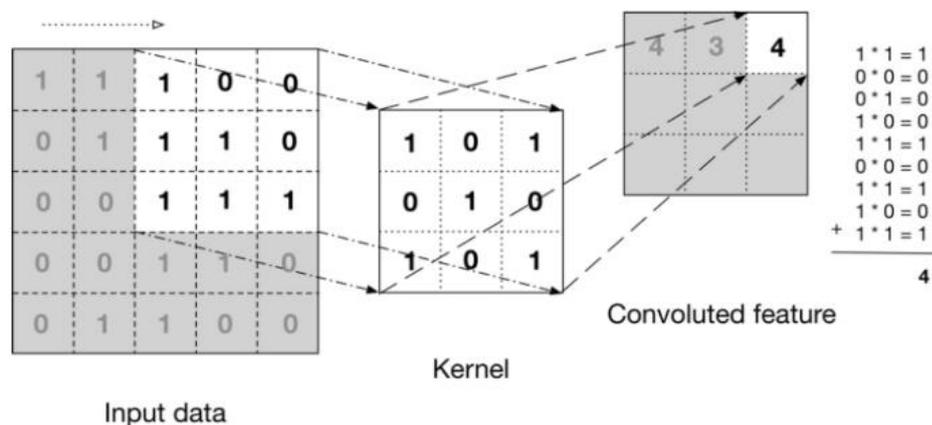


Figura 2: Operação de convolução entre uma matriz de entrada e um kernel (Wadhawan, Kumar, 2020).

A U-net é uma arquitetura de rede neural baseada em aprendizagem profunda vencedora da competição ISBI em 2015. O modelo proposto por Ronneberger (2015) tem como principal característica as capacidades de aprender com um número muito reduzido de amostras, isso é decorrente de sua arquitetura em formato U e contrai e expande a imagem, simulando o processo de argumentação dentro das camadas convolucionais. Embora a U-net tenha custo computacional elevado, ela produz resultado excelente de

segmentação, o que é útil para criar banco de dados para treinar outros modelos (Li et al, 2018, Tang et al, 2019).

2.6 Transformação morfológica

A transformação morfológica é baseada na teoria de conjuntos e em visão computacional é definida por duas operações elementares: erosão e dilatação. A erosão e a dilatação são definidas pelas equações 1 e 2 onde, onde A é a imagem, B é o elemento estruturante (Banan, 1998).

$$A \oplus B = \{z \mid B \cap A\} \text{ Dilatação}$$

$$A \ominus B = \{z \mid B \subseteq A\} \text{ Erosão}$$

O resultado das operações de dilatação e erosão sobre uma imagem binária utilizando uma matriz 3x3 como elemento estruturante é mostrado na Figura 3.

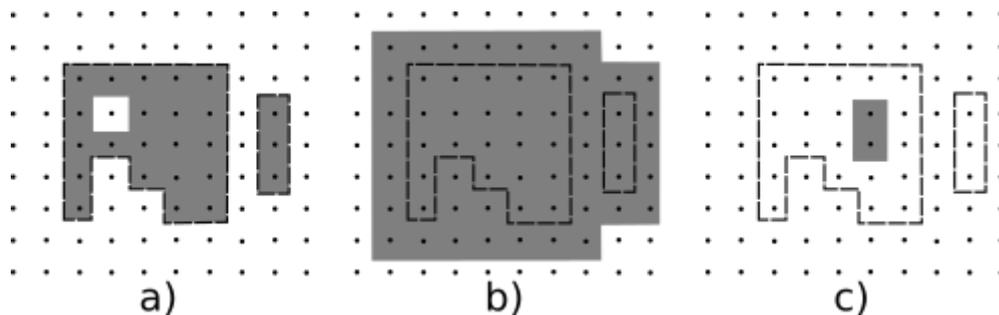


Figura 3: Operações de dilatação e erosão. a) imagem de entrada. b) imagem dilatada. c) Imagem erodida.

A dilatação é uma união de deslocamento, ela expande as bordas, buracos pequenos são eliminados conectando objetos próximos. A erosão combina dois conjuntos usando vetor de subtração, ela remove parte da borda dos objetos separando objetos conectados. O efeito visual na imagem obtido pela combinação da erosão e dilatação, é a remoção de ruídos e fechamento de buracos.

2.7 Processamento de vídeo

Um vídeo é composto por uma sequência de imagens coletadas em um intervalo de tempo, possibilitando representar a sensação de movimento. As técnicas de análise de vídeo, além do processamento de imagem convencional, caracterizam-se pela extração

de informação temporal e compreensão de contexto. A dinâmica de movimento pode ser modelada por equações matemáticas acionando informações possibilitando resultado mais confiável do que se obteria apenas com imagem estática.

2.8 Subtração de plano de fundo

Considerando que o dispositivo de captura seja estacionário, o plano de fundo é formado pelos pixels com valores constantes na imagem ao longo do tempo. Porém, existem ruídos originados por variação luminosa que causam pequenas mudanças no valor dos pixels. Os algoritmos de subtração de plano de fundo visam filtrar esses tipos de ruído mapeando na imagem os pixels que representam os objetos em movimento (Zivkovic ,2004). Sagi (2016) propôs o modelo CNT (CouNT). Este algoritmo, basicamente, conta os quadros do vídeo de que um pixel fica sem alteração e utiliza essa informação como uma limitação para decidir se um pixel é fundo ou não.

3 REFERÊNCIAS

- ALMEIDA, D. O.; OLIVEIRA, L. L. G.: Métodos de visão computacional aplicado a extração de características em ambientes urbanos em imagens de satélite de baixa resolução. **Universidade Federal de Goiás**. Dissertação. 2018.
- BAI, X.; WANG, X.; LIU, X.; et al. Explainable deep learning for efficient and robust pattern recognition: A survey of recent developments. **Pattern Recognition**, 120, 108102. <https://doi.org/10.1016/J.PATCOG.2021.108102>. 2021.
- BANON, G. J. F.; BARRERA, J.; Bases da Morfologia Matemática para análise de imagens binárias. 2.ed. **São José dos Campos**: INPE. 1998
- CHEN, Q.; LI, G.; XIE, L.; XIAO, Q., XIAO, M.: Structure guided image completion using texture synthesis and region segmentation. **Optik**, 185, 896–909. doi:10.1016/j.ijleo.2019.04.028. 2019.
- CHIMIEL, M.; SLOWINSKI, M.; DASIEWICZ, K.: Application of computer vision systems for estimation of fat content in poultry meat. **Food Control**, 22, 1424-1427. 2011. Doi:10.1016/j.foodcont.2011.03.002
- CROSS, H. R.; GLILLILAND, D. A.; DURLAND, P. R.; SEIDEMAN, S.: Beef carcass evaluation by use of a video image analysis system. **Journal of Animal Science**, 57, 908-917. 1983.

- DAVENPORT, T. H.; PRUSAK, L. Conhecimento Empresarial; como as organizações gerenciam o seu capital intelectual. Rio de Janeiro: Campus, 1998. 237p.
- WADHAWAN, A.; KUMAR, P.: Deep learning-based sign language recognition system for static signs. **Neural Comput & Applic** 32, 7957-7968. 2020. doi.org/10.1007/s00521-019-04691-y
- EINARSSON, E.; EYTHORSDDOTTIR, E.; SMITH, C. R.; VIDAE, J. J.: Genetic parameters for lamb carcass traits assessed by video image analysis, EUROP classification and in vivo measurements. **Icelandic Agricultural Sciences**, 28, 3-14. 2015. doi.org/10.16886/IAS.2015.01.
- GARCÍA, R.; AGUILAR, J.; TORO, M.; PINTO, A.; RODRÍGUEZ, P.: A systematic literature review on the use of machine learning in precision livestock farming. **Computers and Electronics in Agriculture**, 179, 105826. doi:10.1016/j.compag.2020.105826. 2020.
- IMA – Instituto Mineiro de Agropecuária. Seleção por ultra-sonografia de carcaça melhora rendimento frigorífico: A baixa remuneração da carne bovina no Brasil ainda é um problema frequente. **Clipping electronica**. Belo Horizonte. 2010.
- LAWRIE, R.A. Ciência da carne. Tradução: Jane Maria Rubensam. 6 ed. Artimed: Porto Alegre, 2005.
- Li, X. Chen, H.; Qi, X.; Dou, Q.; Fu, C. W.; Heng, P, A.: H-DenseUNet: Hybrid Densely Connected UNet for Liver and Tumor Segmentation from CT Volumes. **IEEE Transactions on Medical Imaging**, 1–1. doi:10.1109/tmi.2018.2845918. 2018.
- LUCIANE, V.; FLORIANI, V.; VARVAKIS, G.: Gerenciamento do fluxo de informação como suporte ao processo de tomada de decisão: revisão. **Informação & Informação**. 15. 85-103. 10.5433/1981-8920.2010v15n1p85. 2010.
- MANDARINO, R. A., BARBOSA, F. A., LOPES, L. B., TELLES, V., FLORENCE, E. DE A. S., & BICALHO, F. L.: Evaluation of good agricultural practices and sustainability indicators in livestock systems under tropical conditions. **Agricultural Systems**, 174, 32–38. doi:10.1016/j.agsy.2019.04.006. 2019.
- NEVES K.A.L.; XIMENES T.; MARTINEZ G. B.; A pecuária na Amazônia: a busca por um modelo sustentável. **papers do naea n° 330**. ISSN 15169111. 2014.
- YANG, S.; LUO, P.; LOY, C. C.; TANG, X.: From Facial Parts Responses to Face Detection: A Deep Learning Approach. **Computer Vision and Pattern Recognition** arXiv:1509.06451v1. 2015.
- PABIOU, T.; FIKSE, W. F.; CROMIE, A. R.; KEANE, M. G.; NASHOLM, A.; BERRY, D. P.: Use of digital images to predict carcass cut yields in cattle. **Livestock Science**, 137, 130-140. 2011.

