

GUTIERREZ JOSÉ DE FREITAS ASSIS

**ANÁLISE DE IMAGENS NA CARACTERIZAÇÃO BIOMÉTRICA E AVALIAÇÃO
DA CARÇAÇA DE BOVINOS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Zootecnia, para obtenção do título de *Doctor Scientiae*.

Orientador: Mário Luiz Chizzotti

Coorientadores: Cristina Mattos Veloso
Sebastião de C. Valadares Filho

**VIÇOSA - MINAS GERAIS
2021**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

A848a
2021 Assis, Gutierrez José de Freitas, 1992-
Análise de imagens na caracterização biométrica e
avaliação da carcaça de bovinos / Gutierrez José de Freitas
Assis. – Viçosa, MG, 2021.
1 tese eletrônica (146 f.); il. (algumas color.).

Orientador: Mário Luiz Chizzotti.

Tese (doutorado) - Universidade Federal de Viçosa.

Inclui bibliografia.

DOI: <https://doi.org/10.47328/ufvbbt.2021.132>

Modo de acesso: World Wide Web.

1. Bovinos - Carcaças. 2. Gordura Subcutânea.
3. Biometria. 4. Processamento de imagens. 5. Redes neurais
(Computação). I. Universidade Federal de Viçosa. Departamento
de Zootecnia. Programa de Pós-Graduação em Zootecnia.
II. Título.

CDD 22. ed. 636.2

Bibliotecário(a) responsável: Renata de Fátima Alves CRB6/2578

GUTIERREZ JOSÉ DE FREITAS ASSIS

**ANÁLISE DE IMAGENS NA CARACTERIZAÇÃO BIOMÉTRICA E AVALIAÇÃO
DA CARÇA DE BOVINOS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Zootecnia, para obtenção do título de *Doctor Scientiae*.

APROVADA: 30 de julho de 2021.

Assentimento:


Gutierrez José de Freitas Assis
Autor


Mário Luiz Chizzotti
Orientador

Aos meus pais, irmãos e amigos.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter permitido que eu alcançasse mais esta vitória.

À Universidade Federal de Viçosa, e ao Departamento de Zootecnia-DZO, por proporcionar toda a estrutura necessária para o meu aprendizado e formação profissional.

A todos os professores do Departamento de Zootecnia, que contribuíram com minha formação acadêmica

Ao Professor Mário Luiz Chizzotti, pela amizade, ensinamentos e orientação durante o doutorado.

Aos funcionários do DZO, pela ajuda sempre que necessária.

Agradeço aos amigos, estagiários, bolsistas de iniciação científica e membros do Laboratório de Ciência da Carne (LCC), pela amizade, apoio e por todas as discussões que contribuíram para o desenvolvimento deste trabalho.

Aos meus pais, Ilidio e Eunice, que sempre estiveram ao meu lado me incentivando a novos desafios.

Aos meus irmãos, Débora e Joubert, que sempre me aturaram em meus momentos de estresse e dificuldade.

À empresa Intergado pela parceria e empréstimo dos sensores.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de estudos.

Por fim, meus sinceros agradecimentos a todos que participaram de maneira direta ou indireta da execução e conclusão deste trabalho. OBRIGADO!

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

RESUMO

ASSIS, Gutierrez José de Freitas, D.Sc., Universidade Federal de Viçosa, julho de 2021. **Análise de imagens na caracterização biométrica e avaliação da carcaça de bovinos**. Orientador: Mário Luiz Chizzotti. Coorientadores: Cristina Mattos Veloso e Sebastião de Campos Valadares Filho.

O processo de tipificação determina o mercado para o qual a carcaça será direcionada, considerando sua qualidade. Atualmente, este processo é desenvolvido de maneira subjetiva, e, portanto, a confiabilidade desse pode ser comprometida. Neste sentido, ferramentas que permitam a avaliação objetiva da carcaça bovina in vivo e post mortem são de grande importância. Diante disso, nossos objetivos neste trabalho são (1) avaliar o efeito da classe sexual sobre a morfologia corporal ou de carcaças em bovinos e investigar as relações entre as medidas biométricas e os escores de acabamento atribuídos às carcaças em frigorífico comercial, (2) desenvolver um algoritmo de segmentação utilizando rede neural convolucional, capaz de realizar a segregação de diferentes tecidos em imagens digitais de carcaças, de forma automática, e, (3) desenvolver equações de predição da espessura de gordura subcutânea em bovinos utilizando meta-análise de dados experimentais. Foram utilizados dados de animais de diferentes composições genéticas, classes sexuais, idades e pesos. Os animais foram aleatoriamente selecionados nos currais de espera dos frigoríficos, identificados, submetidos a jejum de sólidos durante 16 horas, pesados e, concomitantemente, foram coletadas imagens do dorso do animal utilizando câmeras RGB-D. Após o abate, a carcaça de cada animal foi dividida longitudinalmente, em duas meias-carcaças, as quais foram pesadas e os escores visuais de gordura avaliados por profissionais treinados, sendo as carcaças resfriadas a 4 °C por 24 horas. As meias-carcaças foram utilizadas para obtenção de imagens RGB-D. As imagens coletadas foram analisadas para mensuração dos parâmetros biométricos. Os dados foram analisados pelos procedimentos gerais de modelos lineares do SAS 9.0 (Statistical Analysis System Institute, Inc.) e, em seguida, as médias das diferentes classes sexuais foram comparadas pelo teste de Tukey (5%). Uma segunda etapa foi realizada utilizando as imagens coletadas como input para uma rede neural convolucional de segmentação (CNN). Na arquitetura da rede, o backbone

convolucional utilizado foi a rede ResNeXt-101 combinada com Feature Pyramid Network. Os resultados obtidos indicam que há influência da classe sexual sobre o peso corporal, peso de carcaça e medidas biométricas. Os escores de gordura foram influenciados por medidas biométricas. Houve efeito do peso corporal no escore final e os animais mais pesados obtiveram os maiores escores de gordura. Comportamento semelhante a este foi verificado para a análise das carcaças, com as maiores médias dos parâmetros biométricos observadas para o escore uniforme. Porém, não houve efeito linear entre o escore de gordura e as medidas biométricas, havendo sobreposição das médias para os menores escores atribuídos às carcaças. No segundo estudo, a rede CNN foi capaz de detectar a proporção de tecidos com uma precisão de 66,5, 42,4 e 11,3%, usando sobreposições (IoU) de 25, 50 e 75%, respectivamente. A análise de imagens pode ser usada para obter medidas biométricas em bovinos e suas carcaças e para estimar o escore final de gordura da carcaça. Além disso, esta pesquisa contribui para a proposição de um método de segmentação de carcaças e tecidos o que pode auxiliar no desenvolvimento de sistemas automatizados de avaliação de carcaças.

Palavras-chave: Análise de imagem. Bovino. Carcaça. Gordura subcutânea. Predição.

ABSTRACT

ASSIS, Gutierrez José de Freitas, D.Sc., Universidade Federal de Viçosa, July, 2021. **Image analysis in biometric evaluation and carcass grading on beef cattle.** Adviser: Mário Luiz Chizzotti. Co-advisers: Cristina Mattos Veloso and Sebastião de Campos Valadares Filho.

The grading process determines the market to which the carcass will be directed, considering its quality attributes. Currently, in slaughterhouses the grading processes are developed subjectively and, therefore, the economic efficiency of these processes can be compromised. In this sense, tools that allow the objective evaluation of the bovine carcass in vivo and post mortem are of great importance. Therefore, our objectives in this research are (1) to evaluate the effect of sex class on body or carcass morphology in bovine and to investigate the relationships between biometric measurements and fat scores assigned to carcasses in a commercial slaughterhouse. (2) To develop a segmentation algorithm using convolutional network, capable to perform the segregation of different tissues in digital images of carcasses, automatically, and, (3) develop equations to predict the rib fat thickness through meta-analysis of experimental data. Data from animals of different genetic compositions, sex classes, ages and weights were used. The animals were randomly selected in the at slaughterhouses, identified, subjected to solids fasting for 16 hours, weighed and, concomitantly, it was collected images of the animal dorsum using RGB-D cameras, for video image analysis. After slaughter, the carcass of each animal was divided longitudinally, in two half-carcasses, which were weighed and the visual fat scores was evaluated by trained professionals, and then carcass were cooled at 4 °C for 24 hours. The hot half-carcasses were used to obtain the RGB-D images. The images collected were analyzed to measure the biometric parameters. Data were analyzed using general linear model procedures of SAS 9.0 (Statistical Analysis System Institute, Inc.) and, then the means of different sex classes were compared by the test of Tukey (5%). A second step was performed using the collected images as input to a segmentation convolutional network (CNN). In the network architecture, the convolutional backbone used was the ResNeXt-101 network combined with the Feature Pyramid Network. The obtained results indicate that there is influence of the sex class on body weight, carcass weight and biometric

measures. Visual fat scores were influenced by biometric measurements. There was an effect of body weight on the final score and the heaviest animals had the highest fat scores. Similar behavior to this was verified for the analysis of the carcasses, with the highest means of the biometric parameters observed for the uniform score. However, there was no linear effect between the fat score and biometric measurements, with an overlapping of means for the lowest scores assigned to the carcasses. In the second study, the network CNN was able to detect the proportion of tissues with an accuracy of 66.5, 42.4 and 11.3%, using overlays (IoU) of 25, 50 and 75%, respectively. Image analysis can be used to obtain biometric measurements in bovine and their carcasses and to estimate the final carcass fat score. In addition, this research contributes to the proposition of a method of segmentation of carcasses and body tissues that can assist in the development of automated computer vision systems applied to the evaluation of carcasses in slaughterhouses.

Keywords: Bovine. Carcass. Image analysis. Prediction. Subcutaneous fat.

SUMÁRIO

INTRODUÇÃO GERAL	12
OBJETIVOS	13
Geral	13
Específicos.....	14
CONTRIBUIÇÃO.....	14
REFERÊNCIAS.....	14
CAPÍTULO 1	16
REVISÃO DE LITERATURA	16
INTRODUÇÃO	17
AVALIAÇÃO DE CARACTERÍSTICAS DE CARCAÇA <i>IN VIVO</i>	20
Método subjetivo: Escore de condição corporal.....	20
Método objetivo: Ultrassonografia, Tomografia computadorizada e Absorciometria por raios-X com dupla energia (DEXA)	21
AVALIAÇÃO DE CARACTERÍSTICAS DE CARCAÇA <i>POST MORTEM</i>	23
Avaliação subjetiva na linha de abate	23
Avaliação objetiva na linha de abate.....	27
PROCESSAMENTO DE IMAGENS DIGITAIS.....	32
Aquisição de imagens digitais.....	33
Pré-processamento.....	34
Segmentação.....	35
Extração, classificação e reconhecimento de atributos	37
REDES NEURAIS NO RECONHECIMENTO DE PADRÕES E PROCESSAMENTO DE IMAGENS.....	38
Redes Neurais Convolucionais.....	41
Treinamento da rede Neural convolucional	42
Rede Completamente Convolucional.....	44
ARQUITETURA DE REDES CNN.....	44
Rede Neural Convolucional – VGG	45
Rede Neural Convolucional – ResNet	45
Rede Neural Convolucional – DenseNet	46
Rede Neural Convolucional – U-Net.....	47
Rede Mask R-CNN	47
AVALIAÇÃO DOS CLASSIFICADORES.....	48

Métricas de qualidade.....	49
CONSIDERAÇÕES FINAIS	50
REFERÊNCIAS.....	50
CAPÍTULO 2	66
EFEITO DA CLASSE SEXUAL E ESCORE DE ACABAMENTO DE GORDURA NA CARÇAÇA SOBRE MEDIDAS BIOMÉTRICAS OBTIDAS PELA ANÁLISE DE IMAGENS DIGITAIS EM BOVINOS.....	66
RESUMO.....	67
INTRODUÇÃO	69
MATERIAIS E MÉTODOS.....	70
RESULTADOS E DISCUSSÃO.....	74
CONCLUSÕES	83
REFERÊNCIAS.....	84
CAPÍTULO 3	88
EFEITO DA CLASSE SEXUAL E ESCORE DE ACABAMENTO DE GORDURA SUBCUTÂNEA SOBRE MEDIDAS BIOMÉTRICAS OBTIDAS PELA ANÁLISE DE IMAGENS DIGITAIS DE CARÇAÇAS BOVINAS.....	88
RESUMO.....	89
INTRODUÇÃO	91
MATERIAIS E MÉTODOS.....	91
RESULTADOS E DISCUSSÃO.....	95
CONCLUSÕES	101
REFERÊNCIAS.....	101
CAPÍTULO 4	104
SEGMENTAÇÃO AUTOMÁTICA DE IMAGENS DIGITAIS DE CARÇAÇAS BOVINAS UTILIZANDO REDES NEURAI CONVOLUCIONAIS (CNN)	104
RESUMO.....	105
INTRODUÇÃO	106
MATERIAIS E MÉTODOS.....	107
Rede neural proposta	108
RESULTADOS E DISCUSSÃO.....	111
Comparação Inter-Observador	113
CONCLUSÕES	120
REFERÊNCIAS.....	121

CAPÍTULO 5	125
DESENVOLVIMENTO DE EQUAÇÕES PARA ESTIMAR O GRAU DE ACABAMENTO DE GORDURA E COMPOSIÇÃO DE CARÇAÇA EM BOVINOS .	125
RESUMO.....	126
INTRODUÇÃO	127
DESCRIÇÃO DO BANCO DE DADOS	129
EQUAÇÕES PARA PREDIÇÃO DO ACABAMENTO DE CARÇAÇA POR ESPESSURA DE GORDURA SUBCUTÂNEA (EGS).....	131
REFERÊNCIAS.....	138
CONCLUSÕES GERAIS.....	143

INTRODUÇÃO GERAL

A bovinocultura de corte é desenvolvida em todos os estados e ecossistemas do país, sob uma ampla gama de sistemas de produção. Estes variam desde uma pecuária extensiva, suportada por pastagens nativas e cultivadas de baixa produtividade e com pouco uso de insumos, até uma pecuária intensiva, com pastagens de alta produtividade, suplementação alimentar em pasto e confinamento (Cezar et. al., 2005). Entretanto, qualquer que seja o sistema de produção, o objetivo é produzir animais pesados e em conformidade com as características estabelecidas pelo mercado consumidor. Em função disso, é de grande utilidade que o pecuarista tenha conhecimento do nicho de mercado que está sendo atendido por seu produto e do valor que pode ser agregado a este. Isso incentivará a produção de lotes mais homogêneos de animais e, conseqüentemente, carcaças de boa qualidade, independente do sistema de produção adotado. Neste sentido, os processos de avaliação, classificação e tipificação de carcaças permitem estimar a qualidade do produto final de um sistema de produção e promovem, também, a harmonização entre os diferentes elos da cadeia produtiva, de forma que as demandas do consumidor final sejam convertidas em orientações para os pecuaristas.

As características de carcaça, assim como os atributos de qualidade da carne, podem ser avaliadas, utilizando-se, para isso, indicadores que permitem hierarquizar as carcaças e carnes de acordo com sua qualidade (Feijó, 2019). A avaliação das carcaças, em princípio, é realizada em duas partes, sendo a primeira de classificação dos lotes por classe sexual, maturidade e faixa de peso animal, de modo que as carcaças sejam agrupadas por categoria. A segunda parte é a tipificação propriamente dita, que consiste em alocar as carcaças já classificadas em tipos ordenados da melhor para a pior, seguindo indicadores comumente utilizados nas avaliações de bovinos, como a musculosidade (conformação) e a quantidade de gordura (acabamento). Em resumo, as carcaças consideradas dos melhores tipos produziram carne de melhor qualidade (Felício, 2005; de Quadros et al., 2015). Assim, carcaças com qualidade superior serão premiadas e aquelas com características não desejáveis serão penalizadas.

Todos os sistemas existentes avaliam a carcaça no que diz respeito a características de rendimento de carne e qualidade, uma vez que a quantidade e qualidade da carne comercializável varia de acordo com estes indicadores (Bridi,

2002). O rendimento em carne magra aumenta com o grau de musculosidade e diminui com o aumento da quantidade de gordura na carcaça, que, por sua vez, podem ser estimados pela área de olho de lombo, espessura de gordura subcutânea ou pelos escores de conformação e de acabamento da carcaça. Frente ao exposto, a adoção dos sistemas de avaliação, classificação e tipificação de carcaças bovinas faz-se necessária para auxiliar a tomada de decisões, seja por parte dos pecuaristas ou pelos agentes envolvidos com a indústria frigorífica e na comercialização da carne (Sainz & Araujo, 2001).

Atualmente, grande parte dos frigoríficos que realizam os processos de avaliação das carcaças, os realizam de maneira manual e subjetiva, e, portanto, a eficiência econômica do processo pode ser comprometida, devido a equívocos que podem ocorrer (Gomes et al., 2021). O grau de acabamento das carcaças, devido à sua grande variabilidade, tem sido relatado como um dos principais problemas enfrentados pela indústria frigorífica, visto que essa característica apresenta correlação negativa com a maciez da carne. Neste sentido, a determinação adequada do grau de gordura é uma tarefa importante e, muitas vezes, complexa de ser realizada, uma vez que a distinção entre os principais tecidos na superfície da carcaça, em especial, a distinção entre a gordura e o tecido conectivo, pode ser difícil em estágio inicial, podendo confundir o especialista (Gomes et al., 2021). Esta subjetividade, associada com a restrição de tempo nas operações frigoríficas, podem ocasionar imprecisões e inconsistências em relação à classificação das carcaças. Diante disso, o estudo proposto nessa pesquisa visa auxiliar a automatização e padronização do processo de avaliação de carcaças bovinas, considerando o acabamento de gordura com base em técnicas computacionais.

OBJETIVOS

Geral

Avaliar o uso de equações de predição ou visão computacional na classificação de carcaças bovinas.

Específicos

Caracterizar o efeito da classe sexual sobre a morfologia corporal de bovinos e investigar as relações ente as medidas biométricas *in vivo* e os escores de acabamento atribuídos às carcaças em frigorífico comercial, por meio do processamento de imagens digitais coletadas nos currais de manejo.

Caracterizar o efeito da classe sexual sobre a morfologia da carcaça e investigar as relações ente as medidas biométricas da carcaça com os escores de acabamento atribuídos em frigorífico comercial, por meio do processamento de imagens digitais coletadas na linha de abate.

Desenvolver uma técnica de segmentação de imagens, baseada em arquiteturas de Rede Neural Convolutacional (CNN - *Convolutional Neural Network*), para a segmentação automática da proporção de tecidos na superfície da carcaça.

Desenvolver equações de predição da espessura de gordura subcutânea na carcaça bovina a partir de meta-análises de dados experimentais.