- PEREIRA, A.S.C.; GUEDES, C.: Tipificação de carcaça e seus benefícios. **Boletim Técnico Serrana**, São Paulo, out. 2004.
- RONNEBERGER, O.; FISCHER, P.; BROX, T.: U-Net: Convolutional Networks for Biomedical Image Segmentation. Computer Science Department and BIOS Centre for Biological Signalling Studies **University of Freiburg**, Germany. arXiv:1505.04597v1. 2015.
- RIBAS, M. N.; CAVALCANTI, L. F. L.; MACHADO, F. A.; PAIVA, C. A. V.; PEREIRA, L. G. R.: Pecuária de Precisão: Uso de tecnologias para apoio à tomada de decisão. 2017.
- RICARDO, H.A. Resfriamento de carcaças de ruminantes. **PUBVET**, Londrina, V. 4, N. 9, Ed. 114, Art. 770, 2010.
- RIVAROLI, D. C.; ORNAGHI, M. G.; MOTTIN, C. PRADO, R. M.; RAMOS, T. R.: Guerrero, A., Jorge, A. M. & Prado, I. N. 2017. Essential oils in the diet of crossbred (½ Angus vs. ½ Nellore) bulls finished in feedlot on animal performance, feed efficiency and carcass characteristics. **Journal of Agricultural Science**, 9, 205-212. 2017.
- SILVA, M. J. F. B.; LINS, L. F.; LINS, N. B. O.; SIQUEIRA, G. F. M.; et al. Avaliação de carcaça bovina: uma revisão sobre o uso de ultrassom. **Medicina veterinária (UFRPE)** ISSN 1809-4678. 2018
- TANG, P.; LIANG, Q.; YAN, X.; XIANG, S.; SUN, W.; ZHANG, D.; COPPOLA, G. Efficient Skin Lesion Segmentation Using Separable-Unet with Stochastic Weight Averaging. **Computer Methods and Programs in Biomedicine**. doi:10.1016/j.cmpb.2019.07.005. 2019.
- KASHIHA, M.; BAHR, C.; OTT, S.; MOONS, C. P. H.; NIEWOLD, T. A., ÖDBERG, F. O.; BERCKMANS, D.: Automatic weight estimation of individual pigs using image analysis. **Computers and Electronics in Agriculture**, 107, 38-44. 2014.
- SANTOS, A. C. P.; SILVA, B. C. D.; OLIVEIRA, V. S.; VALENÇA, R. L.: Métodos de avaliação de carcaça e de carne dos animais através de predições in vivo e post mortem - revisão de literatura. **Revista científica de medicina veterinária**. 2018.
- SAGI, Z.: BackgroundSubtractorCNT: A Fast Background Subtraction Algorithm (Version 1.1.4). Zenodo. 2016. <http://doi.org/10.5281/zenodo.4267853>
- STINGA L.; BOZZO G.; FICCO G.; et al. Classification of bovine carcasses: New biometric remote sensing tools. **Italian journal of food safety**, 9(3), 8645. <https://doi.org/10.4081/ijfs.2020.8645>. (2020).
- ZIVKOVIC Z. Improved adaptive Gaussian mixture model for background subtraction. **Proceedings of the 17th International Conference on Pattern Recognition**. ICPR. doi:10.1109/icpr.2004.1333992. 2004.

CAPÍTULO 1 – DETERMINAÇÃO DO PERCENTUAL DE COBERTURA DE GORDURA EM CARCAÇAS BOVINAS USANDO VISÃO COMPUTACIONAL

1 INTRODUÇÃO

A carne bovina é uma das principais fontes de proteína animal para os seres humanos. Dentre as características almejadas pelos consumidores estão: suculência, maciez, sabor e cor atraente (Osullivan et al, 2003, Caridade et al, 2020). Com o mercado acirrado, as boas práticas para promover a qualidade da carne e o desenvolvimento sustentável da cadeia pecuária são fundamentais para manter a bovinocultura de corte bem-sucedida. Não só os consumidores brasileiros têm exigido altos padrões de qualidade e diversificação de cortes, mercados como o europeu e asiático tem influenciado na adoção de sistemas de produção mais competitivos e engajados com as questões ambientais.

Em relação à qualidade da carne, alguns parâmetros são atualmente utilizados para avaliar carcaça bovina *in vivo*, como a espessura de gordura subcutânea, a área de olho de lombo e a gordura de marmoreio. Os padrões podem ser medidos por ultrassom, sendo esses os principais indicadores de acabamento de carcaça (Silva et, al. 2011, Caridade et al, 2020; Iglesia et al, 2020). No entanto, a avaliação individualizada é inviável para a maioria dos frigoríficos devido ao significativo número de animais, bem com o tempo e recursos dispendidos, restando apenas métodos empíricos para avaliar o acabamento.

Por outro lado, o uso de tecnologia baseada em visão computacional e processamento de imagem, tem se mostrado bastante eficaz no processo de automação de rotina de inspeção (Spencer et al, 2019, Rajan et al. 2021). Grandes produtores de carne bovina como Austrália e EUA fazem uso intensivo de métodos computacionais para avaliação de carcaça, esses mesmos países são os que comercializam os melhores

produtos com preços superiores aos praticados no Brasil (Silva, et al, 2011). Com base nesse cenário de modernização da bovinocultura de corte e na expressiva produção de carne bovina no Brasil, existe uma necessidade de parametrizar e viabilizar processos de avaliação de carcaças com base em métodos mais eficientes.

Nesse estudo foi proposto um sistema não invasivo, para avaliar a cobertura de gordura de carcaças de novilhas e vacas utilizando imagens e posteriormente verificar a relação da cobertura de gordura com os métodos de classificação de carcaça por acabamento.

2 MATERIAL E MÉTODOS

2.1 Localização

O experimento foi conduzido com o apoio da Embrapa Agrossilvipastoril, localizada no município de Sinop, Mato Grosso, Brasil. Os dados foram coletados em um frigorífico também localizado em Sinop, com o auxílio e supervisão do serviço de inspeção local. As coletas ocorreram entre outubro de 2020 e julho de 2021. O período abrangeu o final da estação seca e o início da estação chuvosa segundo as características climáticas do estado de Mato Grosso.

Os animais abatidos foram trazidos de propriedades rurais situadas na região médio-norte do Mato Grosso, vindo de Alta Floresta, Juara, Guarantã do norte, Itaúbas, Juara, Marcelândia, Nova Santa Helena, Novo Horizonte do norte, Sorriso, Terra Nova e Vera, conforme demonstra o mapa na Figura 1.

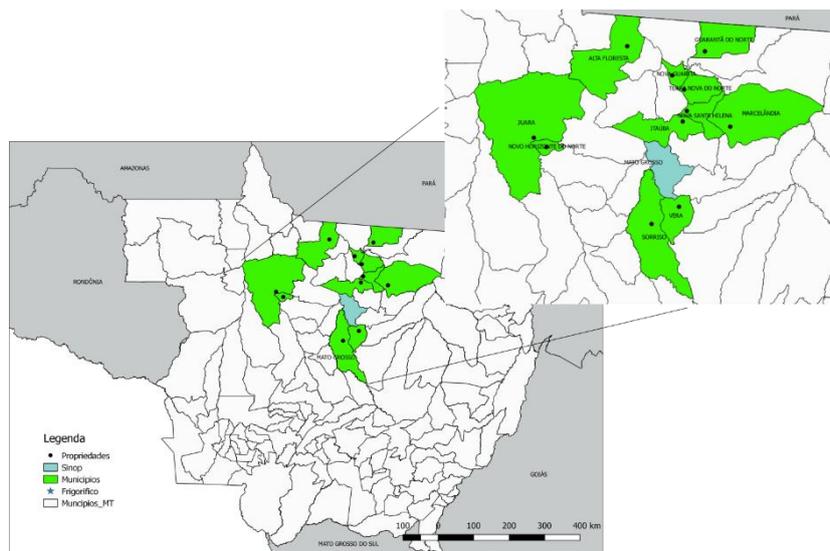


Figura 1. Mapa da região do estado de Mato Grosso Brasil de onde tiveram origem os animais analisados neste estudo.

Foram amostradas 1.200 imagens do lado esquerdo das meia carcaças, das quais 166 eram de machos, 511 de vacas e 523 de novilhas. Nesse trabalho foram avaliadas somente as fêmeas, pois existe diferença para avaliação de acabamento para carcaça de machos. As carcaças das novilhas e das vacas apresentaram 220 Kg em média com variação de 35 kg.

2.2 Coleta de dados

Uma câmera Intelbras VIP 3220D foi instalada no local onde está localizada a balança eletrônica destinada à pesagem das carcaças (Figura 2). Este ponto foi escolhido por ser o local onde as carcaças receberam a etiqueta de identificação individual. Por meio destas etiquetas, foi possível consultar informações adicionais no sistema do frigorífico como: peso, origem e o resultado da classificação visual com base no acabamento.