CONTRIBUIÇÃO

Desenvolvimento de uma metodologia que auxilie a classificação automática do acabamento de gordura em carcaças bovinas, baseada na aplicação de técnicas de processamento de imagens digitais.

Propõe-se metodologia para extração de características de interesse na carcaça bovina, para a classificação com relação ao acabamento de gordura, por meio da automatização do processo de classificação. Metodologia esta capaz de realizar a tarefa de classificação, equivalente àquela realizada por um observador humano treinado. A contribuição tecnológica é representada pela metodologia de aquisição das imagens digitais, segmentação e classificação das carcaças bovinas durante o processo de abate.

REFERÊNCIAS

- Bridi, A. M. (2002). Normas de avaliação, classificação e tipificação de carnes e carcaças. Univ. Est. Londrina. Disponível em: <http://www.uel.br/pessoal/ambridi/Carnesecarcacasarquivos/Avaliacaocarcacabovinosuinoaseaves.pdf>. Acesso em: 18 julho 2020.

- Cezar, I. M., de Queiroz, H. P., Thiago, L. D. S., Garagorry, F. L., Costa, F. P. (2005). Sistemas de produção de gado de corte no Brasil: uma descrição com ênfase no regime alimentar e no abate. Campo Grande, MS: Embrapa Gado de Corte. ISSN 1517-3747.
- De Quadros, D. G., Paes, B. R., Vieira, G. A., Andrade, A. P., Miranda, A. M., Araújo, J. A. M., de Azevedo, P. S. (2015). Classificação e tipificação de carcaças bovinas na região oeste da Bahia em duas épocas do ano. *Boletim de Indústria Animal*, 72(2), 102-110.
- Feijó, F. D. (2019). Avaliação qualitativa e quantitativa da carcaça e da carne de raças bovinas. Disponível em: <http://hdl.handle.net/10183/196085>.
- Felício, P.E. (2005). Classificação e tipificação de carcaças bovinas. In: Simpósio Goiano Sobre Manejo E Nutrição De Bovinos De Corte E Leite, 7, 2005. Goiânia. Anais. Goiânia: Colégio Brasileiro de Nutrição Animal. p.11-25. 2005.
- Gomes, M. D. N. B., Feijó, G. L. D., Duarte, M. T., Silva, L. G. P. D., Surita, L. M. A., Pereira, M. W. F. (2021). Manual de avaliação de carcaças bovinas. Disponível em: <https://repositorio.ufms.br/handle/123456789/3865>. Acesso em: 01 de setembro de 2021.
- Sainz, R. D., Araujo, F. R. (2001). Tipificação de carcaças de bovinos e suínos. In Congresso Brasileiro de Ciencia e Tecnologia de Carne. São Pedro. Anais. Campinas: Centro de Tecnologia de Carnes do Instituto de Tecnologia de Alimentos, 1, 26-55.

CAPÍTULO 1

REVISÃO DE LITERATURA

Gutierrez J. F. Assis^{*1}, Débora E. F. Assis^{*}, Gustavo B. Carneiro^{*}, André L.C.

Mendes^{*}, Fabyano F. Silva^{*}, Mario L. Chizzotti^{*1}.

^{*} Departamento de Zootecnia, Universidade Federal de Viçosa, Viçosa, Minas Gerais, Brasil, 36.570-900.

¹Autores correspondentes. E-mail: gutierrez.assis@ufv.br; mariochizzotti@ufv.br

INTRODUÇÃO

Cada país tem estabelecido o seu próprio sistema de avaliação, classificação e tipificação de carcaças, havendo inclusive países que adotam dois sistemas, sendo um destinado ao mercado interno e outro ao mercado externo. Estes sistemas divergem quanto aos critérios avaliados (indicadores quantitativos e qualitativos) na carcaça para agrupá-las (sexo, maturidade, peso, conformação e acabamento) e estabelecer seu valor comercial. O sexo é obtido por meio da observação das características sexuais dos animais (machos não castrados, machos castrados e fêmeas). As carcaças de animais não castrados são mais pesadas e apresentam maior proporção de músculos, no entanto, tendem a apresentar menor quantidade de gordura subcutânea e intramuscular se comparado aos animais castrados e as fêmeas. As fêmeas apresentam menor desenvolvimento muscular e depositam maior quantidade de gordura, com os machos castrados exibindo características intermediárias. A maturidade é obtida pelo exame dos dentes incisivos e ossificação das apófises.

O peso refere-se ao peso de carcaça obtido na sala de matança, logo após o abate, e é de relevância econômica aos frigoríficos. Carcaças mais pesadas diluem o custo operacional pela quantidade de carne produzida, considerando que animais de pesos diferentes na linha de abate requerem a mesma mão-de-obra e tempo de processamento na desossa (Costa et al., 2002). Além disso, o abate de animais pesados e maturos proporciona a indústria frigorífica obter maior quantidade de couro e subprodutos por unidade animal.

A conformação é um indicador bastante prático do rendimento a desossa, pois relaciona-se com o maior ou menor desenvolvimento muscular. Pode ser avaliada de forma subjetiva, utilizando escores visuais, ou mensurada de maneira objetiva. As carcaças podem ser classificadas conforme os seguintes escores de conformação: convexa (C; maior musculabilidade no coxão, considerada a melhor conformação), subconvexa (Sc), retilínea (R), sub-retilínea (Sr) ou côncava (Co; menor desenvolvimento muscular e, portanto, a de pior conformação). A musculabilidade pode ainda ser avaliada pela área do músculo Longissimus dorsi (Área de olho de lombo, AOL). Essa medida é obtida a partir do corte transversal da meia-carcaça resfriada, entre a 12^a e 13^a costelas, e, portanto, não é adotada pelo

sistema brasileiro, visto que secciona um músculo com alto valor agregado, o contrafilé.

O acabamento expressa a quantidade e a distribuição de gordura subcutânea presente na carcaça. A gordura subcutânea é um importante indicador de qualidade da carcaça, pois influencia o aspecto visual da carcaça, rendimento da porção comestível e a qualidade da carne produzida. Neste sentido, alguns frigoríficos têm bonificado produtores que entregam carcaças apresentando o acabamento exigido, assim, o grau de acabamento dos animais tem sido utilizado como critério para determinação do ponto de abate. A avaliação do grau de acabamento da carcaça pode ser realizada de forma subjetiva, utilizando escores visuais ou mensurada objetivamente. A avaliação subjetiva é realizada visualmente em diferentes locais da carcaça: na altura da 6^o, 9^o e 12^o costelas, parte dorsal e ventral do músculo grande dorsal e músculo serrátil dorsal caudal, na região lombar e no coxão (BRIDI, 2002), frente disso, as carcaças podem ser classificadas conforme os seguintes escores:

- **Ausente ou magra (escore 1):** Carcaça desprovida de gordura subcutânea. A musculatura é aparente na superfície lateral das meias-carcaças, com os limites dos músculos apresentando-se bem visíveis.
- **Escassa (escore 2):** Gordura subcutânea praticamente ausente nas regiões do coxão e paleta-acém-pescoço, onde a musculatura sobressai. A região lombar, a alcatra e a face lateral do coxão são recobertas por uma camada de gordura de 1 a 3 mm de gordura após o resfriamento.
- **Mediana (escore 3):** A gordura subcutânea recobre a região lombar, a alcatra e a face lateral do coxão com uma camada de 3 a 6 mm de espessura. Os limites dos músculos do traseiro não são visíveis.
- **Uniforme (escore 4):** A região lombar, a alcatra e a face lateral do coxão são uniformemente recobertos, até o limite da paleta e do pescoço, por uma camada de 6 a 10 mm de gordura, fazendo desaparecer o relevo muscular.
- **Excessiva (escore 5):** A gordura subcutânea reveste praticamente toda a carcaça. A região lombar, a alcatra e a face lateral do coxão são recobertos por uma camada de gordura superior a 10 mm.

A avaliação objetiva do grau de acabamento das carcaças é realizada utilizando-se um paquímetro para mensuração da espessura de gordura subcutânea entre a 12^a e 13^a costela (Luchiari Filho, 2000). Embora esta avaliação seja mais precisa se comparada com a avaliação visual, ela não é comumente praticada no Brasil, pois deve ser realizada na carcaça resfriada, o que demandaria maior tempo de permanência das carcaças nos frigoríficos.

A gordura age como um isolante térmico, protegendo as massas musculares dos efeitos negativos da exposição direta à temperatura de refrigeração e permite que as mesmas resfriem lentamente, em ritmo próximo à curva ideal, otimizando a atividade enzimática proteolítica, reduzindo a probabilidade de ocorrer encurtamento excessivo das fibras musculares (Cold shortenig) e melhorando a maciez da carne, respectivamente (Kazama et al., 2008; Bridi, 2019). A ausência de gordura subcutânea possibilita ainda maior perda de líquidos pela carcaça e elevado grau de escurecimento de cortes superficiais, reduzindo consideravelmente o seu valor de mercado (Magnabosco et al. 2006; IMA, 2010). A ausência da gordura subcutânea influencia negativamente a maciez, suculência e cor das carnes produzidas (Magnabosco et al., 2006).

Para que estes eventos indesejáveis sejam evitados, os frigoríficos brasileiros exigem que as carcaças apresentem a espessura mínima de 2,5 a 3 mm de gordura subcutânea, para proteção durante o período de resfriamento (Bridi, 2019). A cobertura uniforme de gordura proporciona aos cortes desossados uma melhor apresentação visual (Moreira et al., 2017; Pascoal, 2008), e além disso, influencia as características sensoriais da carne (Vaz & Restle, 2000). No entanto, o excesso de gordura subcutânea também não é indicado, pois apresenta correlação negativa com a porcentagem de carne magra na carcaça.

Frente ao exposto, podemos dividir os indicadores entre os que podem ser baseados na avaliação visual realizada por especialistas, e aqueles baseados na avaliação objetiva, utilizando ferramentas e ou técnicas computacionais para quantificação das características desejáveis.

AVALIAÇÃO DE CARACTERÍSTICAS DE CARÇAÇA *IN VIVO*

Método subjetivo: Escore de condição corporal

Tecnologias não invasiva que permitem predizer a composição corporal e avaliar a qualidade da carcaça antes que os animais sejam abatidos ainda são escassas. Normalmente, à campo o que se observa é a avaliação do peso animal como indicativo da qualidade da carcaça, no entanto, o peso corporal é função da estrutura (*frame*) do animal, e por isso, pode ocorrer que elevados pesos não estejam associados a animais com boas condições corporais (musculatura e acabamento) e sim a animais de grande porte. Há, também, animais que, embora estejam com pesos inferiores, podem estar em melhores condições em virtude do seu menor tamanho e da distribuição da gordura subcutânea. Além desse aspecto, as variações no peso podem ser causadas por variações no enchimento do rúmen, no status fisiológico associado a gestação e ao parto (vacas e novilhas) e da hidratação de tecidos, e não apenas em virtude de alterações consistentes no conteúdo de gordura e musculatura (Faria et al., 2007).

Nesse sentido, a avaliação da condição corporal através do escore de condição corporal (ECC), associada ao peso, fornece uma melhor estimativa da qualidade da carcaça a ser produzida. O ECC é uma medida subjetiva baseada na classificação dos animais em função do desenvolvimento muscular e da cobertura de gordura subcutânea (Santos et al., 2009). O escore é obtido mediante avaliação visual e tátil (palpação) do corpo animal, por um profissional treinado. O método é rápido, prático, apresenta baixo custo, reflete as reservas energéticas dos animais e serve como auxiliar na indicação de práticas a serem adotadas no manejo nutricional do rebanho e contribui para a tomada de decisões sobre o momento do abate. A avaliação da condição corporal ou de suas flutuações para estimar as reservas corporais é mais adequada do que as mensurações de peso vivo, pois sua análise independe do tamanho e do estado fisiológico do animal (Machado et al., 2008).

As notas dos escores são dadas aos animais de acordo com a quantidade e distribuição dos tecidos corporais, especialmente gordura e músculos, em determinadas regiões do corpo, associadas a pontos anatômicos específicos, tais como determinadas protuberâncias ósseas: costelas, processos espinhosos da coluna vertebral, processos transversos da coluna vertebral, vazão, ponta do íleo,

base da cauda, sacro e vértebras lombares (Machado et al., 2008). A condição corporal é um indicador confiável do estado nutricional e do acúmulo de gordura. Segundo Machado et al. (2008, p. 9, apud Faulkner, 1990, p. 11-16), ao utilizar a escala de ECC de 1 a 9, relatou que as estimativas de composição e de cobertura de gordura da carcaça bovina variam de 0,7% e de inexistente, em animais com ECC = 1, a 22,3% e 7,4 mm, respectivamente, quando o ECC = 6. Essas estimativas alcançam 35,5% e 17,3 mm em bovinos obesos com escore = 9.

Nesse contexto, o escore de condição corporal é uma ferramenta útil na avaliação da carcaça *in vivo* e, portanto, tem aplicação estratégica no manejo do rebanho. No entanto, deve-se reconhecer que esta avaliação é muito limitada e apenas fornecem um indicativo se a carcaça apresenta o mínimo de acabamento de gordura exigida pelo frigorífico, afim de garantir que o produtor não seja penalizado pela ausência de acabamento.

Método objetivo: Ultrassonografia, Tomografia computadorizada e Absorciometria por raios-X com dupla energia (DEXA)

Ultrassonografia de carcaça

Entre as metodologias existentes para avaliação de carcaças e de características associadas à qualidade da carne, *in vivo*, a ultrassonografia se destaca por ser realizada em tempo relativamente curto e com boa precisão. O objetivo é conhecer o potencial dos indivíduos e do rebanho como um todo, para musculosidade, precocidade de acabamento e qualidade da carne, por meio da análise da área de olho-de-lombo (AOL), espessura de gordura subcutânea (EGS) e grau de marmoreio (Sugisawa et al., 2013). Estes indicadores estão relacionados com o ganho de peso diário, rendimento de carcaça, precocidade de acabamento, sabor e suculência da carne (Cartaxo et al., 2011), e podem ainda ser empregados na identificação do melhor ponto de abate dos animais, de acordo com as exigências da indústria frigorífica. De fato, a utilização da ultrassonografia é mais acurada do que o peso vivo quando se pretende estimar a composição das carcaças (Wilson, 1992).

Diversos estudos apresentaram correlações entre as medidas obtidas por ultrassom pré-abate e as respectivas medidas na carcaça. As correlações variam entre 0,51 e 0,91 para AOL e entre 0,46 e 0,96 para EGS (Perry et al., 1990; Ribeiro

et al., 2000; Suguisawa et al., 2003; Tarouco et al., 2005; Silva et al., 2006; Queiroz et al., 2010; Son e Lee, 2013; Silva, 2018). No entanto, as correlações entre as medidas de carcaça e ultrassom podem ser influenciadas por limitações tecnológicas (aparelhos e transdutores), experiência do técnico, sexo e idade do animal, proporção de gordura e músculo, remoção da gordura junto ao couro e mudança nas características dos tecidos pós-morte (Perkins et al., 1997; Sainz & Araújo, 2002; Yoko, et al., 2011).

Independente das limitações, a aplicação da ultrassonografia tem sido importante na modelagem do crescimento dos tecidos, na avaliação da condição corporal e também no desenvolvimento de sistemas de pagamento baseados em mérito da carcaça, (Silva et al., 2017), visto que possibilita a homogeneização das carcaças bovinas antes do abate, reduz as perdas econômicas e atende as demandas mercadológicas específicas em pesos de cortes cárneos (Cardoso et al. 2013).

Tomografia computadorizada

A Tomografia computadorizada é uma técnica minimamente invasiva que pode ser usada para avaliação *in vivo*. A tomografia é uma tecnologia sofisticada que representa um método rápido, e que fornecem informações objetivas e confiáveis na predição de tecidos de carcaça (Johansen et al., 2007). No entanto, devido à dificuldade de acesso ao equipamento e o alto custo, esta tecnologia não foi amplamente difundida (Rivero et al., 2005). Além disso, durante o processo de aquisição de imagens, o animal deve ficar deitado e imóvel, sendo necessário anestesiá-lo e conter o animal, e, portanto, inviável de ser utilizado em grande escala para bovinos. A utilização tem sido focada principalmente em pequenos ruminantes e suínos.

A Tomografia computadorizada é feita pela rotação de um tubo de raio-X de 360° em torno do corpo do animal, gerando imagens tridimensionais transversais do corpo (Clelland et al., 2014). Posteriormente a digitalização da imagem, o corpo animal é dividido em algumas seções consecutivas, paralelas e os dados são somados para produzir estimativas totais dos diferentes tecidos da carcaça (músculo, gordura e ossos; Anderson et al., 2015).

A Tomografia fornece estimativas precisas dos pesos de tecidos devido a relação entre atenuação de raios X e densidade de tecido. Estudos foram realizados para avaliar a carcaça e prever crescimento e composição corporal, tendo como referência a dissecação manual (Standal, 1984, Jones et al., 2002, Lambe et al., 2006, Johansen et al., 2007, Navajas et al., 2007, Panea et al., 2012). Os resultados demonstraram existir correlações entre as proporções dos tecidos de carcaça e as estimadas pela tomografia computadorizada.

Absorciometria por raios-X com dupla energia (DEXA)

A varredura de absorciometria por raios-X com dupla energia (DEXA) pode ser utilizada para obter medições objetivas da carcaça *in vivo*, fornecendo informações sobre o osso, a massa gorda e a massa muscular. Da mesma forma que a tomografia computadorizada (TC) o DEXA é uma tecnologia baseada na atenuação de raios-X, portanto, a base da tecnologia reside na razão da absorção dos diferentes feixes de raios-X de baixa e alta energia interagindo com os tecidos corporais, permitindo a identificação e quantificação dos tecidos. No entanto, a medição DEXA sofre limitações práticas para a implantação na indústria, entre elas, tamanho corporal dos animais, varreduras de mesa horizontal, taxa de varredura em minutos e a necessidade de se anestésiar e imobilizar os animais. A viabilidade da tecnologia DEXA na avaliação da composição da carcaça já foi descrita para frangos de corte (Goncalves et al., 2019), ovelhas (Hunter et al., 2011) e bezerras (Scholz et al., 2003; Silva et al., 2015; López-Campos et al., 2018), e bovinos (Assis et al., 2019) em todos esses estudos, maiores valores de coeficiente de determinação (R^2) foram descritos para as estimativas de gordura total e massa magra total do que para estimativas ósseas totais.

AVALIAÇÃO DE CARACTERÍSTICAS DE CARCAÇA *POST MORTEM*

Avaliação subjetiva na linha de abate

Existem inúmeras diferenças entre os critérios de avaliação utilizados pelos sistemas de classificação de carcaça de cada país, no entanto, todos têm por objetivo selecionar carcaças com as melhores características, atribuindo ao produtor remuneração diferenciada de acordo com a classificação. Neste trabalho

apresentaremos rapidamente as principais características dos sistemas adotados pelo Brasil, União Européia, Estados Unidos, Austrália, Canadá e Japão.

Brasil: No sistema proposto em 1989, as carcaças deviam ser avaliadas quanto ao peso da carcaça, classe sexual (macho inteiro, macho castrado e fêmea), maturidade (dentição), escore de conformação (convexas, subconvexas, retilíneas, sub-retilíneas e côncavas) e escore de acabamento (ausente, escassa, mediana, uniforme e excessiva). Assim as carcaças seriam hierarquizadas em seis classes (B-R-A-S-I-L), carcaças classificadas como “B” seriam de melhor qualidade e as classificadas como “L” as de pior qualidade (BRASIL, 1989). Contudo, o sistema foi reformulado em 2004 (Instrução Normativa n 09; BRASIL, 2004), e nesse sistema, a conformação e o peso das carcaças foram excluídos, avaliando-se apenas a classe sexual, maturidade e acabamento.

Brasil (ABIEC, 2018): Recentemente, um novo sistema nacional de classificação e tipificação de carcaças bovinas foi proposto. O modelo tem sido desenvolvido pela Associação Brasileira das Indústrias Exportadoras de Carne (ABIEC) em parceria com outras associações e universidades. O sistema tipifica somente por meio de avaliações subjetivas. Considerando a diversidade de raças e cruzamentos utilizados, avalia-se o grupo genético dos animais, a maturidade (dentição), classe sexual, peso da carcaça e acabamento de gordura. Frente estas avaliações as carcaças podem ser enquadradas em três tipos diferentes (Tipo A; Tipo B e Tipo C) conforme pode ser visualizado na Tabela 1.

Tabela 1- Tipificação das carcaças bovinas de acordo com o protocolo de classificação e tipificação de carcaças instituído pela ABIEC (2018).

Classe sexual	TIPO A	TIPO B	TIPO C
Machos Não Castrados	Idade 0 e 2 dentes; acabamento 3 e 4; peso ≥ 16 e $< 23@$.	Idade 0 e 2 dentes; acabamento 3 e 4; peso ≥ 23 e $< 26@$; Idade 0 e 4 dentes; acabamento 2; peso ≥ 16 e $< 26@$; Idade 4 dentes; acabamento 3 e 4; peso ≥ 16 e $< 26@$.	Demais variações
Machos Castrados	Idade 0 a 4 dentes (6 dentes em raças taurinas); acabamento 3 e 4; peso ≥ 15 e $< 23@$.	Idade 0 a 4 dentes (6 dentes em raças taurinas); acabamento 3 e 4; peso ≥ 23 e $< 26@$; Idade 0 a 6 dentes; acabamento 2; peso ≥ 15 e $< 26@$; Idade 6 dentes; acabamento 3 e 4; peso ≥ 15 e $< 26@$;	Demais variações
Fêmeas	Idade 0 a 4 dentes; acabamento 3 e 4; peso $\geq 12@$; idade 6 dentes; acabamento 3 e 4; peso de $\geq 15@$.	Idade 0 a 4 dentes; acabamento 2; peso $\geq 11@$; Idade 0 a 4 dentes; acabamento 3 e 4; peso ≥ 11 e $< 12@$; Idade 6 dentes; acabamento 3 e 4; peso ≥ 11 e $< 15@$; Idade 6 e 8 dentes; acabamento 2; peso $\geq 12@$; Idade 8 dentes; acabamento 3 e 4; peso $\geq 12@$.	Demais variações

Fonte: Associação Brasileira das Indústrias Exportadoras de Carne (ABIEC).
www.abiec.com.br

União Européia: O sistema Europeu tipifica somente por meio de avaliações subjetivas. Avalia-se a maturidade, classe sexual, musculabilidade e acabamento de gordura. Avalia-se a maturidade, através informações disponíveis no regime de identificação e registo de bovinos estabelecido por cada Estado-Membro, atribuindo cinco grupos, de A (mais novo) a E (mais velho). A musculabilidade é avaliada por escore de conformação (dá mais para a menos musculosa) segundo as letras S-E-U-R-O-P (S = superior; E= excelente ou convexa; U = muito boa ou subconvexa; R = boa ou retilínea; O = razoável ou subretilínea e P = pobre ou côncava). A classificação por acabamento é uma avaliação em cinco classes, 1 = deficiente, 2 = baixo, 3 = médio, 4 = alto, 5 = excelente. O acabamento é avaliado comparando-se as carcaças com escores padrões pré-estabelecidos. A combinação destes

parâmetros, permite que as carcaças bovinas sejam classificadas e hierarquizadas das melhores para as piores (Comunidade Europeia, 2017)

Estados Unidos: A classificação do USDA (1997) resume-se em “Yield Grades” e “Quality Grades” (categorias de rendimento e de qualidade, respectivamente). Para avaliar a Yield Grades, a carcaça é seccionada transversalmente entre a 12^a e 13^a costela e a área do olho do lombo e a espessura da gordura subcutânea são visualizados e mensurados. Subsequentemente, o peso da gordura renal, pélvica e torácica, em porcentagem do peso da carcaça são estimados. Para o “Quality Grade”, avalia-se a classe sexual (novilhos castrados, novilhos inteiros, touros, novilhas, vacas), graus de maturidade e marmorização. A maturidade é avaliada pelo grau de ossificação dos ossos e cartilagens, podendo a carcaça ser classificada dentro das seguintes categorias: A (9 a 30 meses), B (30 a 42 meses), C (42 a 72 meses), D (72 a 96 meses) e E (acima de 96 meses). A avaliação de marmoreio é feita visualmente no músculo Longissimus dorsi, entre a 12^a e a 13^a costelas, utilizando-se cartões padrões do USDA (USDA, 1997).

Austrália: No sistema AUS-MEAT, as carcaças são avaliadas pelo peso, classe sexual, maturidade, acabamento, musculabilidade e escores de contusões. O peso é obtido na carcaça quente ao final da linha de abate. A avaliação da maturidade é preferencialmente realizada observando-se a dentição, no entanto, a ossificação das apófises também pode ser realizada. A avaliação da musculabilidade é feita pela observação de imagens padrões, podendo a carcaça ser enquadrada em cinco categorias. A avaliação do acabamento de gordura é feita pela observação do padrão de marmorização. A avaliação da marmorização é feita na carcaça resfriada e o escore de marmorização é avaliado na superfície de corte do contraflé, conforme comparação entre a amostra retirada da carcaça e os padrões do Meat Standards Australia (MSA, 2003).

Canadá: No sistema canadense os principais pontos avaliados são: maturidade, musculabilidade, espessura de gordura subcutânea, marmorização e coloração da carne e da gordura. A musculabilidade e acabamento são determinados entre a 12^a e 13^a costelas com auxílio de uma régua (BCRC, 2019). A classificação de carcaça canadense utiliza 4 padrões de marmorização (A, AA, AAA e *Canada Prime*; BCRC, 2019).

Japão: No Japão, as avaliações para rendimento e qualidade são realizadas entre a 6ª e 7ª costela. As avaliações são realizadas tendo como base imagens e paletas de cor padrão. As notas de rendimento são dadas como A, B e C. A nota A é empregada para carcaças que apresentam rendimento superior a 72%, consideradas acima da média, a B para carcaças com rendimento entre 69-72%, consideradas na média, e a C para valores inferiores a 69%, abaixo da média. As notas de qualidade variam de 1 (pobre) a 5 (excelente), considerando nas avaliações a marmorização, coloração e brilho da carne, firmeza e textura da carne, coloração e qualidade da gordura. A nota final é dada associando-se as avaliações de rendimento e qualidade (JMGA, 2008)

Avaliação objetiva na linha de abate

A grande maioria dos sistemas de classificação e tipificação, contém elementos subjetivos, passíveis de erros humanos e que levam a uma lentidão no processo de avaliação e aumento de custos. Além disso, devido a sua subjetividade, o sistema de classificação torna-se inconsistente e dificulta o estabelecimento de um programa de pagamento com base na qualidade, que reflete o valor real da carcaça para a indústria (Gomide et al, 2014). Neste sentido, a medição objetiva, em tempo real, das características de carcaça que determinam a qualidade final da carne, é um passo importante para a indústria e está em crescente desenvolvimento devido principalmente as tecnologias de análise de imagem digital. Algumas das tecnologias ainda estão distantes de serem utilizadas dentro do ambiente frigorífico, outras, no entanto já estão bem avançadas e a caminho da comercialização, ou já sendo aplicadas nas indústrias de carne em todo o mundo. As tecnologias utilizadas incluem câmeras de alta definição, ultrassonografia, tomografia computadorizada, espectroscopia no infravermelho próximo (NIRS), imagem de raios-X e outros sistemas. Independente das tecnologias, estas devem ser capazes de coletar e analisar os dados em ambientes hostis como frigoríficos, onde serão expostas as condições adversas de temperatura, umidade e iluminação. Além disso, essas ferramentas precisam ser rápidas, econômicas e confiáveis. Abaixo são descritas algumas tecnologias já em utilização e outras que estão progredindo.

A análise por imagem de vídeo (VIA), dentre as tecnologias em desenvolvimento, parece ser a mais promissora, e estão presentes desde a década

de 1980 para carcaças de bovinos (Craigie et al., 2012). Basicamente, existem dois tipos de VIA no mercado: Aqueles realizados em cortes obtidos transversalmente na carcaça, e aqueles em que a mensuração é realizada na carcaça inteira, ou seja, na superfície da carcaça.

A VIA de carcaça inteira é integrada à planta de abate dentro do frigorífico e opera de forma autônoma e automática (Craigie et al., 2012). Alguns desses estão atualmente em utilização e permitem avaliar mais de 1000 carcaças por hora (Craigie et al., 2012). Além disso, a velocidade dos sistemas pode ser ajustada de acordo com o número de carcaças que estão na linha de abate. Os sistemas operam com um mecanismo que expõe as laterais das carcaças a uma câmera (Wnęk et al., 2017). Conforme a carcaça passa pelo sistema, uma imagem é obtida contra um fundo azul ou verde-escuro e outra, com projeção luminosa de “linha de grade”, permitindo a medição de comprimentos, alturas, ângulos, áreas e volumes. Todos os dados são processados e a partir desses, as carcaças são classificadas quanto ao acabamento e grau de conformação. Exemplos desses sistemas são o VBS 2000 (E+V technology GmbH e Co.KG), da Alemanha, o BCC-2 (Carometec A/S), da Dinamarca (Gomide et al., 2014), e os MAC-2 / MAC-S (Normaclass), da França (Heggli et al., 2021). A precisão dos sistemas de VIA de carcaça inteira foi avaliada em diferentes unidades comerciais (Allen & Finnerty, 2000; Craigie et al., 2012; Wnęk et al., 2017). No entanto, segundo Wnęk et al. (2017) é difícil tirar conclusões sobre esses, pois não há definições claras de características de carcaça, por exemplo, rendimento de carne vendável (%), e também há falta de informações a respeito do nível de aparas (toailete) das carcaças.

O segundo tipo de aplicação da VIA envolve a aquisição de imagens do músculo *Longissimus*, provenientes do corte transversal realizado entre a 12^a e 13^a costela de uma carcaça bovina resfriada. A análise de imagem permite estimar o rendimento em carne através da mensuração da área de olho de lombo (AOL) e da espessura de gordura subcutânea (EGS), e a qualidade da carne, através da coloração do tecido muscular e do grau de marmorização. Atualmente existem diversos instrumentos disponíveis no mercado, como o VIAScan da Austrália; o VGB 2000 (E+V technology GmbH e Co.KG), da Alemanha; e o CVS (Computer Vision Systems), do Canadá (Gomide et al., 2014).

A E+V rib-eye camera já está em uso comercial na indústria de carne bovina dos EUA para classificação de qualidade. Na Austrália, a câmera E + V tem sido usada para avaliar carcaças, com o propósito de desenvolver e ajustar uma calibração para o sistema de classificação australiana MSA. À medida que os dados são coletados, o sistema de câmeras melhora sua capacidade de avaliar o marmoreio AusMeat. Atualmente, o sistema está passando pelo processo de credenciamento do AusMeat (Powe, 2019).

A câmera Meat Image Japan (MIJ), tem sido usada para avaliar as carcaças Wagyu no Japão. Avalia o *Longissimus dorsi* para fornecer uma previsão objetiva da pontuação de marmoreio, área do olho de lombo e outras características que a indústria japonesa Wagyu valoriza. Um exemplo semelhante de câmera está em utilização na Austrália para avaliação das carcaças de Wagyu. A câmera tem apresenta potencial para avaliar o marmoreio das carnes produzidas na Austrália, no entanto, ainda é necessário um contínuo desenvolvimento do software para se adequar à classificação da MSA.

A utilização de câmeras e análises de imagens tem se mostrado bastante promissor. Lu e Tan (2004) usaram preditores baseados em imagem para prever o rendimento de carne magra. Pipek et al. (2004) utilizaram a análise de imagem para estimar o teor de gordura de carcaças de bovinos. Os autores encontraram boa correlação entre o método químico de (Soxhlet) e os resultados obtidos pela análise de imagens. Sendo que a discriminação do tecido adiposo dos demais tecidos (conjuntivo, ossos) e o teor de brilho podem ser fatores limitantes.

Os sistemas E+V rib-eye camera e MIJ grading câmera, citados anteriormente empregam sistema de câmeras convencionais, e como tal, podem apresentar limitações quanto a diferenciar ossos e gordura, tudo pode ser interpretado como gordura ou marmoreio na imagem. Frente disso, as câmeras hiperespectrais ou multiespectrais também estão sendo avaliadas pela sua capacidade em contornar problemas de aplicação, tais como aqueles associados a inspeção e avaliação de qualidade, o que torna a utilização de tais câmeras à campo uma alternativa promissora para avaliação não-destrutiva de produtos agrícolas e alimentares, incluindo a qualidade da carne (Cluff et al., 2008; Konda Naganathan et al., 2008). As imagens hiperespectrais, já foram aplicadas em produtos cárneos, para a classificação de qualidade da carne suína (Qiao et al., 2007a, b), detecção de

tumores em carcaças de frangos (Park et al., 2007; Nakariyakul et. al, 2008), avaliação da qualidade de peixes (Sivertsen et al., 2009) e avaliação da maciez da carne bovina (Konda Naganathan et al., 2008).

Entre as tecnologias desenvolvidas com o objetivo de classificar as carcaças quanto ao conteúdo de gordura e carne magra, aquelas baseadas na diferença de condutividade elétrica entre o tecido muscular e adiposo são uma opção. A análise de impedância bioelétrica é baseada nessa diferença, neste sistema, eletrodos são inseridos na carcaça e uma corrente elétrica alternada (10Hz a 500kHz) é aplicada, o equipamento mede a resistência da carcaça e estima o conteúdo de carne magra e percentual de gordura de marmoreio de bovinos (Gomide et al., 2014).

A ultrassonografia, recentemente, também passou a ser aplicada na avaliação de carcaças na linha de abate. O ultrassom é uma tecnologia não invasiva que permite uma predição muito precisa da composição da carcaça e do rendimento em carne magra. Entretanto, a precisão na avaliação da gordura intramuscular nas carcaças é menor do que no animal vivo. Nesta técnica, um equipamento converte pulsos elétricos em ondas de alta frequência (ultrassom), que ao serem emitidas sobre as carcaças, sofrem uma reflexão parcial pelos tecidos menos densos, ou total em tecidos de alta densidade, como ossos. Um software integra as informações e transmite os dados recebidos em percentual de carne magra. A gordura de marmoreio da carne pode ser detectada por sinais mais fracos recebidos entre a gordura e os ossos, porém a tecnologia deve ser redesenhada para garantir uma precisão adequada dessa medida. Exemplos dessa tecnologia são aparelhos UltraForm e AutoForm, de empresa dinamarquesa Carometec A/S, para a avaliação de carcaças suínas. (Gomide et al., 2014).

A espectroscopia no infravermelho próximo (NIRS), é outra análise que pode ser utilizada para prever a qualidade da carne, esta é baseada na transmissão ou refletância da radiação através dos componentes principais das amostras (água, gordura e proteína). Atualmente, a tecnologia de medição por infravermelho é usada em laboratórios para análise de composição mineral em geologia, utilizado para prever a composição ou qualidade de diversas plantas (Norris, 1983), método para análise composicional de amostras homogêneas de tecidos animais (Kruggel et al., 1981; Lanza, 1983), entre outros. No mercado japonês, existem dispositivos NIRS utilizados na indústria de alimentos, para mensurar a qualidade da gordura

(composição de ácidos graxos saturados, insaturados, teor de ácido oleico, etc.) da carne suína e bovina. No entanto, ainda não está sendo amplamente utilizada em ambientes frigoríficos.

A espectroscopia Raman é outra tecnologia que está sendo avaliada. Esta é uma técnica que utiliza uma fonte de laser, que ao incidir sobre o objeto, é espalhada por ele, produzindo luz de energia semelhante ou de energia diferente da incidente. A luz que manteve a mesma frequência da luz incidente nada revela sobre as características do material, mas aquela que se diferenciou, nos permite conhecer a composição molecular deste. Assim, a espectroscopia Raman, proporciona, em poucos segundos, informação composicional (química e estrutural) de praticamente todo tipo de material, não sendo necessário fazer uma preparação especial e além disso, não promove alterações na superfície que se faz a análise. Neste sentido, a espectroscopia Raman tem potencial para medir características sensoriais, pH, conteúdo de ácidos graxos e beta-caroteno, perdas, entre outros (Boyacı et al., 2014; Nunes, 2019).

Existem ainda tecnologias que permitem medir o rendimento e a composição física e química das carcaças de animais, um exemplo disso é a utilização da absorciometria por raios-X com dupla energia (DEXA), esta fornece informações sobre ossos, massa gorda e massa muscular. No entanto, a medição de DEXA em bovinos de corte ainda está em um estágio inicial e, mais recentemente, tem sido utilizado para avaliação de carcaça de cordeiros (Brickell et al., 2018). Assis et al., (2019) utilizaram 15 novilhas Nelore com $263,66 \pm 62$ kg e 11 meses de idade, e desenvolveram equações para estimar a composição das carcaças a partir do uso do equipamento DEXA (GE Lunar Prodigy Advance Dxa System, GE Healthcare, Madison, Wisconsin, USA). As carcaças foram escaneadas e posteriormente totalmente dissecadas, separando-se ossos, músculos e gordura que foram quantificados individualmente. As correlações entre as variáveis DEXA e os respectivos valores observados na carcaça foram significativas ($P < 0,01$) e as equações de predição de ossos, músculo e gordura nas carcaças apresentaram coeficientes de determinação de 0,67, 0,95 e 0,97, respectivamente.