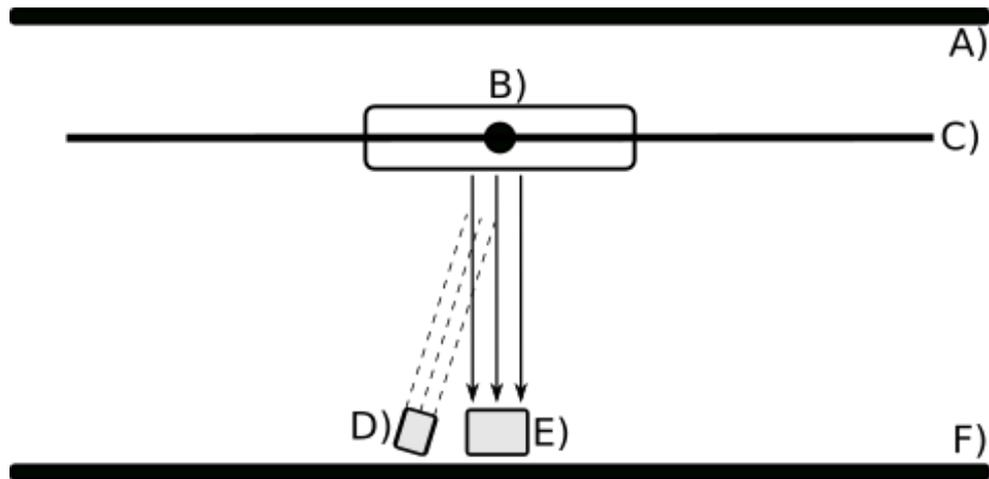


Figura 2. Configuração do experimento associado a linha de abate do frigorífico com ênfase na câmera Intelbras VIP 3220D instalada na parede paralela a linha de abate com distância aproximada de 2.5m das carcaças. A) parede no fundo, B) balança, C) trilho por onde foram deslocadas as carcaças, D) refletor, E) câmera fixada na parede, F) parede.

2.4 Processamento de vídeo

Foi proposto um *pipeline* de visão computacional para estimar o percentual de cobertura de gordura em carcaças bovinas. O processo foi dividido em três etapas. Na primeira fase, foi realizado um processamento de vídeo para identificar e selecionar corretamente uma imagem contendo apenas a carcaça de interesse. Na segunda parte, foi realizado o pré-processamento e a segmentação para remoção do fundo da imagem. Finalmente, na terceira fase foram classificados os pixels da imagem selecionada determinando o percentual de cobertura de gordura da carcaça.

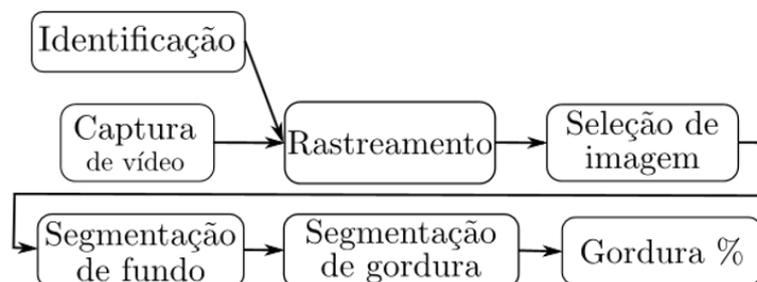


Figura 3. Sequência de processamento do vídeo para cálculo de percentual de gordura.

Os vídeos foram capturados utilizando uma câmera Intelbras VIP 3220D, com taxa de amostragem de 10 quadros por segundo em resolução HD 1080 x 1920, com

padrão de compressão h.264. Os parâmetros de brilho, contraste, saturação, nitidez e *gamma* foram mantidos em 50%. Para melhorar as condições de iluminação ambiente foi instalado um refletor ao lado da câmera. O sistema utilizou sensores de imagens convencionais facilmente encontrados no mercado, com processo de instalação simples, podendo ser integrados na rotina de abatedouros.

Para associar as carcaças no vídeo com os dados no sistema do frigorífico, foi considerada a sequência de abate em conjunto com a comparação do horário da pesagem que coincide com horário das filmagens. As rotinas desenvolvidas para detectar e rastrear as carcaças no vídeo são representadas na Figura 4.

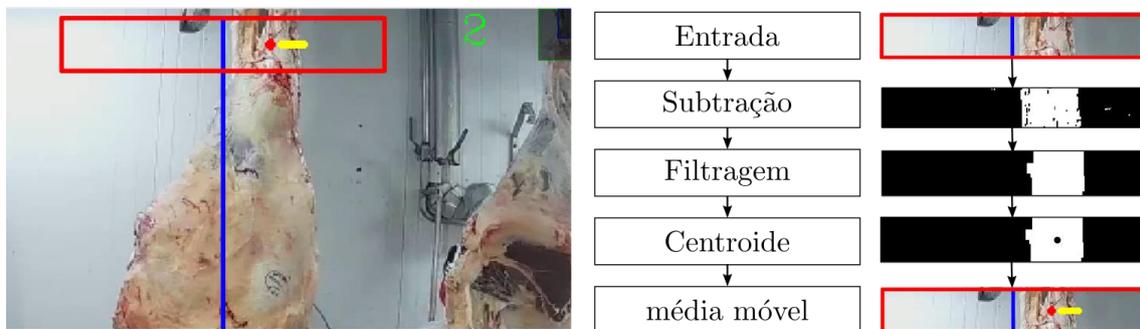


Figura 4 - Sequência de processamento em vídeo visando extrair as imagens relativas às carcaças de interesse.

O processamento foi executado apenas na região marcada com retângulo conforme a imagem acima. Primeiramente, foi aplicado o algoritmo de subtração de plano de fundo, no qual uma máscara é obtida contendo os pixels em movimento no vídeo (Zivkovic, 2004). Em seguida, são aplicadas duas transformações morfológicas de abertura e fechamento para remoção de ruídos. Posteriormente, é calculado o centro geométrico da região de maior área da máscara, este centroide é a posição da carcaça no vídeo (Banon, et al, 1998).

Durante a movimentação das carcaças na linha de abate, ocorreram oscilações no centroide detectado, resultando em contagem duplicadas ou falha na contagem. Por essa razão foi calculada a da média móvel do centroide. Para detectar o cruzamento pela linha

e efetuar a contagem, foi implementado uma fila contendo as informações das últimas 20 médias móveis, assim uma comparação entre a posição da linha e as extremidades da fila é realizada para detectar um cruzamento, conforme ilustra a figura 5.

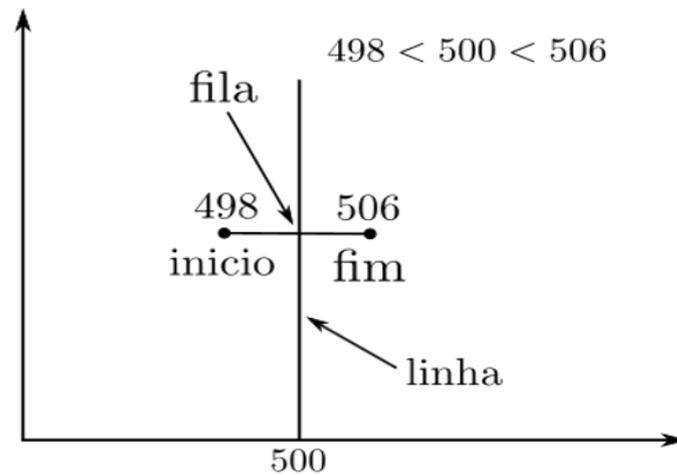


Figura 5. Detecção do cruzamento da linha de referência para contagem da carcaça de interesse.

Após detectado um cruzamento, um temporizador é acionado, desabilitando a contagem por 60 quadros para evitar contagem duplicadas. Como foram utilizadas apenas imagens da metade esquerda das carcaças, apenas a contagem ímpar disparou uma captura da imagem. As imagens recortadas/extraídas dos vídeos foram salvas no formato JPEG, com resolução 400x1080.

Para obter a hora exata da captura de imagem e identificar a carcaça na base de dados do frigorífico, foi projetado um sistema de reconhecimento ótico de caracteres (OCR) e treinado para ler a hora impressa na imagem.

2.5 Segmentação de fundo

Uma vez que as imagens foram identificadas e individualizadas, foram separadas 170 imagens de meia carcaça de forma aleatória para treinar o modelo de segmentação de plano de fundo. Este percentual de imagens representou 16.5 % do total novilhas. As

máscaras para segmentação foram criadas manualmente utilizando a aplicação Web da VIA Annotation (Dutta, 2019). As anotações foram exportadas no formato texto (CSV) e posteriormente criada as máscaras (Figura 6).

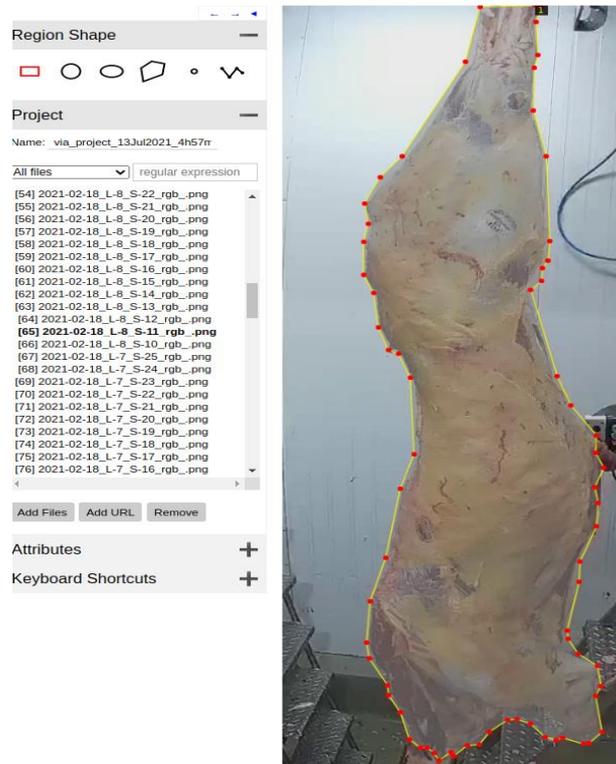


Figura 6 – Ferramenta para anotação de imagens (criação das máscaras para segmentação). Os pontos em vermelho delimitam a região da imagem de interesse, as partes externas são consideradas como parte do plano de fundo.