PROCESSAMENTO DE IMAGENS DIGITAIS

O Processamento de Imagens consiste em transformações sucessivas em imagens objetivando extrair as informações nela presente. É evidente que neste sentido processar uma imagem, como é feito pelo sistema visual humano (SVH), é extremamente complexo visto que o sistema deve responder a todas as situações. Os computadores atuais nos ajudam a melhor compreender estas tarefas e conseqüentemente modernizá-las e reproduzi-las.

Neste sentido, o processamento de imagens, é extremamente dependente do sistema no qual ele está associado, não existindo até o momento, sistemas de análise de imagens complexos e abrangente para todos os problemas. Geralmente as técnicas de processamento de imagens baseiam-se em métodos matemáticos que auxiliam no detalhamento quantitativo das imagens de diferentes origens, nos permitindo efetuar mensurações de área, perímetros, comprimentos, larguras, e etc, e em seguida deduzir grandezas estatísticas de uma forma automática.

A análise quantitativa e a interpretação das imagens representam atualmente um ponto de apoio importante em diversas disciplinas científicas, pois em todas estas disciplinas estamos na busca de informações quantitativas que representem o fenômeno estudado. Do ponto de vista da ótica, uma imagem é um conjunto de pontos que convergem para formar um todo, ou seja, a imagem é o suporte para troca de informações. Os métodos recentes de exploração automática desta informação permitiram o desenvolvimento de técnicas complexas, que podem ser globalmente classificadas em duas grandes linhas, análise da informação e técnicas de melhoria da imagem (do termo em inglês "*enhancement*", Albuquerque & Albuquerque; 2000).

O termo análise refere-se a parte do processamento onde ocorre a descrição das informações contidas na imagem. Nesta parte, diversas mensurações quantitativas (parâmetros) são utilizadas para descrever diferentes informações dentro de uma imagem. A complexidade e a necessidade em tempo de processamento, irão definir quais as técnicas serão dedicadas a análise de imagens.

O segundo ponto está associado a melhoria da qualidade da imagem. De uma forma geral, trabalha-se nos níveis de cinza da imagem, visando aumentar o contraste ou colocar em evidência alguma região de interesse particular (Região de

Interesse). Entende-se como Região de Interesse (ROI - "*Region Of Interest*" ou AOI - "*Area Of Interest*") a região definida automaticamente a partir de parâmetros obtidos na própria imagem (ou por um usuário) onde o processamento estará totalmente concentrado. Como exemplos deste tipo de técnica podemos citar a utilização de filtros espaciais, utilização de cores-falsas, subtração da imagem por uma imagem referência e a correção de deformações espaciais devido a ótica ou devido a variação da iluminação de fundo. Os sistemas dedicados a melhorar a qualidade da imagem trabalham geralmente muito rápido, pois são construídos em "*hardware*" ou software embarcado, permitindo rapidamente ao usuário um julgamento sobre várias imagens processadas, segundo o tipo de tratamento. Esta técnica é encontrada na maioria dos programas de tratamento de imagens ou fotografias que estão atualmente no mercado, com algoritmos implementados em software, para computadores.

A utilização destes métodos, neste caso, tem por objetivo desenvolver um sistema de tratamento da informação onde cada fase vai exigir métodos para retirar da imagem os parâmetros que expressem informação. Neste instante as fases de pré-tratamento podem ter um peso importante quando queremos favorecer o desempenho do sistema computacional. De maneira geral, um sistema de processamento e análise de imagens pode ser de uma maneira geral dividido nas seguintes etapas: Aquisição e digitalização de imagens, pré-processamento, segmentação, extração, classificação e reconhecimento de atributos. A seguir, serão apresentadas breves descrições de cada uma destas etapas.

Aquisição de imagens digitais

O processo de aquisição de uma imagem tem por objetivo a obtenção de uma imagem digital. Para que uma imagem digital seja adquirida são necessários: um instrumento formador de imagem e um digitalizador, que converterá a saída elétrica do dispositivo de sensoriamento físico para a forma digital (Gonzalez & Woods, 2002). Alguns exemplos de módulos de aquisição são: as câmeras, os scanners ou ainda alguns sensores dedicados (como sistemas de infravermelho, mapeamento magnético de uma superfície, sensoriamento de radares, etc).

O sensor de aquisição de imagem mais frequentemente utilizado é a câmera de vídeo, esta apresenta características de sensibilidade, resolução e função de

transferência entre a imagem capturada da cena e a intensidade do sinal de vídeo fornecido (Albuquerque & Albuquerque; 2000).

As imagens geradas podem ser classificadas como analógicas ou digitais de acordo com o princípio de funcionamento dos sensores de captura utilizados. Os dispositivos analógicos utilizam de um filme fotográfico construído de material fotossensível, que ao ser exposto a luminosidade devido a abertura do diafragma, permite que a imagem fique gravada nesse filme, denominado negativo. Já os dispositivos digitais baseiam-se na utilização de um sensor que converte a luz recebida pelo objeto em sinais elétricos. Câmeras mais sofisticadas permitem ajuste da iluminação de fundo, a correção do contraste da imagem, ou até realçar os contornos dos objetos através da execução de funções específicas, em tempo real.

Uma imagem digital pode ser definida como uma matriz, onde cada linha e coluna identifica um ponto, e possui o valor correspondente ao nível de cinza, ou à cor, naquele ponto da imagem. Esses elementos da matriz são os pixels (*"picture elements"*) que é o menor elemento de resolução da imagem. A forma mais comum para o pixel é a forma retangular ou quadrada, sendo que frequentemente, a organização de uma imagem sob a forma de uma matriz de pixels é feita em uma simetria quadrada. Isto se deve a facilidade de implementação eletrônica, seja dos sistemas de aquisição seja dos sistemas de visualização de imagens (Albuquerque & Albuquerque; 2000).

Pré-processamento

O pré-processamento objetiva melhorar a imagem, corrigindo algum defeito proveniente de sua aquisição e/ou realçando características importantes para a análise (Gomes, 2001). O pré-processamento é necessário para garantir que as imagens apresentem as mínimas imperfeições, e assim permita que a etapa de segmentação tenha resultados satisfatórios.

Comumente no pré-processamento de imagens, a correção de fundo é uma das operações mais utilizadas e envolve a utilização de filtros repetidas vezes na mesma imagem. Os filtros, são geralmente descritos através de matrizes de "convolução", neste caso deve-se escolher uma matriz de dimensão $n \times n$ com valores dependentes do filtro que se quer usar, seja ele passa baixa, passa faixa ou

passa alta. Em uma imagem, as baixas frequências correspondem as variações suaves dos níveis de cinza e as altas frequências correspondem as variações abruptas dos níveis de cinza, por exemplo as bordas dos objetos, assim quando se desejar evidenciar as bordas de um determinado objeto pode-se usar filtros do tipo passa-alta (Albuquerque & Albuquerque; 2000). Filtros passa-baixa podem ser utilizados quando se deseja eliminar todas as altas frequências correspondentes as bordas dos objetos e desse modo conseguir analisar a iluminação de fundo, caso esse seja o objeto de interesse. O filtro passa-baixa desfoca a imagem original produzindo uma estimativa do fundo irregular (Paciornik & Maurício, 2004)

Segmentação

Segmentar consiste em dividir a imagem em diferentes regiões que satisfaçam um critério de uniformidade (homogeneidade), permitindo tratar cada região individualmente, tornando-as regiões com propriedades significativas, facilitando a extração de dados, classificação e reconhecimento de atributos.

Inicialmente quando uma imagem é capturada, existem as informações pertencentes ao objeto de interesse e o plano de fundo, assim cada pixel na imagem pode ser segmentado nessas duas regiões. Neste caso, a imagem colorida é convertida em uma imagem com representação binária, na qual existem apenas dois valores possíveis para cada pixel, preto (região do objeto) e branco (a região do fundo da imagem). Essa conversão facilita a manipulação das imagens, principalmente por reduzir significativamente a quantidade de dados no processo de tratamento da informação (Queiroz & Gomes, 2006)

Existem diversos métodos para realizar a segmentação de imagens, porém não existe um único método que seja capaz de segmentar todos os tipos de imagens. No entanto, os métodos de segmentação podem ser complementares e dependendo da aplicação, podem ser combinados melhorando a qualidade final das imagens resultantes. A essas combinações dá-se o nome de técnicas híbridas (Comunello, 1999).

Os principais métodos são baseados em segmentação por limiarização, segmentação por bordas e segmentação por crescimento de regiões. A técnica de segmentação por limiarização trabalha com um limiar conhecido como threshold, o

qual define o nível de seleção dos pontos da imagem a incorporar-se em uma dada classe, por meio de valores máximos e mínimos. Uma das dificuldades do processo reside na determinação do valor mais adequado de limiarização, i.e., do ponto de separação dos pixels da imagem considerada. Através da análise do histograma da imagem, é possível estabelecer um valor para T na região do vale situado entre picos que caracterizam regiões de interesse na imagem (Queiroz & Gomes, 2006)

A técnica de segmentação por bordas procura-se separar as partículas umas das outras e do fundo (Gonzalez & Woods, 2002). Considera-se borda, toda e qualquer mudança brusca da luminosidade em uma imagem, o que permite localizar as extremidades dos objetos, visto que borda é o contorno entre um objeto e seu fundo (Gonzalez & Woods, 2002). Teoricamente a detecção de borda pode ser facilmente implementada, havendo para isso um número limitado de algoritmos que se utilizam de operadores sensíveis à descontinuidade abrupta, os quais irão operar como detector de borda. Os operadores responsáveis por essa função são os operadores de derivada, os quais irão atuar de maneira que onde a taxa de mudança dos níveis de cinza de uma imagem for grande, aquele pixel será considerado como um pixel de borda, e nas demais áreas, será considerado como sendo do corpo da imagem em si (Coser, 2009)

A segmentação por crescimento de regiões é uma técnica de segmentação baseada em região visam reunir num mesmo conjunto pixels adjacentes que atendem a um dado critério de heterogeneidade. Desta forma, regiões da imagem são agrupadas ou divididas dependendo de seus pixels terem ou não características semelhantes em termos de cor, textura ou forma (Happ et al., 2013). Nestes, seleciona-se um conjunto inicial de pixels denominados sementes. As regiões crescem a partir das sementes à medida que vão sendo agregadas a pixel ou a sub-regiões vizinhas que atendam a determinado critérios de heterogeneidades (Happ et al., 2013). As sementes podem ser selecionadas de maneira aleatória, determinística ou pelo usuário (Pedrini E Schwartz, 2008). São dificuldades inerentes a este método a definição do critério de parada, a dependência dos resultados em relação a escolha e a determinação das características apropriadas para a composição do critério de heterogeneidade. (Happ et al., 2013).

Extração, classificação e reconhecimento de atributos

Para construir um sistema de decisão que seja capaz de identificar e extrair as variáveis dos objetos de interesse é recomendado segmentar a imagem em regiões (objeto e fundo), obtendo assim dados mais relevantes. Se a etapa de classificação for aplicada diretamente sobre a imagem bruta, onde o volume de dados pode ser grande e conter informações desnecessárias, a aplicação pode se tornar inviável devido a um tempo de processamento demasiadamente longo e classificação não satisfatória.

Após a etapa de segmentação procede-se a fase de parametrização, fase essa que identifica e calcula parâmetros nos objetos segmentados. São exemplos de parâmetros pertinentes a um objeto o seu perímetro, área, largura, comprimento, entre outras. A etapa de extração de características filtra a parte mais importante dos dados para a etapa de classificação, o que acaba tornando essa tarefa dependente do processo de binarização. Assim, a qualidade das medidas obtidas será dependente de um eficiente sistema de reconhecimento de formas, e este deve ser o mais independente possível dos erros provenientes da segmentação ou da parametrização (Albuquerque & Albuquerque; 2000).

Em seguida, temos a etapa de classificação. Nessa etapa vários tipos de métodos podem ser aplicados, podendo, cada um, apresentar desempenho diferentes, para cada tipo de aplicação. Dentre os métodos mais comuns podemos citar as Máquinas de Vetor de Suporte, as Redes Neurais, o KNN (*K-Nearest Neighbour*), e Métodos Estatísticos como Naive Bayes. Existem ainda as variações de cada classificador que visam melhorar o desempenho para algum tipo aplicações com características específicas, o que indica que a escolha do classificador também poderá depender da aplicação (Aquino, 2017).

Por fim, temos a etapa de reconhecimento. Essa etapa é a parte do processamento que vai classificar os objetos a partir de informações encontradas na imagem, partindo, geralmente, de uma base de conhecimento previamente estabelecida. Os métodos de reconhecimento devem estabelecer um compromisso entre a eficiência e confiabilidade, além de possibilitarem revisão do conhecimento por meio da experiência adquirida.

REDES NEURAIS NO RECONHECIMENTO DE PADRÕES E PROCESSAMENTO DE IMAGENS

Redes neurais artificiais (RNAs) constituem um campo da ciência da computação ligado à inteligência artificial, que busca implementar modelos matemáticos que se assemelhem às estruturas neurais biológicas. Nesse sentido, apresentam capacidade de adaptar os seus parâmetros como resultado da interação com o meio externo, melhorando gradativamente o seu desempenho na solução de um determinado problema (Ferneda, 2006). O processamento neural permite extrair relações das variáveis de entrada sobre a dimensão que as caracterizam, tornando tal processamento uma ferramenta valiosa em problemas complexos de reconhecimento de padrões. As redes neurais podem trabalhar em conjunto com outras técnicas de processamento, assim, os dados podem ser pré-processados, destacando-se as informações de interesse e a rede neural será aplicada sobre esta, ao invés de trabalhar com os dados brutos, diminuindo dessa maneira a complexidade dos modelos neurais. As RNAs podem ser aplicadas em problemas de aproximação de funções, classificação e agrupamento de dados (Haykin, 2001), como também em situações onde existem interações não-lineares entre as variáveis dependentes e as independentes.

A ideia básica das redes neurais é construir um modelo composto por neurônios, onde ocorre o processamento básico das informações, sendo essas transmitidas através de conexões denominadas sinapses ou pesos sinápticos.

Diferentes arquiteturas de redes neurais são encontradas na literatura. Atualmente os modelos neurais artificiais mais conhecidos e utilizados são constituídos pela arquitetura do tipo perceptron de múltiplas camadas (*Multilayer Perceptron* – MLP, Silva et al., 2012). Tipicamente, essa arquitetura consiste de uma camada de entrada que distribui as informações de entrada para as camadas intermediárias (camadas escondidas) da rede. A última camada é a camada de saída, onde se obtém a solução do problema. A camada de entrada e a camada de saída podem ser separadas por uma ou mais camadas intermediárias, por onde os sinais de entrada são propagados da entrada para a saída. Nesse sentido, para implementarmos uma rede neural devemos determinar as seguintes variáveis: número de nós na camada de entrada, número de camadas escondidas e o número de neurônios a serem colocados nessas camadas, e número de neurônios na camada de saída. Todos estes parâmetros influenciam o desempenho da RNA e,

portanto, devem ser escolhidos atentamente (Santos et al., 2005).

O número de neurônios na camada de entrada representa o número de variáveis que serão utilizadas para alimentar a rede neural. O número de neurônios nas camadas escondidas é escolhido por meio de critérios de ajustamento-penalidade (complexity-regularization), que são análogos aos critérios estatísticos AIC (Akaike Information Criterion) e BIC (Bayesian Information Criterion), ou através da capacidade preditiva da rede (Santos et al., 2005 apud Rocha & Pereira, 1997).

Portanto, o número de neurônios na camada escondida é bastante variável, não havendo um critério geral que permita definir este. Redes neurais com poucos neurônios tendem a possuir melhor poder de generalização, diminuindo problemas de overfitting (sobreajuste). Esse problema ocorre quando, após o período de treinamento, a rede se especializa no conjunto de treinamento e perde a capacidade de generalização quando é utilizada para classificar os padrões pertencentes ao conjunto de teste (Santos et al., 2005). No entanto, um número reduzido de neurônios nas camadas escondidas pode proporcionar deficiências na capacidade de generalização da rede em problemas complexos, podendo ocorrer underfitting, ou seja, o modelo não se adapta nem aos dados de treinamento. Outras decisões a serem pensadas incluem: definição da função de ativação dos neurônios da camada escondida e da camada de saída, o algoritmo de treinamento e seus respectivos parâmetros, a transformação dos dados ou método de normalização, a seleção do conjunto de treinamento e conjunto de teste, o critério de parada do treinamento e a escolha de uma medida de desempenho da rede (Gevert et al., 2010).

A função de ativação, também chamada de função de transferência de um neurônio artificial, consiste de uma função para transformar o nível de ativação de um neurônio em sinal de saída. A função de ativação define o sinal de saída com base nos conjuntos de entrada. Em geral, a função de ativação limita os valores da saída do neurônio aos conjuntos 0,1 ou -1,1 no caso discreto ou aos intervalos [0,1] ou [-1,1] no caso contínuo. As funções de ativação comumente utilizadas são a Sigmoides, Tangente Hiperbólica (TanH), Unidade Linear Retificada (ReLU), Unidade Linear Exponencial (ELU) e Unidade Linear Retificada com Vazamento (Bittencourt, 2009; Goodfellow et al., 2016).

Ao implementarmos uma rede neural, normalmente o conjunto de dados é separado em conjunto de treinamento, conjunto de teste e conjunto de validação. O conjunto de treinamento deve ser constituído por uma amostragem representativa,

uma vez que este conjunto de dados serão utilizados para o treinamento, ajuste dos parâmetros da rede e comparação dos resultados obtidos com conjuntos de rótulos associados aos dados de entrada (Santos et al., 2005). O conjunto de teste é um novo conjunto de dados distinto, utilizado para verificar a capacidade de generalização da rede em condições reais (Santos et al., 2005). A habilidade de generalização da rede refere-se ao desempenho da rede ao classificar padrões do conjunto de teste. Deficiências na capacidade de generalização da rede podem ser atribuídas aos problemas de overfitting e underfitting (Santos et al., 2005).

O conjunto de validação objetiva verificar a eficiência da rede quanto a capacidade de generalização durante o treinamento, podendo, também, ser empregado como critério de parada do treinamento. Entretanto, em alguns casos o tamanho do banco de dados pode ser bastante reduzido, dificultando a divisão desse em três conjuntos (treinamento, teste e validação). Quando isso ocorre uma das alternativas para evitar o problema de overfitting é utilizar o método de validação cruzada (Hertz et al., 1991).