A arquitetura de rede neural U-net foi treinada para realizar a segmentação de plano de fundo (Ronneberger, 2015). A razão para escolha desse modelo foi devido a tarefa de segmentar manualmente grande quantidade de amostras ser custosa e também devido à complexidade do problema. Do modelo original, foi adicionado normalização por blocos, habilitado preenchimento de borda e alterado as dimensões das camadas para ajustar o tamanho da entrada para 400x1072x3. A divisão das imagens em treinamento e teste foi realizada usando a função *train_test_split* do *sklearn*. A U-net foi treinada no ambiente Google colab (<https://colab.research.google.com/>) por 500 épocas (ciclos de treinamento).

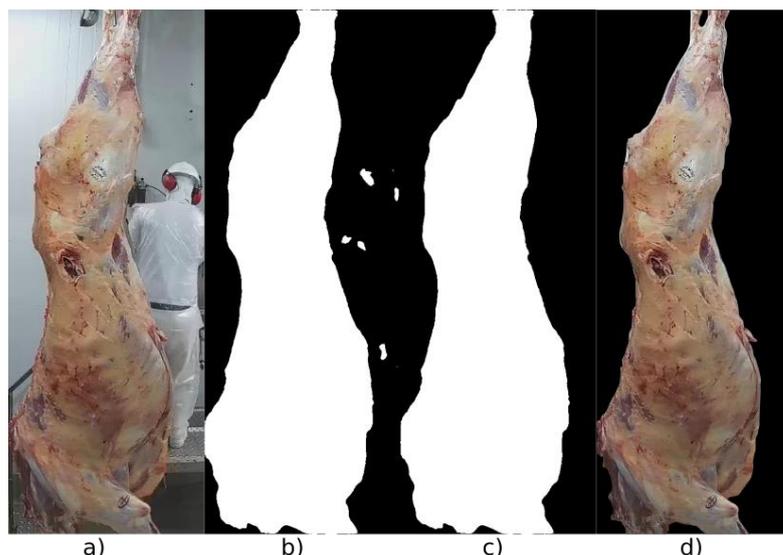


Figura 7. Etapas para a construção do banco de imagens. a) Imagem de entrada. b) Máscara predita pela U-net, c) Mascara filtrada. d) Imagem segmentada com auxílio da máscara filtrada.

Após a obtenção da máscara foi aplicado um filtro para remover partes com áreas pequenas, seguido de uma transformação morfológica de fechamento (Banon et al, 1998). As máscaras processadas foram salvas em uma pasta separada, no formato JPEG.

2.6 Segmentação de gordura

Além da remoção do fundo nas imagens, foi necessária uma segunda segmentação para identificar quais pixels que representam mapear as regiões da imagem em: gordura, carne ou tecido conjuntivo. Para tal objetivo, foram comparados dois classificadores e, posteriormente realizada a análise e identificação daquele com melhor eficácia. Os classificadores foram: a) uma máquina de vetor de suporte (SVM); b) uma rede neural (RNA), ambos os modelos utilizaram uma janela deslizante. Esse método abordou um problema de segmentação como classificação, no qual a imagem é cortada ou dividida em pequenos blocos. Em cada um desses blocos, o classificador foi usado para prever sua respectiva classe, conforme mostrado na Figura 8.

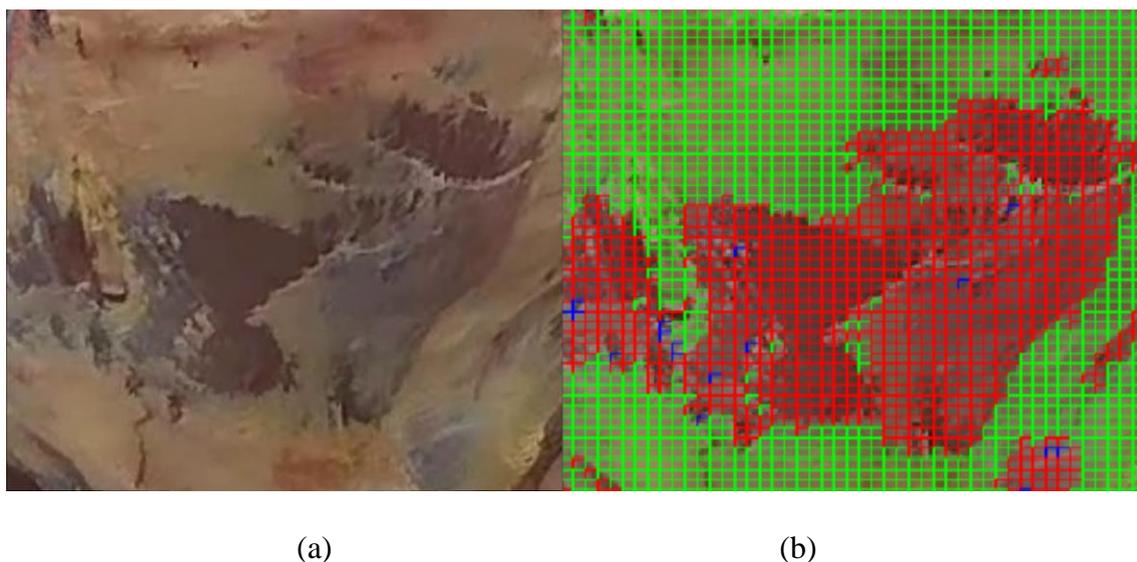


Figura 8 – Processo de segmentação de carcaça, (a) Imagem de entrada (b). imagem particionada em blocos como resultado da etapa de segmentação. Os retângulos em verde foram classificados com cobertura de gordura, os vermelhos representam a carne e os em azul o tecido conjuntivo.

Foram rotuladas amostras de janelas com dimensão de 10x10 pixels, onde os classificadores foram treinados e aplicados em um conjunto de imagens aleatórias. Posteriormente, uma análise visual foi realizada visando identificar padrões característicos dos blocos classificados incorretamente. Posteriormente, uma nova amostragem foi realizada para inserir ao modelo informações acerca dos erros cometidos, ao todo foram utilizados 444 blocos para treino e 174 para validação.

2.7 Classificação pelos avaliadores

A portaria de 2004 apresenta o método de avaliação de acabamento de carcaça utilizando uma medida de espessura de gordura. Entretanto, os frigoríficos raramente adotam esses métodos pelo tempo e custo de execução. Sendo assim, neste estudo foram convidados avaliadores já treinados na avaliação de carcaça de forma visual. A estes avaliadores foram pedidos que comparassem a carcaças selecionadas com uma carcaça de referência. Nessa primeira etapa foram avaliadas 350 carcaças por 4 especialistas com o objetivo de verificar a consistência do método, para então prosseguir com a avaliação

das carcaças restantes. Uma aplicação de computador foi construída para auxiliar nas avaliações, as imagens usadas como referência para comparação foram postas ao lado da carcaça para auxiliar os avaliadores, como visualizado na Figura 9.

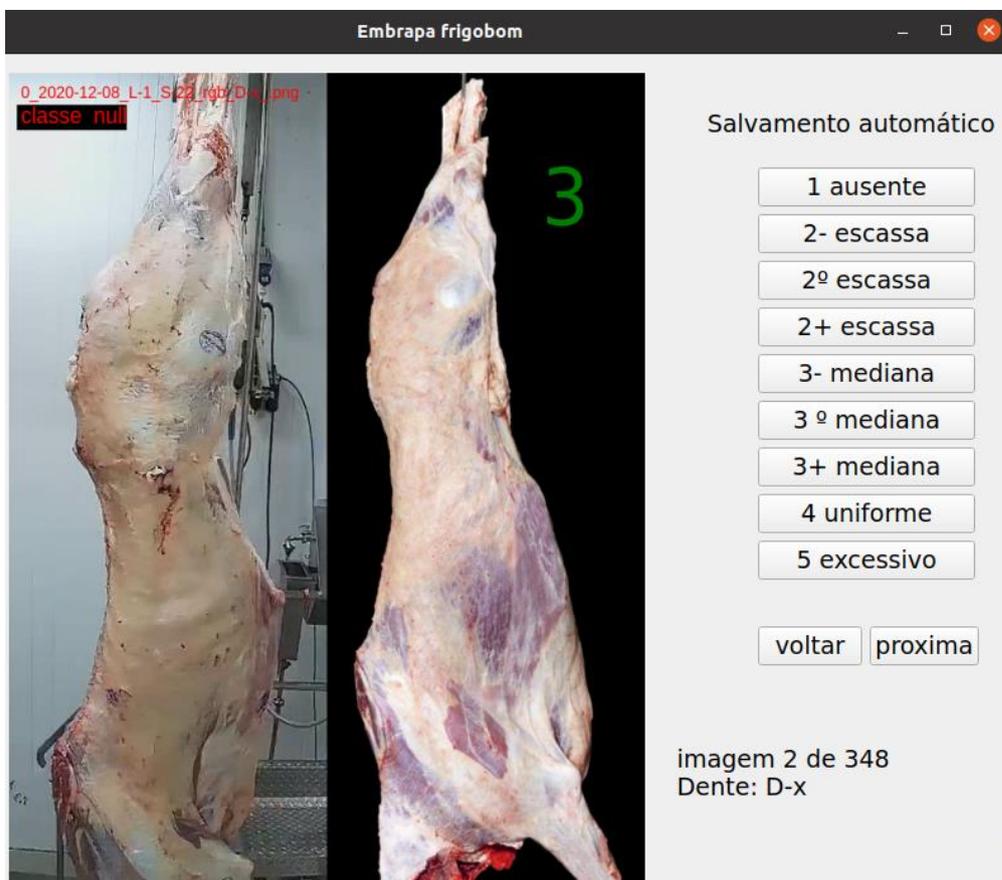


Figura 9. Interface da ferramenta computacional desenvolvida neste estudo para auxiliar para os técnicos na etapa de classificação das carcaças segundo o padrão SEUROOP com inserção de classes intermediária.