Uma vez especificada a arquitetura da rede, torna-se necessário definir o algoritmo de treinamento da rede. Existem inúmeros algoritmos de aprendizado específicos para determinados modelos de redes neurais, estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

Diversos métodos para treinamento supervisionado de RNA são descritos na literatura. Entretanto, o algoritmo de aprendizado da rede neural mais popularmente usado para esse tipo de treinamento é o algoritmo de retropropagação (backpropagation) (Haykin, 1999; Vieira, 2000). O algoritmo de backpropagation consiste em duas fases: uma fase de propagação do sinal (feedforward) e uma de retropropagação do erro (backpropagation). Na fase feedforward os dados de entrada são propagados através da rede aplicando uma série de dot products (multiplicação entre os vetores) e ativações até alcançar a camada de saída, onde é expressa a resposta da rede. Durante a fase feedforward, os pesos das conexões são mantidos fixos. Na retropropagação do erro, o objetivo é otimizar os pesos para que a rede neural possa aprender a mapear corretamente as entradas para as saídas, para isso a resposta da rede é subtraída da saída desejada para produzir um sinal de erro, que será propagado, camada a camada, da saída para a entrada. Assim os pesos serão ajustados de forma que o valor do erro entre a resposta da rede e a resposta desejada seja reduzido (Barros, 2018).

O critério de parada do treinamento deve considerar a capacidade de generalização da rede, uma vez que o treinamento prolongado pode promover sobreajuste à rede, prejudicando o desempenho da rede quando o conjunto de teste lhe for apresentado (Calôba, 1995). Além disso, a escolha da taxa de aprendizado também pode comprometer a eficiência de processamento da rede. Baixos valores da taxa de aprendizado tornam o treinamento lento, já valores elevados podem provocar divergência do processo de treinamento (Kleinbaum, 1994). Portanto, a fase de treinamento deve ser rigorosa e verdadeira, a fim de serem evitados modelos ilegítimos.

Redes Neurais Convolucionais

As redes neurais convolucionais (CNN) são redes neurais profundas utilizadas no âmbito de visão computacional, as quais utilizam a convolução no lugar da multiplicação geral da matriz em pelo menos uma de suas camadas (Goodfellow et al., 2016). Existem inúmeras variantes de arquiteturas CNN na literatura. No entanto, seus componentes básicos são muito semelhantes, consistindo em três tipos de camadas, as camadas convolucionais, subamostragem e totalmente conectadas (Gu et al., 2018).

A camada convolucional tem como objetivo aprender representações de recursos das entradas. A camada de convolução é composta de vários kernels de convolução (matrizes de filtros espaciais lineares) que são usados para calcular diferentes mapas de características, que é a matriz de saída da camada de convolução, relacionado com o filtro. O empilhamento dos diferentes mapas de características produzidos pelos kernels ao serem aplicados na entrada formam a saída da camada de convolução (Gu et al., 2018). Cada ponto na saída pode ser interpretado como a saída de um neurônio que está conectado a uma região na entrada e que compartilha os parâmetros com os neurônios no mesmo mapa de ativação. Após gerados os mapas de características, aplica-se uma função de ativação não-linear (Cavalcante, 2019).

A camada de subamostragem (pooling) visa atingir a invariância ao deslocamento, reduzindo a resolução espacial da informação gerada pela camada de convolução. Geralmente é colocado entre duas camadas convolucionais. Cada mapa de característica de uma camada de pooling é conectado ao seu mapa de feições correspondente da camada convolucional anterior (Gu et al., 2018). Uma

operação típica de *pooling* é a *max pooling* (Nielsen, 2015). Outros tipos incluem Average Pooling e L2 Pooling. A operação max-pooling nas CNNs modernas combina as respostas máximas dos mapas de características em uma distribuição conjunta resumida das características em alguma região de interesse (Boureau et al., 2010). O objetivo do max-pooling em CNNs tradicionais é reduzir o tamanho do espaço de parâmetro removendo informações redundantes enquanto preserva as respostas relevantes dos mapas de recursos convolucionais.

Diversas arquiteturas populares utilizando camadas max-pooling foram propostas nos últimos anos, como Alexnet (Krizhevsky et al., 2012), Fast-RCNN (Girshick, 2015), GoogleNet (Szegedy et al., 2015), ResNet (He et al., 2016) e assim por diante, o que demonstra a eficácia da operação de max-pooling para construir redes neurais profundas. Ao empilhar várias camadas convolucionais e pooling, pode-se extrair gradualmente representações de recursos de nível superior. Depois de várias camadas convolucionais e de pooling, pode haver uma ou mais camadas totalmente conectadas que visam realizar um raciocínio de alto nível (Gu et al., 2018)

A camada totalmente conectada é semelhante à maneira como os neurônios são organizados em uma rede neural tradicional. Cada nó em uma camada totalmente conectada está diretamente conectado a todos os nós na camada anterior e na próxima, ou seja, cada um dos nós na camada pooling são conectadas como um vetor à primeira camada da camada totalmente conectada (Albawi et al., 2017). Por fim, posteriormente às camadas totalmente conectadas, está a camada de saída. Camada essa que permite realizar a classificação de objetos em uma imagem, aplicando algum tipo de função de ativação (Karn, 2016), sendo a Softmax a mais utilizada nesta etapa (Araújo et al., 2017). A saída da função Softmax é equivalente a uma distribuição de probabilidade categórica, ou seja, ela informa a probabilidade de cada uma das classes ser verdadeira (Yang, 2017).

Treinamento da rede Neural convolucional

Inicialmente, todos os valores dos filtros das redes e os pesos das camadas totalmente conectadas são inicializados. Existem diversas maneiras de inicializar os pesos (Glorot; Bengio, 2010), podendo ocorrer seguindo algum método ou de maneira aleatória. Em seguida, a rede realiza o processo de propagação (convolução, função de ativação e pooling, além da propagação nas camadas

totalmente conectadas) sobre uma imagem de treinamento de entrada. Então, é calculado a probabilidade para cada classe de saída, assim como o erro total obtido na camada de saída. A backpropagation é a forma mais utilizada de treinamento da CNN (Haykin, 2001), de modo que o ajuste dos valores dos filtros e pesos são realizados na proporção que estes contribuem para o erro. Posteriormente, o processo de propagação e ajustes dos parâmetros são repetidos para todas as imagens do conjunto de treinamento, sendo chamado de “época” o conjunto total de imagens de treinamento que passam por este processo.

Existem classificações que dependem de quando o cálculo do erro será realizado e quando o algoritmo de aprendizado irá atualizar os parâmetros da rede. Frente disso, o conceito de batch e iteração são necessários. O batch é um grupo de amostras do conjunto de treinamento, de tamanho fixo, na qual ao final da passagem o erro é calculado e os ajustes feitos, enquanto a iteração é a quantidade de batches necessários para que seja completo uma época. Assim os algoritmos podem ser classificados em 3 classes distintas (Chaves, 2019):

Gradiente descendente batch: o tamanho do batch é igual ao tamanho do conjunto de treinamento, portanto, a atualização dos pesos somente ocorre após todos os dados passarem pela rede.

Gradiente descendente estocástico: o tamanho do batch é igual à 1, ou seja, a atualização dos pesos ocorre para todos as amostras do conjunto de dados.

Gradiente descendente mini-batch: o tamanho do batch é maior que 1 e menor que o tamanho do conjunto de dados. Normalmente, os mini-batches conhecidos e utilizados na literatura são 32, 64 e 128.

O término do treinamento ocorre quando a média do erro obtida pela rede na época atual seja inferior à um limiar ou o número de épocas seja atingido. O término do treinamento indica que a rede está apta para classificar as imagens do conjunto de treinamento de maneira ótima. O processo de treinamento apenas altera os valores dos filtros e pesos das camadas totalmente conectadas. O número de camadas, tamanho do filtro, o *stride* da convolução e o padding não são ajustados, esses são definidos anteriormente quando se define a arquitetura da rede (Chaves, 2019).

Padding se refere à quantidade de pixels adicionados a imagem quando ela está sendo processada pelo kernel de uma CNN. Se o padding em uma CNN for definido como zero, cada valor de pixel adicionado terá o valor zero.

Rede Completamente Convolutacional

A Rede Completamente Convolutacional (FCN) é semelhante a uma rede neural convolutacional (CNN). Porém, na arquitetura da rede completamente convolutacional a camada totalmente conectada, empregada para classificação, é substituída por outra camada de convolução, utilizada para classificar pixel-a-pixel da imagem. Portanto, a arquitetura da rede FCN pode ser utilizada para tarefa de segmentação semântica (semantic segmentation), isto é, o processo de atribuição de uma classe de objeto para cada pixel de uma imagem, permitindo capturar informações globais da cena e identificar qual a localização e objetos existentes na imagem (Long et al., 2015).

A arquitetura de uma rede FCN pode ser dividida em duas partes principais, o caminho de downsampling (reduz a dimensão da imagem utilizando etapas de pooling) e o caminho de upsampling (restitui a imagem para a sua resolução original). A FCN primeiro usa a rede neural convolutacional para extrair recursos de imagem, posteriormente transforma o número de canais no número de categorias através da camada de convolução 1×1 e, finalmente, transforma a altura e a largura do mapa de feições para o tamanho da imagem de entrada usando a camada de convolução transposta. A saída do modelo tem a mesma altura e largura da imagem de entrada e uma correspondência de um para um nas posições espaciais. O canal de saída final contém a previsão da categoria do pixel da posição espacial correspondente (Zhang, et al., 2019). De maneira resumida, a rede consegue reduzir a imagem utilizando camadas intermediárias e posteriormente reconstruí-la com interpolação e outras convoluções.

A FCN consegue segmentar a entrada da rede ao mesmo tempo em que a classifica, não sendo necessário utilizar outras técnicas de segmentação nas imagens, devido a isso, esta arquitetura tem sido amplamente difundida (Skeika, 2019). Um dos problemas dessa arquitetura de rede é que ao propagar a informação por diversas camadas alternadas de convolução e de pooling, a resolução de saída do mapa de característica é reduzida. Portanto, as estimativas obtidas pela rede geralmente apresentarão baixa resolução, resultando em bordas de objetos relativamente imprecisos (Le, 2017).

ARQUITETURA DE REDES CNN

Existem na literatura diversas arquiteturas de redes CNN. Abaixo será

apresentado um detalhamento sobre as principais diferenças entre as redes VGG, ResNet, DenseNet e U-Net, normalmente utilizadas. Estas são aplicadas para resolução de diversos problemas de visão computacional e processamento de imagens.

Rede Neural Convolucional – VGG

O VGG foi desenvolvido para melhorar a precisão da classificação, aumentando a profundidade das CNNs (Simonyan & Zisserman, 2014). A rede VGG recebe a entrada de imagens RGB 224×224 e as passa através de camadas convolucionais consecutivas com filtros de dimensão 3×3 , seguidas de uma camada de max-pooling (Simonyan & Zisserman, 2014). Por fim, após as camadas convolucionais, são seguidas 3 camadas totalmente conectadas, com 4096, 4096 e 1000 canais, respectivamente. Algumas das desvantagens da rede VGG é que ela consome muito tempo computacional, utiliza muita memória e é estruturada com um grande número de parâmetros (Hulstaert, 2018).

Rede Neural Convolucional – ResNet

Redes Neurais Convolucionais Residuais (ResNet, He et al., 2015) possibilitam desenvolver redes neurais mais profundas do que CNNs tradicionais, mas com complexidade inferior à redes menos profundas (Pereira, 2017). Erroneamente, pode-se deduzir que o aumento no número de camadas proporciona redes com maior capacidade de generalização e aprendizado. Contudo, à medida que a rede se aprofunda, o desempenho pode ficar saturado ou começar a degradar rapidamente (He & Sun, 2015; Srivastava et al., 2015; He et al., 2015). A solução encontrada para contornar esse problema, foi baseada em aprendizado utilizando blocos residuais, onde as camadas de uma dada rede têm de aprender resíduos adicionais ao conteúdo de entrada da rede (HE et al., 2015).

Dentro dos blocos, existem skip connections que permitem realizar o mapeamento das informações via operação de identidade e conecta a saída da camada anterior com a camada posterior, enquanto que no mapeamento original é efetuada as operações de convolução e função de ativação ReLU. Ao final de cada bloco residual, o mapeamento realizado pelas operações de convolução e função de ativação ReLU é somado ao mapeamento por identidade. A saída do bloco residual pode ser representada por: $H(x) = F(x) + x$. Onde: $H(x)$ é a saída de cada bloco

residual, $F(x)$ é a função que demonstra as operações de convolução seguida da função de ativação ReLU e x é a entrada contendo a matriz com os mapas de características. Assim sendo, os gradientes da função de custo conseguem fluir para as camadas iniciais via skip connections. Neste tipo de rede, a camada de max-pooling é substituída por sucessivas camadas de convolução com stride de 2, o que faz com que a resolução espacial diminua pela metade (Cavalcante, 2019).

O aprendizado residual pode ser dividido em atalho de identidade e atalho de projeção. Os atalhos de identidade podem ser usados diretamente quando a entrada e saída são das mesmas dimensões. Quando as dimensões mudam, o atalho ainda executa o mapeamento de identidade, com entradas extras de zero preenchidas com a dimensão aumentada. O atalho de projeção é usado para coincidir com a dimensão (Marques Junior, 2019).

Rede Neural Convolutacional – DenseNet

A rede DenseNet original é composta por 4 blocos densos, com camadas de transição e uma camada de classificação final, caso esteja trabalhando em tarefa de classificação de imagens. As camadas de transição são camadas entre dois blocos adjacentes, e que modificam os tamanhos dos mapas de recursos por meio de convolução e pooling. O tamanho dos blocos densos é a única coisa que muda para cada versão da DenseNet para tornar a rede mais profunda (Huang et al., 2017).

Nesses blocos densos, cada camada pega todos os mapas de recursos anteriores como entrada, ajudando assim o processo de treinamento ao aliviar o problema do gradiente de desaparecimento. Esse problema de gradiente de desaparecimento aparece em redes realmente profundas, quanto maior a profundidade da rede, maior é o caminho para que a informação flua da camada de entrada até a camada de saída, fazendo com que a propagação dos gradientes, que fluem em direções opostas, diminua a cada etapa e eventualmente torna-se 0. Essas conexões permitem que o erro seja propagado entre as camadas mesmo este sendo demasiadamente reduzido. As conexões permitem ainda reduzir o número de parâmetros totais da rede, visto que se reutiliza informações de mapas de recursos anteriores em vez de gerar novos parâmetros, reduzindo a probabilidade de ocorrência de overfitting (Huang et al., 2017).

Rede Neural Convolutacional – U-Net

A U-Net foi desenvolvida para proporcionar segmentações mais precisas em pequenos conjuntos de treinos Ronneberger et al. (2015). É uma rede só com camadas de convolução e não têm a camada totalmente conectada. Este tipo de arquitetura conhecida como Encoder-Decoder é formado por camadas de contração e expansão, apresentando uma simetria entre estas camadas, tomando um formato de "U" (Almeida, 2017). A combinação entre os mapas de características do decoder (expansão) e seus correspondentes simétricos no encoder (contração), permite a rede aprender a informação e localização dos conteúdo na imagem.

O caminho de contração segue a arquitetura típica de uma rede convolutacional, isto é, aplicação repetida de duas convoluções com kernel 3x3. Cada uma seguida por uma função de ativação ReLU (Unidade Linear Retificada) e uma operação de max pooling com kernel 2x2 e stride de 2 para para redução da amostragem (downsampling). Em cada etapa de downsampling, dobra-se o número de neurônios. O caminho de expansão consiste em um aumento de amostragem do mapa de características (upsampling) seguido por uma convolução com kernel 2x2 que dividirá pela metade o número de neurônios. Uma concatenação é realizada com o mapa de característica recortado do caminho de contração e duas convoluções, com kernel 3x3 cada uma, seguidas por uma ReLU. Na camada final, uma convolução de 1x1 é usada para mapear cada vetor de recurso de 64 componentes para o número desejado de classes. No total, a rede tem 23 camadas convolucionais. Para permitir um mosaico uniforme do mapa de segmentação de saída, é importante selecionar o tamanho do bloco de entrada de forma que todas as operações de maxpool de 2x2 sejam aplicadas a uma camada com tamanhos pares de x e y (Ronneberger et al., 2015).

Rede Mask R-CNN

A Mask R-CNN (He et al., 2017), é um modelo melhorado da Rede Faster R-CNN (Girshick, 2015) por adicionar a rede a capacidade de gerar a máscara do objeto. A Faster R-CNN consiste em duas etapas, na primeira, o backbone convolutacional é responsável pela delimitação dos objetos e extração de recursos. A segunda etapa, realiza a classificação e regressão. A Mask R-CNN adota as mesmas duas etapas da Rede Faster R-CNN, com o primeiro estágio idêntico. Dentro da segunda etapa, em paralelo ao reconhecimento da caixa delimitadora

(classificação e regressão) a Mask R-CNN também produz uma máscara binária para cada região de interesse (He et al., 2017).

Nessa arquitetura, a rede de backbone pode ser qualquer rede que extraia recursos da imagem, como ResNeXt (Xie et al., 2017) e ResNet (He et al., 2016) com profundidade de 50 ou 101 camadas. Além disso, para realizar a detecção em várias escalas, uma rede em pirâmide de recursos (Lin et al. 2017, Feature Pyramid Network-FPN) pode ser usada na rede de backbone. A FPN usa uma arquitetura composta por uma via de baixo para cima, uma via de cima para baixo e conexões laterais para construir uma pirâmide de recursos na rede a partir de uma única entrada. A rede FPN baseado em ResNet-101 (Hariharan et al., 2014) tem sido usada como backbone por alcançar ganhos em precisão e velocidade (Lin et al., 2017; Hariharan et al., 2014).

Diferentes arquiteturas de Rede Mask R-CNN têm sido propostas na literatura para solucionar problemas com monitoramento de pragas (Júnior & Rieder, 2020), avaliação de frutas (Santos et al., 2020), segmentação de animais (Qiao et al., 2019; Bello et al., 2021; Tu et al., 2021), entre outros, apresentando resultados satisfatórios.

AVALIAÇÃO DOS CLASSIFICADORES

Os diferentes métodos de aprendizado, após o treinamento, devem ser avaliados para que possam ser comparados. Para isso, algumas métricas são utilizadas em problemas de classificação.

Matriz de confusão

A matriz de confusão é uma ferramenta que permite analisar de forma rápida o desempenho de cada sistema. Os valores que compõem a matriz são obtidos fornecendo os dados do conjunto de teste ao método de classificação e comparando sua predição com os rótulos reais (observado). Após a comparação os valores são classificados em quatro possíveis opções: Verdadeiro Positivo (VP): Amostras que pertencem a classe positiva (X) e foram classificados como positivos (X). Falso Positivo (FP): Amostras que pertencem a classe negativa (Y) e foram classificados como positivos (X). Falso Negativo (FN): Amostras que pertencem a classe positiva (X) e foram classificados como negativos (Y). Verdadeiro Negativo (VN): Amostras que pertencem a classe negativa (Y) e foram corretamente classificados como

negativos (Y). Bons resultados são caracterizados por altos valores na diagonal principal e valores nulos para elementos fora da diagonal principal (Bittencourt, 2009).