Para cada classe de acabamento foi criado um botão para registro da classificação do avaliador. As imagens foram embaralhadas aleatoriamente considerando o percentual de cobertura de gordura. Todavia, os avaliadores receberam as imagens na mesma ordem das imagens para o processamento.

2.8 Classificação pelo frigorífico

O frigorífico em questão não realiza exportação, nesse caso, a classificação não é de caráter obrigatório. Portanto, uma classificação parcial das carcaças é realizada,

simplificando o método de classificação de acordo com as próprias diretrizes do frigorífico, avaliando em três níveis de acabamento, onde as classes são: PADRÃO (escore=3,4), DESUNIFORME (escore=2) e SEM COBERTURA (escore= 1). Buscando atender sua demanda, foi proposto um modelo Convolutacional Neural Network - CNN para realizar essa atividade.

Nesse estudo foram utilizadas 1.034 imagens de meia carcaça. As imagens foram divididas em bloco de 25% para validação e 75% para treinamento. O modelo foi treinado no ambiente Google colab por 350 épocas.

2.9 Análise estatística

Para avaliação da U-net, usada na etapa de segmentação do plano de fundo, foi utilizado o coeficiente de similaridade de Jaccard, ou *Intersection over Union* (IoU) (Jaccard, 1912). Essa métrica avalia a correspondência entre duas regiões, descrito como uma medida de sobreposição pela união das áreas. Seu valor varia entre 0 e 1 onde, o valor 0 não existe correspondência entre as regiões e 1 as regiões são idênticas. O IoU é definido pela equação (Rahman, 2016).

$$IoU = \frac{PT}{FN + TP + FP}$$

Onde,

TP positivas classificadas como positiva (True Positive - TP)

FP negativas classificadas como positivas (False Positive -FP)

FN positivas classificadas como negativas (False negative - FN)

Visando confrontar os resultados do modelo SVM de RNA usados para a segmentação da região da carcaça em gordura, carne e tecido conjuntivo, foram calculadas a precisão, recuperação e *F-I score*. A precisão e recuperação são importantes

para avaliar modelos de classificação pois fornece uma métrica individual por classe. A precisão é a capacidade do modelo de não classificar como positiva uma amostra negativa, já a recuperação é a capacidade do modelo em encontrar todas as amostras positivas. O *F-1 score* é uma média harmônica ponderada entre a precisão e a recuperação (Fawcett, 2006). Ambos representados pelas equações.

$$precisão = \frac{TP}{TP + FP}$$

$$recuperação = \frac{TP}{P}$$

$$f1score = \frac{2}{1/precisão + 1/recuperação}$$

Onde:

TP positivas classificadas como positiva (True Positive - TP)

FP negativas classificado com positivas (False Positive -FP)

P = Total de amostras positivas.

Para comparar o grau de concordância entre os avaliadores do frigorífico foram calculados níveis de concordância Kappa, assumindo que pontuações acima de 0,8 são consideradas de boa concordância, zero ou menos significa nenhum acordo. O kappa é definido pela equação:

$$k = (p_o - p_e)/(1 - p_e)$$

Onde,

p_o É a razão de concordância observada.

p_e É a concordância esperada quando ambos classificadores atribuem rótulos aleatoriamente.

O Kappa normalmente é utilizado quando deseja comparar o nível de concordância entre dois avaliadores quando não se sabe a verdade fundamental, assim

ambos podem estar errados em uma amostra específica, mas o erro global pode ser diluído por conta da repetição da avaliação.

Para avaliar o modelo CNN proposto para estimar a classificação realizada pelo frigorífico foi utilizado a matriz de confusão. A matriz de confusão representa a relação de acertos e erros do modelo usando uma matriz de tabulação cruzada dos resultados preditos com as classes originais. Os resultados são presumidos em quatro situações possíveis.

- TP verdadeiro positivo (True Positive)
- FP falso positivo (False Positive)
- TN verdadeiro negativo (True negative)
- FN falso negativo (False negative)

3 RESULTADOS

3.1 Estimativa do percentual de cobertura da carcaça

A rede neural U-net treinada para segmentação de fundo da imagem atingiu um IoU médio de 0,96 ao segmentar 171 imagens. Os resultados para cada imagem segmentada estão mostrados no gráfico da figura 10.

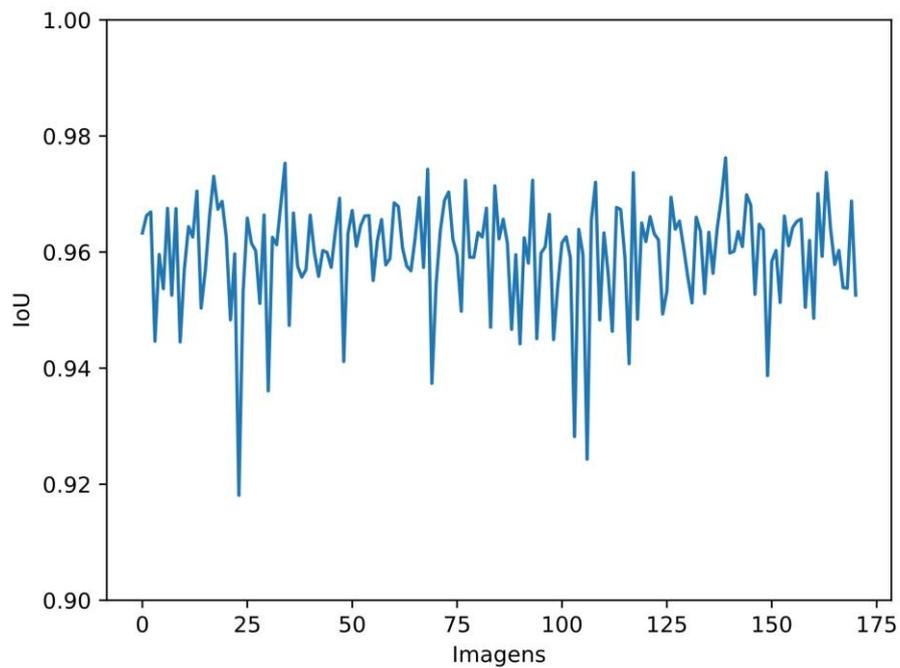


Figura 10 – Resultado da segmentação de 171 imagens com U-net e a métrica IoU calculada para cada imagem.

O processo de anotação manual para criar as mascas para treinamento e validação geralmente são acometidos por erros nas bordas das carcaças e o plano de fundo. Esse erro reflete no resultado da segmentação realizada pela U-net treinada.

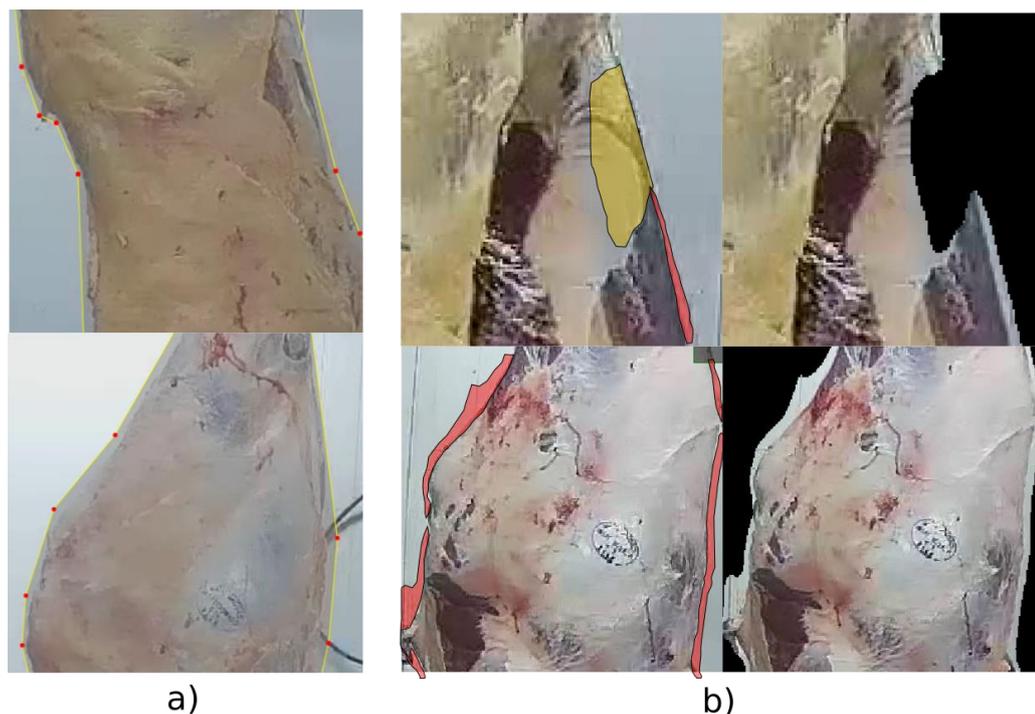


Figura 11: Efeito de erros de bordas do anotador sobre as predições realizadas pela U-net a) Imagens anotada manualmente, os pontos em vermelho delimitam a região marcada como carcaça pelo anotador b) Imagens segmentada pela rede U-net.