Métricas de qualidade

Existem diversas métricas utilizadas para a avaliação dos modelos de classificação. Cada uma delas busca avaliar um aspecto diferente do modelo. As mais comuns são: acurácia, precisão, sensibilidade, especificidade, jaccard, coeficiente de similaridade Dice

Acurácia: É a probabilidade de acerto do classificador. É calculada a partir das proporções de verdadeiros positivos e verdadeiros negativos sobre todos os casos avaliados.

$$AC = \frac{VP + VN}{VP + FP + VN + FN}$$

Precisão: quantidade de segmentos que, dentre todos os segmentos classificados como positivos, pertencem a classe positiva.

Sensibilidade: é a habilidade de classificar corretamente as carcaças pertencentes à determinada categoria, é a taxa de verdadeiro positivo.

$$S = \frac{VP}{VP + FN}$$

Especificidade: é a habilidade de classificar corretamente as carcaças que não pertencentes à determinada categoria, é a taxa de verdadeiro negativo.

$$E = \frac{VN}{VN + FP}$$

F-Measure (F1): é a média harmônica entre sensibilidade e especificidade.

$$F1 = \frac{2 * S * E}{(S + E)}$$

O ponto de máximo para as métricas de acurácia e F1 ocorre quando o verdadeiro positivo e verdadeiro negativo tendem para 1.

Equação do Jaccard (J): é definido como a intersecção entre a verdade fundamental (ground truth) e a imagem segmentada pelo algoritmo, sendo dividida pelo total de pixels no conjunto de classificações.

$$J = \frac{VP}{VP + FP + FN}$$

Coeficiente de Similaridade Dice (DSC): é definido como a intersecção entre a

verdade fundamental (ground truth) e a imagem segmentada pelo algoritmo, dividido pelo volume médio dessas duas regiões.

$$DSC = \frac{2(VP)}{2VP + FP + FN}$$

CONSIDERAÇÕES FINAIS

Conforme apresentado neste capítulo, existem algumas técnicas que são utilizadas para avaliar a qualidade da carcaça. As soluções utilizadas baseiam-se em observações visuais e em alguns casos, medidas objetivas obtidas a partir de sistemas de análise de imagens e uso de redes neurais. Este último, apresenta como principal vantagem a redução considerável no tempo das operações. Vantagens adicionais podem ser observadas, como facilidade na interpretação dos dados e robustez das avaliações devido a diminuição de equívocos que podem ocorrer durante a avaliação subjetiva.

Dentro deste contexto, os próximos capítulos apresentarão a utilização de processamento de imagens e redes neurais, aplicados na identificação de padrões que podem ser utilizados para o desenvolvimento de software para a classificação de carcaças *in vivo* ou na linha de abate.

REFERÊNCIAS

- ABIEC - Associação Brasileira das Indústrias Exportadoras de Carne (2018). Protocolos, tipificar e classificar. Disponível em: https://www.gov.br/agricultura/pt-br/assuntos/camaras-setoriais-tematicas/documentos/camaras-setoriais/carne-bovina/2018/50a-ro/2018_tipificar-e-classificar-06-04-2018.pdf. Acesso: 23 de junho de 2021.
- Albawi, S., Mohammed, T. A., Al-Zawi, S. (2017). Understanding of a convolutional neural network. In 2017 International Conference on Engineering and Technology (ICET), Antalya, pp. 1-6. Doi: 10.1109/ICEngTechnol.2017.8308186
- Albuquerque, M. P., Albuquerque, M. P. (2000). Processamento de imagens: Métodos e Análises Centro Brasileiro de Pesquisas Físicas. Rio de Janeiro. Disponível em: <http://www.cbpf.br/~mpa/curso2.htm>. Acesso em 29/01/2020.

- Allen, P., Finnerty, N. (2000). Objective Beef Carcass Classification: A Report of a Trial of Three VIA Classification Systems. The National Food Centre, Teagasc and Department of Agriculture, Food and Rural Development, Dublin, Ireland.
- Almeida, C. F. P. (2017). Mapeamento da Distribuição Populacional Através da Detecção de Áreas Edificadas em Imagens de Regiões Heterogêneas do Google Earth Usando Deep Learning. PUC-Rio, Departamento de Informática. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/livros/liv101427.pdf>. Acesso em: 19 de Janeiro de 2021.
- Anderson, F., Williams, A., Pannier, L., Pethick, D. W., Gardner, G. E. (2015). Sire carcass breeding values affect body composition in lambs. Effects on lean weight and its distribution within the carcass as measured by computed tomography. *Meat science*, 108, 145-154.
- Aquino, J. H. N. D. (2017). Extração de características de imagens para classificação da qualidade de couro caprino usando padrão binário local. Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Ciências, Programa de Pós-Graduação em Ciência da Computação, Fortaleza, 2017. Disponível em: <http://www.repositorio.ufc.br/handle/riufc/30005>. Acesso em: 04/03/2020.
- Araújo, F. H., Carneiro, A. C., Silva, R. R., Medeiros, F. N., Ushizima, D. M. (2017). Redes neurais convolucionais com tensorflow: Teoria e prática. Sociedade Brasileira De Computação. III Escola Regional de Informática do Piauí. Livro Anais-Artigos e Minicursos, 1, 382-406.
- Assis, G. D. F., Godoi, L. A., Filho, S. V., Silva, B. D. C., Assis, D. D. F., Chizzotti, M. L. (2019). Prediction of beef carcass physical and chemical composition by dual-energy x-ray absorptiometry. In *EAAP Scientific Series* (pp. 425-426). Wageningen Academic Publishers. DOI: 10.3920/978-90-8686-891-9_131.
- Barros, V. P. A. (2018). Avaliação do desempenho de algoritmos de retropropagação com redes neurais artificiais para a resolução de problemas não-lineares (Master's thesis, Universidade Tecnológica Federal do Paraná).
- BCRC - Beef Cattle Research Council (2019). Carcass grading. Disponível em:

- <http://www.beefresearch.ca/research-topic.cfm/carcass-grading-41>. Acesso em: 08 de julho de 2021.
- Bello, R. W., Mohamed, A. S. A., Talib, A. Z. (2021). Contour Extraction of Individual Cattle From an Image Using Enhanced Mask R-CNN Instance Segmentation Method. *IEEE Access*, 9, 56984-57000.
- Bittencourt, C. D. R. (2009). Classificação automática do acabamento de gordura em imagens digitais de carcaças bovinas. Disponível em: https://repositorio.unb.br/bitstream/10482/4958/1/Dissertacao_Carmen_Bittencourt.pdf. Acesso em: 19 maio 2020.
- Bottou, L. (1998). Online learning and stochastic approximations. *On-Line Learning in Neural Networks*, 17(9), 142–177.
- Bottou, L. (2010). Large-scale machine learning with stochastic gradient descent. In *Proceedings of the International Conference on Computational Statistics* (pp. 177–186). Berlin: Physica-Verlag Heidelberg.
- Boureau, Y. L., Ponce, J., LeCun, Y. (2010). A theoretical analysis of feature pooling in visual recognition. In *Proceedings of the 27th international conference on machine learning (ICML-10)*, pp. 111-118.
- Boyacı, I. H., Temiz, H. T., Uysal, R. S., Veliöğlü, H. M., Yadegari, R. J., Rishkan, M. M. (2014). A novel method for discrimination of beef and horsemeat using Raman spectroscopy. *Food chemistry*, 148, 37-41. doi: 10.1016/j.foodchem.2013.10.006.
- Brickell, C., Glendenning, R., Kennedy, G., Cook, J., Soundy, A. Scott Technology Ltd (2018). P.PSH.0888 - Lamb and Beef X-Ray Data Extended Ocm Benefits and Transportability For Cutting Beef, Meat and Livestock Australia Limited. Locked Bag 1961.
- Bridi, A. M. (2019). Fatores que afetam a qualidade e o processamento dos produtos de origem animal. SD. Disponível em:< <http://www.uel.br/pessoal/ambridi/Carnesecarcacasarquivos/FATORESQUEAFE TAMAQUALIDADEDACARNE.pdf>> Acesso em: 13 jul. 2019.
- Bridi, A. M. (2002). Normas de avaliação, classificação e tipificação de carnes e carcaças. Univ. Est. Londrina. Disponível em: <http://www.uel.br/pessoal/ambridi/Carnesecarcacasarquivos/Avaliacaocarcacabovinosuinoeaves.pdf>. Acesso em: 18 julho 2020.

- Calôba, L. P. (1992). Introdução à computação neuronal. In Anais do 9º Congresso Brasileiro de Automação (pp. 25-38).
- Cardoso, L. L. (2013). Estimativas do rendimento comercial de novilhos com a utilização de ultrassom. (Master's thesis, Universidade Federal do Rio Grande do Sul).
- Cartaxo, F. Q., Sousa, W. H. D., Cezar, M. F., Costa, R. G., Cunha, M. D. G. G., Gonzaga Neto, S. (2011). Características de carcaça determinadas por ultrassonografia em tempo real e pós-abate de cordeiros terminados em confinamento com diferentes níveis de energia na dieta. *Revista Brasileira de Zootecnia*, 40(1): 160-167.
- Cavalcante, M. C. (2019). Segmentação De Imagens De Lesões De Pele Usando A Rede Neural Convolutacional U-Net. Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo. Disponível em:
https://ele.ufes.br/sites/engenhariaeletrica.ufes.br/files/field/anexo/projeto_de_graduacao_ii_-_matheus_coutinho_cavalcantes.pdf. Acesso em: 23 de setembro de 2020.
- Chaves, E. D. L. (2019). Detecção de câncer de mama por meio de imagens infravermelhas utilizando Redes Neurais Convolucionais. Disponível em: <https://repositorio.ufu.br/handle/123456789/25938>. Acesso em: 22 de janeiro de 2021.
- Clelland, N., Bungler, L., McLean, K. A., Conington, J., Maltin, C., Knott, S., Lambe, N. R. (2014). Prediction of intramuscular fat levels in Texel lamb loins using X-ray computed tomography scanning. *Meat Science*, 98(2), 263-271.
- Cluff, K., Naganathan, G. K., Subbiah, J., Lu, R., Calkins, C. R., & Samal, A. (2008). Optical scattering in beefsteak to predict tenderness using hyperspectral imaging in the VIS-NIR region. *Sensing and Instrumentation for Food Quality and Safety*, 2(3), 189-196. <https://doi.org/10.1007/s11694-008-9052-2>.
- Comunello, E. (1999). Desenvolvimento de uma metodologia computacional para a identificação, contagem e mensuração de calcificações relacionadas com neurocisticercose em imagens de tomografia computadorizada. Florianópolis, Santa Catarina, Brasil: UFSC.

- Comunidade Européia (2017). Regulamento Delegado (Ue) 2017/1182. Grelhas Da União Para A Classificação De Carcaças. Jornal Oficial da União Europeia. Disponível em: <https://eur-lex.europa.eu/legal-content/PT/TXT/PDF/?uri=CELEX:32017R1182&from=LV>. Acesso em: 10 de julho de 2021.
- Coser, L. (2009). Filtro de difusão anisotrópico orientado por evidência de borda. Tese de Mestrado, Departamento de Ciência da Computação - Universidade Federal de Santa Catarina, Florianópolis, SC - Brasil.
- Costa, E. C. D., Restle, J., Pascoal, L. L., Vaz, F. N., Alves Filho, D. C., Arboitte, M. Z. (2002). Desempenho de novilhos Red Angus superprecoce, confinados e abatidos com diferentes pesos. *Revista Brasileira de Zootecnia*, 31, 129-138.
- Craigie, C. R., Navajas, E. A., Purchas, R. W., Maltin, C. A., Bünger, L., Hoskin, S. O., Ross, D. W., Morris, S. T., Roehe, R. (2012). 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 subjective systems. *Meat Science*, 92(4), 307–318. Doi: 10.1016/j.meatsci.2012.05.028.
- Júnior, T. D. C., Rieder, R. (2020, November). Uma Implementação Baseada em Mask R-CNN para Detecção de Insetos em Imagens Digitais. In *Anais Estendidos do XXXIII Conference on Graphics, Patterns and Images* (pp. 139-142). SBC. Doi: 10.5753/sibgrapi.est.2020.12996.
- de Queiroz, J. E. R., Gomes, H. M. (2006). Introdução ao processamento digital de imagens. *Rita*, 13(2), 11-42.
- Queiroz, S. A., Dibiasi, N. F., Tholon, P., Barrozo, D. (2010). Estimativas de correlações genéticas entre características de carcaça medidas por ultrassonografia e por escores visuais em touros Brangus. *Ars Veterinaria*, 26(1), 32-37.
- Faria, C. U., Magnabosco, C. D. U., de Albuquerque, L. G., Los Reyes, A. D., Saueressig, M. G., Lôbo, R. B. (2007). Utilização de escores visuais de características morfológicas de bovinos nelore como ferramenta para o melhoramento genético animal. *Embrapa Cerrados-Documents (INFOTECA-E)*. Cerrados, 40 p. ISSN 1517 - 5111

- Faulkner, D. B. (1990). Body condition scoring beef cows. In: Winter Beef Meetings. Proceedings. Urbana-Champaign: Department of Animal Sciences, p. 11-16.
- Ferneda, E. (2006). Redes neurais e sua aplicação em sistemas de recuperação de informação. *Ciência da Informação*, 35, 25-30. <https://doi.org/10.1590/S0100-19652006000100003>.
- Gevert, V. G., da Silva, A. C. L., Gevert, F., Ales, V. T. (2010). Modelos de regressão logística, redes neurais e support vector machine (svm s) na análise de crédito a pessoas jurídicas. *RECEN-Revista Ciências Exatas e Naturais*, 12(2), 269-293.
- Girshick, R. (2015). Fast r-cnn. In Proceedings of the IEEE international conference on computer vision (pp. 1440-1448). Doi: 10.1109/ICCV.2015.169.
- Glorot, X., Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. In Proceedings of the thirteenth international conference on artificial intelligence and statistics (pp. 249-256). JMLR Workshop and Conference Proceedings.
- Gomes, O. D. F. M. (2001). Processamento e análise de imagens aplicados à caracterização automática de materiais. Rio de Janeiro: Dissertação (Mestrado em Ciências da Engenharia Metalúrgica). Pontifícia Universidade Católica do Rio de Janeiro.
- Gomide, L. A. M.; Ramos, E. M.; Fontes, P. R. (2014). Tecnologia de abate e tipificação de carcaças, 2 ed. Rev. e ampl. Viçosa: UFV. 336p.
- Gonçalves, C. A., Sakomura, N. K., da Silva, E. P., Artoni, S. M. B., Suzuki, R. M., Gous, R. M. (2019). Dual energy X-ray absorptiometry is a valid tool for assessing in vivo body composition of broilers. *Animal Production Science*, 59(5), 993-1000. Doi: 10.1071/an17637.
- Gonzalez, R. C., Woods, R. E. (2002). Digital image processing.
- Goodfellow, I., Bengio, Y., Courville, A. (2016). Deep learning. MIT press. Disponível em: <<http://www.deeplearningbook.org>>. Acesso em: 01 de setembro de 2021.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X.,

- Wang, G., Cai, J., Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354-377. doi.org/10.1016/j.patcog.2017.10.013.
- Happ, P. N., Feitosa, R. Q., Bentes, C., Farias, R. (2013). Um algoritmo de segmentação por crescimento de regiões para GPUs. *Boletim de Ciências Geodésicas*, 19 (2): 208-226.
- Hariharan, B., Arbeláez, P., Girshick, R., & Malik, J. (2014). Simultaneous detection and segmentation. In *European conference on computer vision* (pp. 297-312). Springer, Cham.
- Haykin S. (1999). *Neural Networks: A comparative Foundation*. New Jersey: Prentice Hall.
- Haykin, S. (2001). *Redes Neurais: princípios e prática*, 2ª edição, tradução: Paulo Martins Engel. Editora: Bookman, Porto Alegre, Cap, 1(2), 3.
- He, K., Gkioxari, G., Dollár, P., Girshick, R. (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 2961-2969).
- He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778). Doi: 10.1109/CVPR.2016.90.
- He, K., Sun, J. (2015). Convolutional neural networks at constrained time cost. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 5353-5360).
- Heggli, A., Gangsei, L. E., Røe, M., Alvseike, O., Vinje, H. (2021). Objective carcass grading for bovine animals based on carcass length. *Acta Agriculturae Scandinavica, Section A - Animal Science*, 70:2, 113-121, DOI: 10.1080/09064702.2021.1906940.
- Hertz, J., Krogh, A., Palmer, R. G. (1991). *Introduction to the Theory of Neural Computation*, New York Addison-Wesley Publishing Company.
- Hinton, G. E.; Srivastava, N.; Krizhevsky, A.; Sutskever, I.; Salakhutdinov R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. arXiv preprint arXiv:1207.0580.
- Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708). Disponível em: <https://arxiv.org/pdf/1608.06993.pdf>. Acesso: 06 de janeiro 2021.

- Hulstaert, L (2018). Going deep into image classification, Toward Data Science. Disponível em: <https://towardsdatascience.com/an-overview-of-image-classification-networks-3fb4ff6fa61b>. Acesso em: 30 de abril de 2020
- Hunter, T. E., Suster, D., Dunshea, F. R., Cummins, L. J., Egan, A. R., Leury, B. J. (2011). Dual energy X-ray absorptiometry (DXA) can be used to predict live animal and whole carcass composition of sheep. *Small Ruminant Research*, 100(2-3), 143-152. doi: 10.1016/j.smallrumres.2011.07.003
- 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 freqüente. Clipping eletrônico. Belo Horizonte, 11 abr 2010.
- Ioffe, S., Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning* (pp. 448-456). PMLR.
- JMGA - Japan Meat Grading Association (2008). Beef Carcass Grading Standard. Disponível em: https://wagyu.org/uploads/page/JMGA%20Meat%20Grading%20Brochure_english.pdf. Acesso em: 08 julho de 2021.
- Johansen, J., Egelanddal, B., Røe, M., Kvaal, K., Aastveit, A. H. (2007). Calibration models for lamb carcass composition analysis using computerized tomography (CT) imaging. *Chemometrics and Intelligent Laboratory Systems*, 87(2), 303-311.
- Jones, H. E., Lewis, R. M., Young, M. J., Wolf, B. T. (2002). The use of X-ray computer tomography for measuring the muscularity of live sheep. *Animal Science*, 75(3), 387-399.
- Karn, U. (2016). An intuitive explanation of convolutional neural networks. The data science blog. Disponível em: <<https://ujjwalkarn.me/2016/08/11/intuitive-explanation-convnets>>. Acesso em: 22 outubro de 2020.
- Zeoula, L. M., Prado, I. N. D., Silva, D. C. D., Ducatti, T., Matsushita, M. (2008). Quantitative and qualitative carcass characteristics of heifers fed different energy sources on a cottonseed hulls and soybean hulls based diet. *Revista Brasileira de Zootecnia*, 37(2), 350-357.
- Kleinbaum D.G (1994). *Logistic Regression - A Self-Learning Text*. New York: Spring

Verlag.