A precisão, recuperação e *F1-score* para os modelos propostos para segmentar as carcaças separando em gordura, carne e tecido conjuntivo estão apresentados na tabela 1.

Tabela 1 - Precisão, recuperação e F1-escore para os classificadores SVM e RNA usando janela 10x10.

Classificadores	Classes ¹	Precisão	Recuperação	F1-score	Suporte
SVM	Carne	1,00	0,80	0,94	60
	Gordura	0,97	0,97	0,97	60
	Tecido	0,85	0,96	0,90	54
RNA	Carne	1,00	0,98	0,99	60
	Gordura	0,98	0,98	0,98	60
	Tecido	0,98	1,00	0,99	54

¹As classes são representadas pelas regiões da carcaça com cobertura de gordura, carne e tecido conjuntivo.

Os modelos SVM e RNA apresentaram nível de concordância quase perfeito (Kappa=0,89). A principal diferença observada entre eles foi a performance. O classificador SVM atingiu 425FPS (quadros por segundo - FPS) enquanto a RNA obteve

10FPS. O método de segmentação apresentado foi aplicado na imagem representadas pela Figura 12 para segmentar regiões da carcaça cobertas por gordura, carne e tecido conjuntivo.

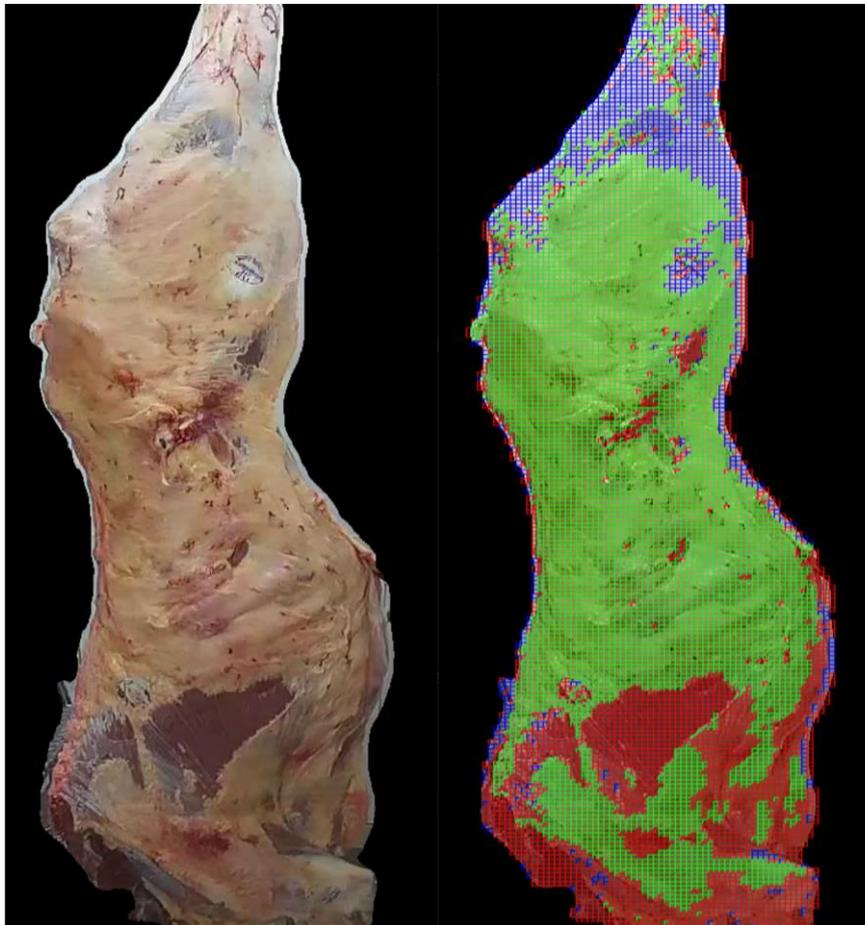


Figura 12 Exemplo de uma imagem segmentada: As áreas em verde, vermelho e azul são de cobertura de gordura, carne e tecido conjuntivo, respectivamente.

A carcaça em média foi particionada em 16.000 blocos 10x10 pixels. Os blocos da borda que contem resíduo do fundo da imagem representam apenas 2 porcentos do total de blocos.

3.2 Classificação pelo frigorífico

Na Figura 13 é possível observar que a classe desuniforme e sem cobertura não apresentou diferença de média significativa, porém a variação para classe sem cobertura é maior.

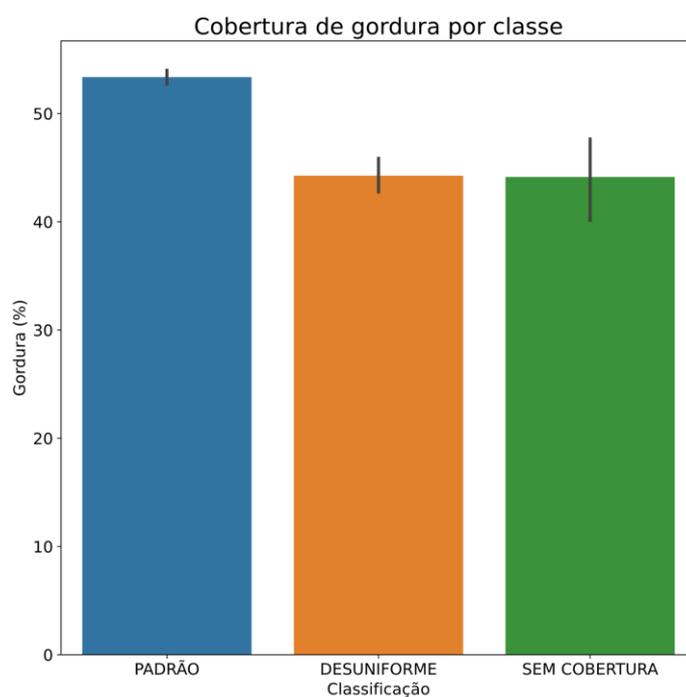


Figura13: Percentual de cobertura de gordura por classificação por acabamento.

O percentual de gordura, carne e tecido conjuntivo produzido pelo SVM não apresentou correlação significativa com a classificação realizada pelo frigorífico ($R^2 = 0,3$). As correlações negativas de carne e tecido conjuntivo com a gordura foi devido ao cálculo de porcentagem ser normalizado pela cobertura total da carcaça.

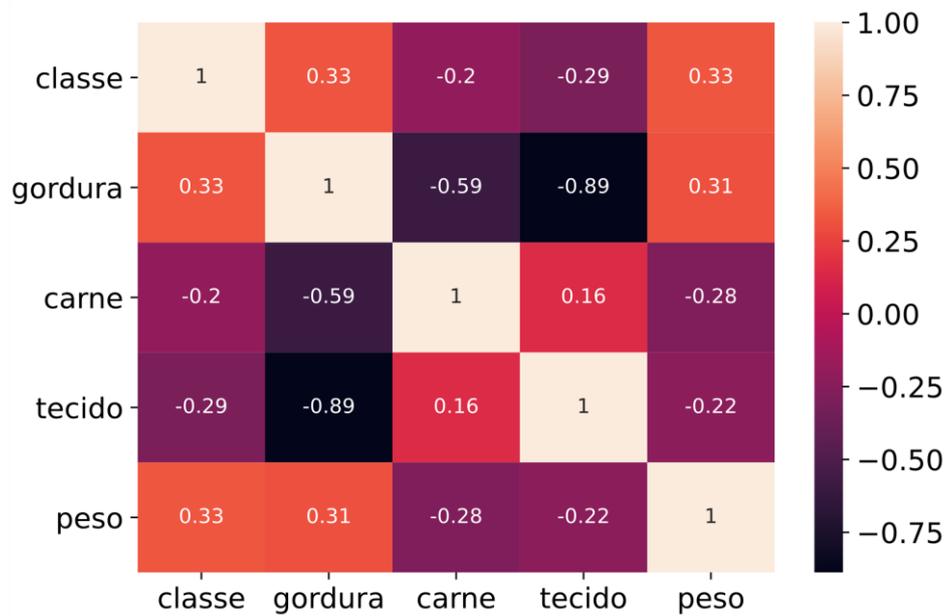


Figura 14 Correlação entre as características, gordura, carne e tecido por classe realizada utilizando o método computacional

Já o método de classificação usando CNN conseguiu extrair atributos que vão além da cobertura de gordura da carcaça. O modelo de CNN proposto para realizar a classificação alcançou 0,82 de acurácia. Os erros cometidos são proporcionais a quantidade de imagem por classe. Na amostragem realizada neste estudo foi difícil obter um número similar de imagens por classe. Por exemplo, mais de 70% dos animais abatidos no Frigorífico são classificados como padrão.

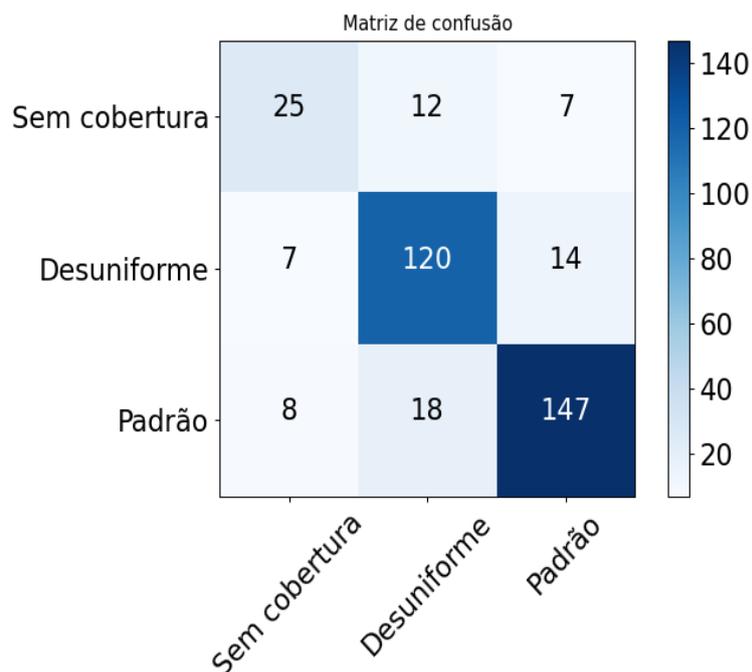


Figura 15. Matriz de confusão das imagens classificadas utilizando o classificador CNN.

3.3 Comparação das avaliações entre os técnicos.

Não foi encontrado concordância entre as avaliações realizadas pelos 4 especialistas ao classificar as 350 ($kappa < 0,3$). Essas discrepâncias aconteceram em critério de avaliações diferentes, isso porque a correlação com o percentual de cobertura de gordura é muito próxima para os avaliadores AV1, AV2 e AV4 mais diverge para o AV3.

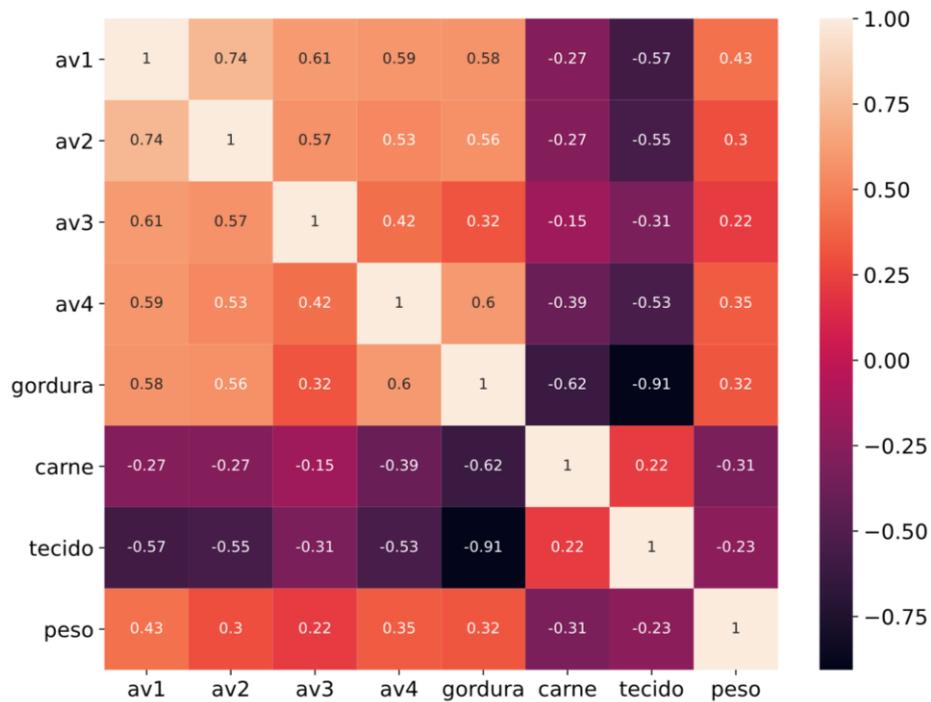


Figura 16. Correlação entre os avaliadores, peso e cobertura da carcaça

A Figura 17 mostra a relações entre os avaliadores, o raio representa o total de carcaça classificada para cada classe que é distribuída ao redor do círculo. O gráfico deslocado para o sentido horário são avaliações mais criteriosa com penalização maior (AV4). Quando deslocado no sentido anti-horário são menos criteriosos (AV3). Ao selecionar as carcaças para avaliação pelos técnicos buscamos contemplar todos os níveis. Porém, nem uma carcaça foi classificada com uniforme e excessivo (score 4 e 5), a classe escassa (score 2º) foi a mais consistente e a maioria foi classificado como mediana menos (score 3-) (Fig, 17).

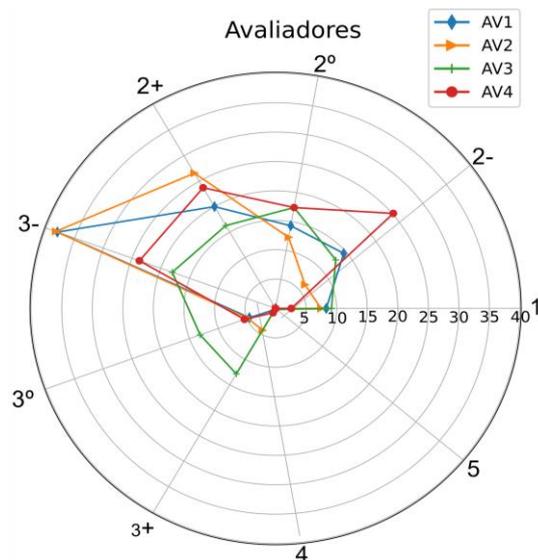


Figura 17. Gráfico com a Comparação de notas atribuídas entre os avaliadores para classificação das carcaças por acabamento. 1 (escassa) 2- (escassa menos) 2+ (escassa mais) 3- (mediana menos) 3° (mediana) 3+ (mediana mais) 4(uniforme) 5 (excessivo),

4 DISCUSSÃO

4.1 Estimativa do percentual de cobertura da carcaça

Embora o processo de segmentação de plano de fundo usando a U-net apresentou excelente resultado (0.96 acurácia), é importante ressaltar que parte considerável do erro cometido é oriundo do processo de anotação. Isto ocorreu devido à dificuldade de marcar corretamente a carcaça na imagem por conta dos detalhes de bordas. Neste sentido, este trabalho enfatiza a importância de corrigir as anotações e aumentar o conjunto de imagem de treinamento para obter resultado consistente.

A arquitetura U-net é projetada para rodar em placa de vídeo dedicada, apresentando alto custo computacional quando executada em CPU (Ronneberger, 2015). Embora o intervalo de tempo entre carcaças de oito segundos seja suficiente para executar o algoritmo, a execução da U-net na CPU gerou picos de carga resultando em pequenos travamentos durante o processamento em tempo real.

Embora a rede U-net também possa realizar a segmentação da carcaça separando as regiões de gordura, carne e tecido conjuntivo, o processo de anotação da imagem inviabiliza sua aplicação, pois teria que avaliar pixel a pixel da imagem manualmente, nesse caso o método usado, dividindo a imagem em blocos reduz substancialmente o trabalho de anotação das imagens.

Um avaliador ao realizar a classificação por acabamento pondera pontos específicos para diferenciar algumas classes. Regiões como a maminha e ponta de agulha quando coberta indica bom acabamento de carcaça. Isso sugere que uma avaliação ponderada do percentual de cobertura de gordura pode melhorar a correlação com as classificações. Igllesia (2020) utiliza 16 pontos de referência na carcaça para dividir em 11 partes, seu método foi capaz de prever com 92% de precisão a avaliação realizada por seis avaliadores. Entretanto a construção de banco de imagens com anotação de pontos de referência aumenta consideravelmente o trabalho.

4.2 Classificação pelo frigorífico

Embora haja um consenso que a classificação realizada pelo Frigorífico em apenas três níveis não seja suficiente para descrever de forma satisfatória as diferenças entre as carcaças, muitos abatedouros costumam fazer adaptações dos métodos tradicionais de classificação para adequá-los as suas realidades. Essas alterações realizadas pelos abatedouros indicam que o número total de classes que minimizam a complexidade do problema não é conhecido.

O total de classes não é um problema muito discutido em projetos de algoritmos de classificação porque normalmente as classes são explícitas. Isso pode levar ao equívoco de que o aumento do total de classes, necessariamente aumentaria a complexidade do problema, sendo justificado pela diluição da probabilidade da predição

ao acaso. Entretanto a determinação equivocada do total de classes do problema tem um efeito muito maior. Ao utilizar redes neurais ou algoritmos de aprendizado baseado em minimização, a escolha errada do total de classes resulta em resíduo que impede a evolução do processo de aprendizado (Rolnick, 2018). Dessa forma, o modelo proposto nesse trabalho seria capaz de fornecer precisão superior se houvesse um acréscimo de classes.