- Konda Naganathan, G., Grimes, L. M., Subbiah, J., Calkins, C. R., Samal, A., Meyer, G. E. (2008). Visible/near-infrared hyperspectral imaging for beef tenderness prediction. *Computers and electronics in agriculture*, 64(2), 225-233.
- Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105. Doi: 10.1145/3065386.
- Kruggel, W. G., Field, R. A., Riley, M. L., Radloff, H. D., Horton, K. M. (1981). Near-infrared reflectance determination of fat, protein, and moisture in fresh meat. *Journal of the Association of Official Analytical Chemists*, 64(3), 692-696.
- Lambe, N. R., Conington, J., McLean, K. A., Navajas, E. A., Fisher, A. V., Bünger, L., Sustainable Livestock Systems Group, SAC. (2006). In vivo prediction of internal fat weight in Scottish Blackface lambs, using computer tomography. *Journal of Animal Breeding and Genetics*, 123(2), 105-113.
- Lanza, E. (1983). Determination of moisture, protein, fat, and calories in raw pork and beef by near infrared spectroscopy. *Journal of Food Science*, 48(2), 471-474.
- Le, J. (2018). How to do Semantic Segmentation using Deep learning. Disponível em: < <https://medium.com/nanonets/how-to-do-image-segmentation-using-deeplearning-c673cc5862ef>>. Acesso em: 15 novembro de 2020.
- Lee, H., Tajmir, S., Lee, J., Zissen, M., Yeshiwas, B. A., Alkasab, T. K., Do, S. (2017). Fully automated deep learning system for bone age assessment. *Journal of digital imaging*, 30(4), 427-441.
- Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., Belongie, S. (2017). Feature pyramid networks for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2117-2125).
- Long, J., Shelhamer, E., Darrell, T. (2015). Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3431-3440).
- López-Campos, Ó., Roberts, J. C., Larsen, I. L., Prieto, N., Juárez, M., Dugan, M. E., Aalhus, J. L. (2018). Rapid and non-destructive determination of lean fat and bone content in beef using dual energy X-ray absorptiometry. *Meat science*, 146, 140-146. doi: 10.1016/j.meatsci.2018.07.009.

- Luchiari Filho, A. (2000). *Pecuária da Carne Bovina São Paulo: A. Luchiari Filho* (134 pp.).
- Machado, R., Corrêa, R. F., Barbosa, R. T., Bergamaschi, M. A. C. M. (2008). *Escore da condição corporal e sua aplicação no manejo reprodutivo de ruminantes. Embrapa Pecuária Sudeste-Circular Técnica (INFOTECA-E).*
- Magnabosco, C. D. U., Sainz, R. D., Faria, C. U., Yokoo, M. J., Manicardi, F., Barbosa, V., ...; Magnabosco, C. U. (2006). *Avaliação genética e critérios de seleção para características de carcaça em zebuínos: relevância econômica para mercados globalizados. Simpósio internacional de produção de gado de corte, 1, 239-271.*
- Marques Junior, L. C. (2019). *Classificação de plantas daninhas em banco de imagens utilizando redes neurais convolucionais. Disponível em: <http://hdl.handle.net/11449/182521>. Acesso em 27 de novembro 2020.*
- Moreira, A. D., Siqueira, G. R., Lage, J. F., Benatti, J. M. B., Moretti, M. H., Miguel, G. Z., Oliveira, I. M., De Resende, F. D. (2017). *Castration methods in crossbred cattle raised on tropical pasture. Animal Production Science, 58(7), 1307-1315.*
- MSA - Meat Standards Australia (2003). *User's guide to Australian Meat. 3rd ed. Brisbane AUSMeat Limited. 84p.*
- Nakariyakul, S., Casasent, D. P. (2008). *Hyperspectral waveband selection for contaminant detection on poultry carcasses. Optical Engineering, 47(8), 087202. <https://doi.org/10.1117/1.2968693>.*
- Navajas, E. A., Lambe, N. R., McLean, K. A., Glasbey, C. A., Fisher, A. V., Charteris, A. J. L., Bünger, L., Simm, G. (2007). *Accuracy of in vivo muscularity indices measured by computed tomography and their association with carcass quality in lambs. Meat Science, 75(3), 533-542.*
- Nielsen, M. A. (2015). *Neural networks and deep learning (Vol. 25). San Francisco, CA: Determination press.*
- Norris, K. H. (1983). *Instrumental techniques for measuring quality of agricultural crops. In Post-harvest physiology and crop preservation (pp. 471-484). Springer, Boston, MA.*

- Nunes, K. M. (2019). Aplicação de técnicas espectroscópicas vibracionais e imagens hiperespectrais na detecção de fraudes em carnes bovinas in natura. Disponível em: <http://hdl.handle.net/1843/30978>. Acesso em: 02 de agosto de 2021.
- Paciornik, S., & Mauricio, M. H. (2004). Digital Imaging. In: G. V. Handbook, Metallography and Microstructures (pp. p. 368-402).
- Panea, B., Ripoll, G., Albertí, P., Joy, M., Teixeira, A. (2012). Atlas de disección de la canal de los ruminantes. ITEA información técnica económica agraria, 108(108), 1-105.
- Park, B., Windham, W. R., Lawrence, K. C., Smith, D. P. (2007). Contaminant classification of poultry hyperspectral imagery using a spectral angle mapper algorithm. *Biosystems Engineering*, 96(3), 323-333.
- Pascoal, L. L. (2008). Rendimento de cortes preparados de carcaças de bovinos e formação do preço de venda. Tese (Doutorado em Zootecnia) - Universidade Federal do Rio Grande do Sul.
- Pedrini, H., Schwartz, W. R. (2008). Análise de imagens digitais: princípios, algoritmos e aplicações. Cengage Learning.
- Pereira, R. M. P. (2017). Estudo do desempenho de redes neurais convolucionais aplicada ao reconhecimento de símbolos musicais, glaucoma e texto. Disponível em: <https://rosario.ufma.br/jspui/handle/123456789/3514>. Acesso em: 19 de janeiro de 2021.
- Perkins, T. L., Paschal, J. C., Tipton, N. C., De La Zerda, M. J. (1997). Ultrasonic prediction of quality grade and percent retail cuts in beef cattle. *Journal of Animal Science*, 75(1), 178-182.
- Perry, T. C., Ainslie, S. J., Traxler, M. J., Fox, D. G., Stouffer, J. R. (1990). Use of real-time and attenuation ultrasonic measurements to determine backfat thickness, rib eye area, carcass marbling and yield grade in live cattle. *Journal of Animal Science*, 68(suppl 1), 337.

- Pipek, P., Jeleníková, J., Sarnovsky, L. (2004). The use of video image analysis for fat content estimation. *Czech Journal of Animal Science-UZPI*, 49(3): 115–120.
- Powe, H. (2019). New objective grading technology being trialled by Teys. *The Land*. Disponível em: <https://www.theland.com.au/story/5898336/glimpse-into-new-objective-grading-technology/>. Acesso em: 11 de novembro de 2019.
- Qiao, J., Ngadi, M. O., Wang, N., Gariépy, C., Prasher, S. O. (2007a). Pork quality and marbling level assessment using a hyperspectral imaging system. *Journal of Food Engineering*, 83(1), 10-16.
- Qiao, J., Wang, N., Ngadi, M. O., Gunenc, A., Monroy, M., Gariépy, C., Prasher, S. O. (2007b). Prediction of drip-loss, pH, and color for pork using a hyperspectral imaging technique. *Meat science*, 76(1), 1-8.
- Qiao, Y., Truman, M., Sukkarieh, S. (2019). Cattle segmentation and contour extraction based on Mask R-CNN for precision livestock farming. *Computers and electronics in agriculture*, 165, 104958 (pp. 1–9).
- Rawat, W., Wang, Z. (2017). Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*, 29(9), 2352-2449. https://doi.org/10.1162/neco_a_00990.
- Reis, R. T. B. (2018). Modelos de aprendizado profundo para detecção de planetas extrassolares. Disponível em: <https://bdm.unb.br/handle/10483/22441>. Acesso: 30 de abril de 2020.
- Ribeiro, E. L. D. A., Rocha, M. A. D., Mizubuti, I. Y., Mori, R. M. (2000). Ganho de peso e componentes do peso vivo em borregos Ile de France inteiros ou castrados e Hampshire Down castrados abatidos aos doze meses de idade. *Ciência Rural*, 30, 333-336.
- Rivero, M. A., Ramirez, J. A., Vazquez, J. M., Gil, F., Ramirez, G., Arencibia, A. (2005). Normal anatomical imaging of the thorax in three dogs: computed tomography and macroscopic cross sections with vascular injection. *Anatomia, histologia, embryologia*, 34(4), 215-219.
- Ronneberger, O., Fischer, P., Brox, T. (2015). U-net: Convolutional networks for

- biomedical image segmentation. In International Conference on Medical image computing and computer-assisted intervention (pp. 234-241). Springer, Cham.
- Sainz, R. D., Araujo, F. R. (2001). Tipificação de carcaças de bovinos e suínos. In Congresso Brasileiro de Ciencia e Tecnologia de Carne, 1, 22–25.
- Sainz, R. D., Araújo, F. R. C. (2002). Uso de tecnologias de ultra-som no melhoramento do produto final carne. In Congresso Brasileiro das Raças Zebuínas (Vol. 5).
- Santos, A. M. D., Seixas, J. M. D., Pereira, B. D. B., Medronho, R. D. A. (2005). Usando redes neurais artificiais e regressão logística na predição da hepatite A. *Revista Brasileira de Epidemiologia*, 8, 117-126. doi: 10.1590/s1415-790x2005000200004.
- Santos, S. A., Abreu, U. G. P. D., Souza, G. D. S., Catto, J. B. (2009). Condição corporal, variação de peso e desempenho reprodutivo de vacas de cria em pastagem nativa no Pantanal. *Revista Brasileira de Zootecnia*, 38, 354-360.
- Santos, T. T., de Souza, L. L., dos Santos, A. A., Avila, S. (2020). Grape detection, segmentation, and tracking using deep neural networks and three-dimensional association. *Computers and Electronics in Agriculture*, 170, 105247, p. 1-17. DOI: 10.1016/j.compag.2020.105247.
- Scholz, A. M., Nüske, S., Förster, M. (2003). Body composition and bone mineralization measurement in calves of different genetic origin by using dual-energy X-ray absorptiometry. *Acta diabetologica*, 40(1), s91-s94. Doi: 10.1007/s00592-003-0037-7.
- Silva, G. N. D. (2018). Predição da retalhabilidade das carcaças de novilhas nelore utilizando medidas ultrassonográficas. Dissertação (Mestrado em Zootecnia) –Universidade Federal da Grande Dourados. Disponível em: < <http://repositorio.ufgd.edu.br/jspui/handle/prefix/1040> > Acesso em 05 de junho de 2020.
- Silva, J. D. S., Lobo, A. G., Oss, D. B., Menezes, A. C. B., Machado, F., Marcondes, M., Chizzotti, M. L. (2015). Determinação da composição da carcaça de bezerras através da absorciometria por raios-X com dupla energia (DEXA). In Embrapa Gado de Leite-Artigo em anais de congresso (ALICE). In: Reunião Anual Da Sociedade Brasileira De Zootecnia, 52, 2015, Belo Horizonte. Zootecnia: otimizando recursos e potencialidades: anais. Belo

- Horizonte: Sociedade Brasileira de Zootecnia, 2015.
- Silva, M. J. F. B., Lins, L. F., de Oliveira Lins, N. B., de Siqueira, M. G. F. M., de Moura, A. P. B. L., de Carvalho Neto, P. M., Barbosa, S. B. P., Júnior, W. M. D. (2017). Avaliação de carcaça bovina: uma revisão sobre o uso do ultrassom. *Medicina Veterinária (UFRPE)*, 11(4), 279-284. ISSN 1809-4678.
- Silva, R. M., Almeida, T. A., Yamakami, A. (2012). Análise de desempenho de redes neurais artificiais para classificação automática de web spam. *Revista Brasileira de Computação Aplicada*, 4(2), 42-57.
- Silva, S. D. L., Leme, P. R., Putrino, S. M., Lanna, D. P. D. (2006). Alterações nas características de carcaça de tourinhos Nelore, avaliadas por ultrassom. *Revista Brasileira de Zootecnia*, 35, 607-612.
- Simonyan, K., Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Sivertsen, A. H., Chu, C. K., Wang, L. C., Godtliebsen, F., Heia, K., Nilsen, H. (2009). Ridge detection with application to automatic fish fillet inspection. *Journal of Food Engineering*, 90(3), 317-324.
- Skeika, E. L. (2019). Utilização de redes neurais completamente convolucionais para identificação e medição de crânios fetais (Master's thesis, Universidade Tecnológica Federal do Paraná). Disponível em: <<https://repositorio.utfpr.edu.br/jspui/bitstream/1/4714/1/utilizacaoredesneuraisconvolucionais.pdf>>. Acesso: 18 de janeiro 2021.
- Son, J., Lee, D. (2013). Estimation of genetic correlations and selection responses for carcass traits between ultrasound and real carcass measurements in Hanwoo cows. *Journal of Animal Science and Technology*, 55(6), 501-508.
- Srivastava, R. K., Greff, K., Schmidhuber, J. (2015). Highway networks. arXiv preprint arXiv:1505.00387.
- Standal, N. (1984). Establishment of CT facility for farm animals. In *In Vivo Measurement of Body Composition in Meat Animals* (pp. 43-51). Elsevier, London.

- Suguisawa, L., Matos, B. C., Suguisawa, J. M. (2013). *Uso Da Ultrassonografia Na Avaliação De Características De Carcaça E De Qualidade Da Carne. Melhoramento genético Aplicado em Gado de Corte*. Brasília: Embrapa, 258 p. ISBN:978-85-7035-256-9.
- Suguisawa, L., Mattos, W. R. S., Oliveira, H. N. D., Silveira, A. C., Arrigoni, M. D. B., Haddad, C. M., Chardulo, L. A. L., Martins, C. L. (2003). Ultrasonography as a predicting tool for carcass traits of Young bulls. *Scientia Agricola*, 60(4): 779-784.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9). Doi: 10.1109/CVPR.2015.7298594.
- Tarouco, J. U., Lobato, J. F. P., Tarouco, A. K., Massia, G. D. S. (2005). Relação entre medidas ultra-sônicas e espessura de gordura subcutânea ou área de olho de lombo na carcaça em bovinos de corte. *Revista Brasileira de Zootecnia*, 34(6): 2074-2084.
- Tu, S., Yuan, W., Liang, Y., Wang, F., Wan, H. (2021). Automatic Detection and Segmentation for Group-Housed Pigs Based on PigMS R-CNN. *Sensors*, 21(9), 3251. <https://doi.org/10.3390/s21093251>.
- USDA. (1997). *Official United States standards for grades of carcass beef*. Agric. Marketing Serv., USDA. Washington, DC.
- Vaz, F. N., Restle, J. (2000). Aspectos qualitativos da carcaça e da carne de machos Hereford, inteiros ou castrados, abatidos aos quatorze meses. *Revista Brasileira de Zootecnia*, 29, 1894-1901.
- Vieira, C. A. O. (2000). *Accuracy of remotely sensing classification of agricultural crops: a comparative study* (Doctoral dissertation, University of Nottingham).
- Wilson, D. E. (1992). Application of ultrasound for genetic improvement. *Journal of Animal Science*, 70(3), 973-983.

- Wnęk, K., Gołębiowski, M., Przysucha, T. (2017). Validation of the first objective evaluation system for beef carcasses. *Canadian Journal of Animal Science*, 98(1), 53-60. <https://doi.org/10.1139/cjas-2016-0241>.
- Wu, H., Gu, X. (2015). Towards dropout training for convolutional neural networks. *Neural Networks*, 71, 1-10.
- Xie, S., Girshick, R., Dollár, P., Tu, Z., He, K. (2017). Aggregated residual transformations for deep neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1492-1500).
- Yang, J. (2017). ReLU and Softmax Activation Functions. Disponível em: < <https://github.com/Kulbear/deep-learning-nano-foundation/wiki/ReLU-and-Softmax-Activation-Functions> >. Acesso em: 22 outubro de 2020.
- Yokoo, M., Magnabosco, C. D. U., Gonzalez, R., De Faria, C. U., Araujo, F. D. C., Rosa, G., Cardoso, F., De Albuquerque, L. G. (2011). Avaliação genética de características de carcaça utilizando a técnica do ultrassom em bovinos de corte. *Embrapa Pecuária Sul-Documentos (INFOTECA-E)*.
- Zhang, A., Lipton, Z. C., Li, M., Smola, A. J. (2019). Optimization algorithms. *Dive into deep learning*. Disponível em: <https://www.d2l.ai>. Acesso em: 02 de setembro de 2021.

CAPÍTULO 2

EFEITO DA CLASSE SEXUAL E ESCORE DE ACABAMENTO DE GORDURA NA CARÇA SOBRE MEDIDAS BIOMÉTRICAS OBTIDAS PELA ANÁLISE DE IMAGENS DIGITAIS EM BOVINOS.

Gutierrez J. F. Assis^{*1}, Débora E. F. Assis^{*}, Gustavo B. Carneiro^{*}, André L.C.

Mendes^{*}, Fabyano F. Silva^{*}, Mario L. Chizzotti^{*1}.

^{*} Departamento de Zootecnia, Universidade Federal de Viçosa, Viçosa, Minas Gerais, Brasil, 36.570-900.