Por outro lado, construir uma base de dados consolidada para treinar e validar modelos é um desafio. Estudos utilizando poucas amostras são comumente encontrados na literatura, (Craigie et al. 2012, Monteils et al. 2017, Stinga et al. 2020). A falta de mão de obra qualificada em conjunto com trabalho laborioso para realizar a classificação manual estão entre os principais fatores que leva a utilização de base de dados limitada. Entretanto, a utilização de poucas amostras para projetar modelos de *Deep Learning* complexos pode levar a métricas de erros não muito realistas (Barbedo 2018). Dessa forma, é imprescindível o acompanhamento por um especialista para validar as previsões do modelo e adotar rotinas de treinamento recursivo, até que as previsões sejam mais confiáveis.

4.3 Comparação das avaliações entre os técnicos.

A correlação próxima a 0,6 da classificação realizada realizado pelos especialistas com cobertura de gordura, é esperada, pois o método empregado avalia qualidade da cobertura. Entretanto, a diferença da correlação do avaliador AV3 indica que seu critério para avaliar o acabamento de carcaça foi diferente dos demais. Díez (2003) comparou dois grupos de carcaças onde foi observado efeito do método SEUROP quanto a conformação. Carcaças com grau mínimo de maturidade fisiológica são mais fáceis de aplicar o método SEUROP. As carcaças de animais abatido precocemente são classificadas com menos rigor do que as carcaças adultas. Segundo Stinga (2020) e Díez

(2203), as avaliações de conformação são mais complexas que a avaliação por acabamento, apontando como a principal razão das discordâncias entre seus avaliadores a conformação das carcaças.

Entretanto a conformação da carcaça é um critério com alto potencial de automação. Semelhante ao acabamento, a conformação pode ser realizada por sistemas de visão computacional. A principal limitação se dá de igual forma a construção de banco de imagens com anotação correta.

O índice Kappa usado para comparar os avaliadores é mais indicado do que as comparações baseadas em percentual de acerto, como aplicado no estudo de Craigie et al. (2012). O percentual de acerto é calculado em relação a uma classificação tomada como padrão ouro. Porém, assertividade não implica em concordância, por exemplo, caso dois avaliadores classificaram 10 carcaças, o primeiro acertou as sete primeiras avaliações, o segundo acertou as sete últimas, então eles atribuíram rótulos iguais para a carcaça 4,5,6 e 7, porém ambos apresentam a mesma acurácia individual de 70%. Além do mais, a probabilidade de que as classificações iguais tenham acontecido ao acaso é de 58%, então o resultado pode ser coincidência e não concordância. Por este motivo, o índice Kappa foi o mais adequado pois tratou esses problemas confrontando os avaliadores sem inferência a uma classificação tomada como a correta, normalizando assim o resultado em função da probabilidade ao acaso.

5 CONCLUSÃO

O uso de sistemas inteligentes, baseado em visão computacional, apresentou-se como uma ferramenta eficiente para automatizar processos de inspeção na indústria. Os resultados mostraram que é possível obter o percentual de cobertura de gordura usando visão computacional como alta precisão. Porém, usando apenas os índices de cobertura

da carcaça não é possível prever o seu grau de acabamento. A baixa concordância entre as avaliações realizadas pelos 4 técnicos ($kappa < 0,3$) reforça a dificuldade em construir modelos, a qual é influenciada pela presença de erro na classificação. Entretanto, como o principal resultado deste estudo, o modelo de CNN proposto para estimar a classificação em três níveis, padrão, desuniforme e sem cobertura realizado pelo frigorífico alcançou resultado satisfatório (0,82 acurácia), podendo então ser utilizado para realizar a classificação adotada pelo frigorífico. Todavia, utilizar a classificação por acabamento para tomar decisão relacionada aos benefícios da cobertura de gordura e sua importância do processo de resfriamento não é indicado, pois a correlação com o percentual de cobertura é muito baixa ($R^2 = 0,3$).

6 REFERÊNCIAS

- ABHISHEK D.; ANDREW Z.; The VIA Annotation Software for Images, Audio and Video. **In Proceedings of the 27th ACM International Conference on Multimedia (MM '19)**, October 21–25, 2019, Nice, France. ACM, New York, NY, USA, 4 pages. <https://doi.org/10.1145/3343031.3350535>. 2019.
- BANON, G. J. F.; BARRERA, J.; Bases da Morfologia Matemática para análise de imagens binárias. 2.ed. São José dos Campos: INPE. 1998.
- BARBEDO, J. G. A. Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification. **Computers and Electronics in Agriculture**, 153, 46–53. doi:10.1016/j.compag.2018.08.013. 2018.
- CARIDADE C.M.R.; PEREIRA C.D; PIRES A.F.; et al. Image analysis as a tool for beef grading, **Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization**, DOI: 10.1080/21681163.2020.1776159. 2020.
- CARIGIE, C. R.; NAVAJAS, R. W.; PURCHAS, C. A. et al.: A review of the development and use of video image analysis (VIA) for beef carcass evaluation as an alternative to the current EUROP system and other. **Meat science**. <https://doi.org/10.1016/j.meatsci.2012.05.028>. 2012.
- subjective systems
- DÍEZ, J.; BAHAMONDE, A.; ALONSO, J.; LÓPEZ, S.; Coz, J.; QUEVEDO, J.; GOVACHE, F.: Artificial intelligence techniques point out differences in classification performance between light and standard bovine carcasses. **Meat Science**, 64(3), 249–258. doi:10.1016/s0309-1740(02)00185-7. 2003.
- DUDA, R. O.; STORK, D. G.: Pattern classification. 2nd ed ed. New York: Wiley. 2001.
- DUTTA, A.; ZISSERMAN, A.: The VIA Annotation Software for Images, Audio and Video. **In Proceedings of the 27th ACM International Conference on Multimedia (MM '19)**, October 21–25, 2019, Nice, France. ACM, New York, NY, USA, 4 pages. <https://doi.org/10.1145/3343031.3350535>. 2019. 2019.
- IGLESIA D. H.; GONZÁLEZ G.V.; GARCÍA M.V.; et al. Non-invasive automatic beef carcass classification based on sensor network and image analysis, **Future Generation Computer Systems**, 113, p. 318–328. doi: 10.1016/j.future.2020.06.055. 2020.
- JACCARD P.; A distribuição da flora na zona alpina.1. *Novo fitologista*. 11 (2): 37–50. doi: 10.1111 / j.1469-8137.1912.tb05611.x . ISSN 0028-646X. 1912IMA 2010
- LAWRIE, R.A. Ciência da carne. Tradução: Jane Maria Rubensam. 6 ed. Artimed: Porto Alegre, 2005.
- MONTEILS, V.; SIBRA, C.; ELLIES-OURY, R.; BOTREAU, A.; et al. A set of indicators to better characterize beef carcasses at the slaughterhouse level in addition

to the EUROP system, Livestock Science, <http://dx.doi.org/10.1016/j.livsci.2017.05.017>. 2017.

- OSULLIVANA M.G.; BYRNEA D.V.; MARTENSA H.; et al. Evaluation of pork color: prediction of visual sensory quality of meat from instrumental and computer vision methods of color analysis. **Meat Science** 65(2), 909–918. doi:10.1016/s0309-1740(02)00298-x. 2003.
- RAJAN, A. J.; JAYAKRISHNA, K.; VIGNESH, T.; CHANDRADASS, J. KANNAN, T. T. M.: Development of computer vision for inspection of bolt using convolutional neural network, *Materials Today: Proceedings*, **materialstoday proceeding**. doi.org/10.1016/j.matpr.2021.01.372. 2021.
- RAHMAN, M. A.; WANGAN, Y; Optimizing Intersection-Over-Union in Deep, p. 234–244. doi: 10.1007/978-3-319-50835-1. 2016.
- ROLNICK, D.; VEIT, A.; BELONGIE, S.; SHAVIT, N.: Deep learning is robust to massive label noise. **Cornell university**. 2018.
- RONNEBERGER, O.; FISCHER, P.; BROX, T.: U-Net: Convolutional Networks for Biomedical Image Segmentation. **Computer Science Department and BIOS Centre for Biological Signalling Studies University of Freiburg, Germany**. arXiv:1505.04597v1. 2015.
- SILVA W.A.L.; POEHLAND R.; OLIVEIRA C.C.; et al. Shading effect on physiological parameters and in vitro embryo production of tropical adapted Nelore heifers in integrated crop-livestock-forest systems. **Tropical Animal Health and Production**, p. 1-9, 2020.
- SILVA, M.R. et al. Importância da deposição de gordura em bovinos de corte e sua mensuração através da técnica de ultrassonografia. **PUBVET, Londrina**, V. 5, N. 15, Ed. 162, Art. 1098, 2011.
- SPENCER, B. F.; HOSKERE, V.; NARAZAKI, Y. Advances in Computer Vision-Based Civil Infrastructure Inspection and Monitoring. **Engineering**. doi:10.1016/j.eng.2018.11.030. 2019.
- STINGA L.; BOZZO G.; FICCO G.; et al. Classification of bovine carcasses: New biometric remote sensing tools. **Italian journal of food safety**, 9(3), 8645. <https://doi.org/10.4081/ijfs.2020.8645>. 2020.
- ZIVKOVIC Z. Improved adaptive Gaussian mixture model for background subtraction. **Proceedings of the 17th International Conference on Pattern Recognition. ICPR**. doi:10.1109/icpr.2004.1333992. 2004.