¹Autores correspondentes. E-mail: gutierrez.assis@ufv.br; mariochizzotti@ufv.br

RESUMO

A avaliação das medidas biométricas permite conhecer o desenvolvimento corporal dos animais, e tem a vantagem de não ser um método invasivo. No entanto, tecnologias que utilizam medidas biométricas em bovinos e suas relações com as características de carcaça ainda são escassas na literatura. Diante disso, os objetivos neste estudo são avaliar o efeito da classe sexual sobre a morfologia corporal de bovinos e investigar as relações entre as medidas biométricas *in vivo* e os escores de acabamento atribuídos às carcaças em frigorífico comercial, por meio do processamento de imagens digitais coletadas nos currais de manejo. O experimento foi conduzido com dados coletados em confinamento e frigorífico comercial. Foram utilizados dados de 147 bovinos da raça Angus (Fêmeas=29; machos castrados=118), com idade máxima de 24 meses e peso vivo médio de $578,8 \pm 38,3$ kg. Os animais foram aleatoriamente selecionados nos currais de espera, identificados, submetidos a jejum de sólidos durante 16 horas, coletadas imagens do dorso animal com sensor de infravermelho e, posteriormente, os animais foram abatidos por meio de concussão cerebral e secção da veia jugular para sangramento total. Após o abate, a carcaça de cada animal foi dividida longitudinalmente em duas metades, o escore de acabamento foi mensurado pela observação visual realizada por profissionais treinados, e as carcaças foram resfriadas em câmara fria a 4 °C por 24 horas. Para obtenção das imagens digitais, utilizou-se o dispositivo Intel® RealSense™, este foi implementado em Python (baseado em OpenCV, 2015). O sensor foi posicionado no curral de manobras a uma altura de 3,00 metros, paralelo ao solo, permitindo coletar imagens de apenas um animal por vez. As imagens foram analisadas e foram obtidos os parâmetros biométricos a serem utilizados. Os dados coletados foram analisados pelo método dos quadrados mínimos, por meio dos procedimentos gerais de modelos lineares (Proc GLM) contidos no pacote estatístico SAS 9.0 (Statistical Analysis System Institute, Inc.). As médias foram comparadas pelo teste de Tukey (5%) para estimar a significância das diferenças entre as mesmas. A regressão do Least Absolute Shrinkage and Selection Operator foi utilizada para selecionar as variáveis mais relevantes para prever o peso da carcaça e acabamento. Houve influência da classe sexual sobre o peso corporal, sendo que os animais castrados apresentaram maiores valores quando comparados às fêmeas. Verificou-se, também, diferença

entre classes sexuais para largura, área, volume corporal projetado, perímetro, circularidade, redondez e relação perímetro área, dos quais os animais castrados obtiveram médias superiores às fêmeas. Com relação aos escores de acabamento verificou-se que estes foram influenciados pelas medidas biométricas. O escore de acabamento atribuído às carcaças teve influência do peso corporal. Assim, os animais mais pesados obtiveram os maiores escores de acabamento. Do mesmo modo, a área, volume corporal projetado, perímetro, circularidade e redondez foram maiores nos escores mediana e uniforme, que não diferiram entre si, e menores para o escore escasso. As equações utilizando medidas biométricas apresentaram coeficientes de determinação de 0,88 e 0,27 para peso de carcaça e escore de acabamento, respectivamente. Os resultados indicam que a análise de imagem pode ser usada para obter as medidas corporais em bovinos e que mais estudos são necessários para estimativa do escore de acabamento da carcaça.

Palavras-chave: biometria, correlação, predição, processamento de imagens, sensor, sexo.

INTRODUÇÃO

Questões socioambientais e econômicas impostas pela sociedade moderna representam desafios à pecuária de corte. Para aperfeiçoar os sistemas de produção de carne bovina, o melhoramento genético e técnicas de zootecnia de precisão são ferramentas importantes para o monitoramento do desempenho dos animais, o que contribui para a tomada de decisão e melhora na eficiência produtiva, econômica e ambiental. Um fator importante na busca de uma melhor eficiência na produção de carne é a estimativa precisa do ponto ideal de abate (Silva et al., 2004). Normalmente em campo, a definição do ponto de abate é realizada com base na idade ou peso fixos em vez de níveis de acabamento, pois estes são mais difíceis de serem determinados (Kempster & Owen, 1981). Logicamente, o peso corporal é uma característica de interesse dentro do sistema de produção, devido à facilidade de obtenção e correlação com a composição corporal, sendo, portanto, este utilizado como um indicativo quantitativo da porção comestível da carcaça. O peso pode ainda ser associado ao escore de condição corporal como indicativo para o momento adequado do abate. No entanto, este tipo de avaliação é subjetivo e, portanto, sujeito a erros.

Nesse sentido, soluções computacionais apoiadas em sensores de baixo custo e análise de imagem têm sido propostas para aquisição de atributos que permitam estimar o peso dos animais e características de carcaça pela análise das medidas biométricas, sem a necessidade de contenção ou manejo (Hyslop et al., 2008; Gomes et al., 2016; Nir et al., 2018; Qiao, Truman e Sukkarieh, 2019; Cominotte et al., 2020; Xu et al., 2020). A avaliação das medidas biométricas permite conhecer o desenvolvimento das diferentes partes que compõem o corpo animal (Fisher, 1975). Estudos de mensurações biométricas e suas relações com as características de carcaça em bovinos ainda são escassos na literatura, e têm a vantagem de não serem um método invasivo (Rosa et al., 2015). Diante disso, os objetivos neste estudo são avaliar o efeito da classe sexual sobre a morfologia corporal de bovinos e investigar as relações entre as medidas biométricas *in vivo* e os escores de acabamento atribuídos às carcaças em frigorífico comercial, por meio do processamento de imagens digitais coletadas nos currais de manejo.

MATERIAIS E MÉTODOS

Todos os procedimentos pré-abate e abate dos bovinos seguiram as normas estabelecidas pela Instrução Normativa n. 3, de 17 de janeiro de 2000 instituída pelo Ministério da Agricultura Pecuária e Abastecimento (BRASIL, 2000).

Local e animais

O experimento foi conduzido com dados coletados em confinamento e frigorífico comercial. Foram utilizados dados de 147 bovinos da raça Angus (Fêmeas=29, machos castrados=118), com idade máxima de 24 meses e peso vivo médio de $578,8 \pm 38,3$ kg. Os animais foram aleatoriamente selecionados nos currais de espera, identificados, submetidos a jejum de sólidos durante 16 horas, coletadas imagens do dorso animal com sensor de infravermelho e, posteriormente, os animais foram abatidos por meio de concussão cerebral e secção veia da jugular para sangramento. Após o abate, a carcaça de cada animal foi dividida longitudinalmente, as meias-carcaças foram pesadas e o escore de acabamento foi mensurado pela observação visual, realizada por profissionais treinados e, em seguida, as carcaças foram resfriadas a 4 °C por 24 horas. Os animais tiveram as carcaças avaliadas quanto ao acabamento de gordura, conforme descrito no Sistema Nacional de Tipificação de Carcaças Bovinas (Ausente (< 1 mm), Escassa (1 - 3 mm), Mediana (3 - 6 mm), Uniforme (6 - 10 mm) e Excessivo (> 10 mm de espessura de gordura)), instituído pelo Ministério da Agricultura, Pecuária e Abastecimento. Não foram registrados escores ausentes e excessivos de acabamento e, portanto, essas classes não puderam ser incluídas nas avaliações.

Obtenção de imagens

A infraestrutura de captura de imagem foi instalada em confinamento comercial. O sensor foi posicionado no curral de manobras, a uma altura de 3,00 metros paralelo ao solo, permitindo coletar imagens de apenas um animal por vez com o Intel® RealSense™. Este dispositivo combina uma câmera RGB e um sensor de profundidade. O sensor de profundidade consiste em um projetor de infravermelho e um sensor de infravermelho e usa o princípio de medição "Luz estruturada" para coletar informações de profundidade. Um padrão de pontos de laser infravermelho é projetado na cena. Sua deformação é detectada pelo sensor infravermelho e usada para calcular os valores de profundidade. O sensor possui um

campo de visão de 85,2° na horizontal e 58° na vertical, resolução de 1280 x 720 pixels e pode gravar até 90 imagens de profundidade por segundo.

O *software* para operar as câmeras Intel® RealSense™ foi implementado em Python (baseado em OpenCV, 2015). As opções de imagens RGB, mapa de profundidade ou ambos, na sobreposição, foram exibidos no monitor para verificação da qualidade dos dados coletados. Os fluxos de dados foram nomeados automaticamente para evitar a substituição.

O tratamento das imagens, bem como as medições foram realizados automaticamente no Python. As imagens foram segmentadas com auxílio da função `threshold_otsu` do módulo `Skimage`, o que permitiu obter a região correspondente ao animal. A função `threshold_otsu` recebe uma imagem e separa os objetos da imagem de forma binária. O retorno da função é um limiar que foi utilizado como uma máscara na filtragem dos pixels da imagem. A partir disso, uma linha foi traçada seguindo a coluna cervical do animal. Outra linha foi traçada conectando os ângulos ventrais das escápulas a fim de eliminar a parte anterior do animal e padronizar as imagens. A parte anterior do corpo, incluindo a região da cabeça, foi retirada por ser uma região que sofre grande variação de posicionamento.

As imagens obtidas estavam sujeitas a erros relacionados à movimentação dos animais durante a captura, contornos inadequados causados por forte luz solar incidente sobre o corpo animal, a cabeça de um segundo animal contra a parte traseira do animal sendo medido ou o animal estar encostado nas réguas do curral de manejo.

Parâmetros corporais avaliados

Nas imagens coletadas, as variáveis avaliadas foram: área do plano dorsal (APD), densidade (DEN), largura (LAR), comprimento dorsal (CD), alongação (ELON), volume corporal projetado (VCP), perímetro (PER), circularidade (CIR), redondez (RDZ), e relação perímetro área (RPA). As medidas de largura e comprimento foram obtidas pela linha perpendicular de cada medida (Figura 1).

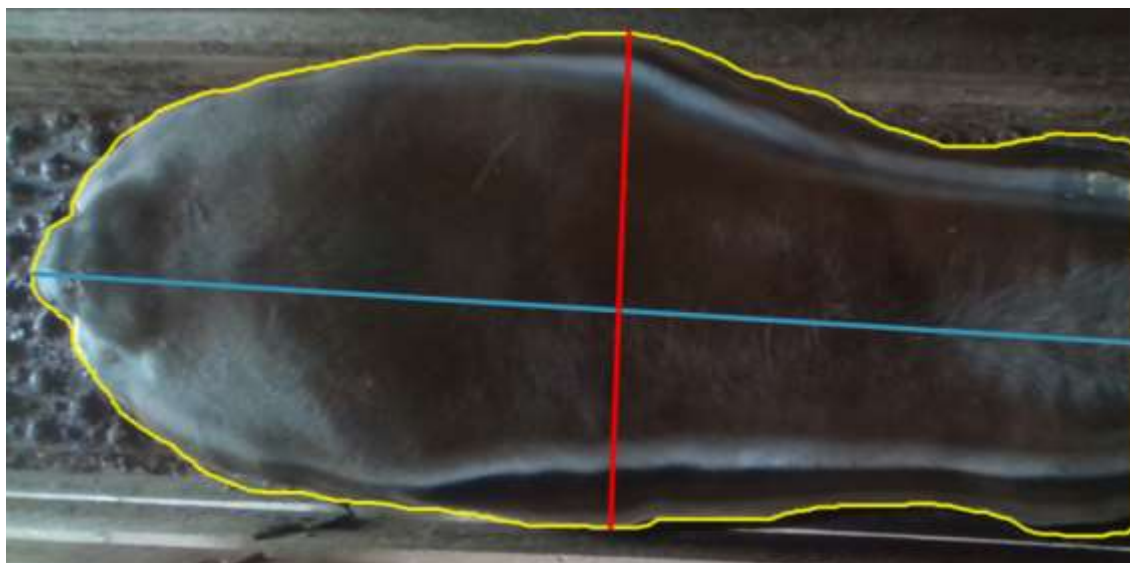


Figura 1 - Ilustração das medidas obtidas pela análise de imagens. Área do plano dorsal (APD; área em contorno amarelo), largura (linha vermelha), comprimento dorsal (linha azul).

A área do plano dorsal foi obtida a partir de uma linha que conecta os ângulos ventrais das escápulas, sendo a APD considerada a imagem anterior à linha, em metros quadrados (m^2 ; Figura 1). Densidade: Razão do tamanho e a dimensionalidade, ou seja, é a quantidade de massa que está contida em um espaço (volume).

$$D = \frac{\text{Massa (kg)}}{\text{Volume (m}^3\text{)}}$$

Largura, no local de maior diâmetro corporal obtido no menor eixo da imagem, em metros (m). Comprimento dorsal, uma linha no plano sagital, do ombro à extremidade mais caudal do animal, em metros (m). Elongação: Razão computada entre a largura do menor eixo e o comprimento do maior eixo. Quanto maior o valor, mais a forma do objeto se aproxima da forma quadrada e/ou redonda e, conforme a razão diminui, mais alongado é o objeto.

$$E = \frac{\text{Largura}}{\text{Comprimento}}$$

O volume corporal projetado foi obtido pelo volume da projeção do dorso animal ao solo, em metros cúbicos (m^3). O Perímetro foi medido como contorno da imagem (m). Circularidade (diâmetro circular equivalente) refere-se ao quanto a forma do objeto se aproxima à de um círculo (adimensional).

$$C = \frac{\text{Perímetro}}{\pi}$$

A Redondez foi obtida pela razão baseada nos descritores de área e perímetro.

$$R = \frac{4\pi * \text{área}}{\text{Perímetro}}$$

A Relação Perímetro /Área foi obtida pela razão entre o perímetro do objeto e área.

$$RPA = \frac{\text{Perímetro}}{\text{Área}}$$

Análise estatística

Os dados coletados foram analisados pelo método dos quadrados mínimos por meio dos procedimentos gerais de modelos lineares (Proc GLM) contidos no pacote estatístico SAS 9.0 (Statistical Analysis System Institute, Inc.). Para avaliação das medidas biométricas o modelo utilizado incluiu apenas o efeito de sexo. Para escore de acabamento de gordura subcutânea o modelo utilizado incluiu os efeitos de sexo e interação entre sexo e acabamento de gordura. As médias foram comparadas pelo teste de Tukey (5%) para estimar a significância das diferenças entre as mesmas.

A regressão LASSO (Least Absolute Shrinkage and Selection Operator, Tibshirani, 1996) foi usada para selecionar as variáveis mais relevantes para prever peso de carcaça e acabamento de gordura nas carcaças. Este método foi implementado através do procedimento GLMSELECT do software SAS® (SAS Inst. Inc., Cary, NC), utilizando todas as variáveis biométricas, peso de carcaça, peso corporal e escore de acabamento de gordura. Em seguida, o procedimento REG foi utilizado para determinar a significância das variáveis selecionadas no GLMSELECT.

RESULTADOS E DISCUSSÃO

A estatística descritiva dos dados utilizados no presente estudo são apresentadas na Tabela 1.

Tabela 1- Estatística descritiva das variáveis utilizadas.

Variáveis	N	Média	Desvio padrão	Mínimo	Máximo
Peso corporal (kg)	147	578,7	38,31	466,0	666,0
Peso de carcaça (kg)	147	324,8	24,53	248,5	381,0
Área (m ²)	147	0,813	0,052	0,623	0,927
Densidade (kg/m ³)	147	323,5	20,02	271,1	382,9
Largura (m)	147	0,641	0,033	0,571	0,715
Comprimento (m)	142	1,130	0,083	0,954	1,366
Elongação	142	0,570	0,048	0,424	0,684
Volume corporal projetado (m ³)	147	1,792	0,115	1,420	2,039
Perímetro (m)	147	3,695	0,130	3,170	3,940
Circularidade	147	1,177	0,040	1,008	1,253
Redondez	147	2,762	0,100	2,470	2,988
Relação perímetro área	147	4,554	0,170	4,205	5,085
Rendimento (%)	147	56,10	1,586	51,24	60,38

As médias das diferentes características biométricas avaliadas, de machos castrados e fêmeas são apresentadas na Tabela 2. Observa-se que, em grande parte das características analisadas, houve diferença significativa ($P < 0,05$) entre machos e fêmeas, sendo que os machos apresentaram resultados superiores. Resultado este atribuído, principalmente, à diferença no peso corporal, visto que os machos, com idades semelhantes às das fêmeas, apresentaram maiores pesos corporais (Tabela 2). Essas diferenças são observadas na área, largura, volume corporal projetado, perímetro, circularidade, redondez e na relação perímetro área. Dessas medidas, pode-se considerar as mais relevantes a área e o volume corporal projetado, uma vez que estes apresentam correlação média alta com peso corporal, sendo o peso, por sua vez, o principal preditor do rendimento de cortes cárneos (Altarriba et al., 2005; Kotch et al., 2004; Bonilha et al., 2008; Sobrinho et al., 2013).

Tabela 2 - Efeito do sexo sobre medidas biométricas obtidas por imagem dorsal em bovinos.

Variável	Classe sexual		EPM	P-valor
	Macho castrado (n=118)	Fêmea (n=29)		
Peso Corporal (kg)	585,0a	553,1b	6,731	0,0001
Peso de carcaça (kg)	330,4a	302,0b	4,057	0,0001
Área dorsal (m ²)	0,821a	0,781b	0,0093	0,0002
Densidade (kg/m ³)	323,3	324,3	3,730	0,814
Largura (m)	0,645a	0,628b	0,0061	0,013
Comprimento dorsal (m)	1,131	1,124	0,0078	0,655
Elongação	0,573	0,561	0,0089	0,253
Volume corporal projetado (m ³)	1,812a	1,708b	0,0199	0,0001
Perímetro (m)	3,715a	3,616b	0,0232	0,0002
Circularidade	1,184a	1,151b	0,0071	0,0001
Redondez	2,775a	2,712b	0,0182	0,0023
Relação perímetro/área	4,533a	4,638b	0,0307	0,0026
Rendimento de carcaça (%)	56,46a	54,65b	0,263	0,0001

EPM: erro padrão da média.

De forma interessante, não houve diferença entre os sexos para o comprimento dorsal, medida que sabidamente impacta o tamanho do animal. Cyrillo et al. (2012) avaliaram as relações entre medidas biométricas, características de carcaça e cortes cárneos comerciais de bovinos machos, Zebu (457,8 kg) e Caracu (488,8 kg). Os autores citam que o comprimento corporal dos animais foi de 139,9 e 147,2 cm de Zebu e Caracu, respectivamente. Valores maiores aos relatados no presente estudo, visto que foi mensurada da articulação escapuloumeral à articulação coxofemoral, contrariamente ao aqui relatado, que se trata de uma linha no plano sagital, do ombro à extremidade mais caudal do animal.

Para a utilização da biometria, é fundamental buscar características fáceis de serem obtidas e com importância na produção animal. Nesse sentido, na Tabela 3, são apresentadas algumas medidas biométricas e correlações importantes.

Tabela 3 - Coeficientes de correlação (abaixo da diagonal) e valores P (acima da diagonal) entre peso corporal, medidas biométricas e escore de acabamento de gordura subcutânea.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	-	0,0001	0,051	0,0001	0,001	0,738	0,095	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001
2	0,929	-	0,0001	0,0002	0,010	0,828	0,156	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001
3	0,160	0,513	-	0,563	0,773	0,876	0,945	0,068	0,0192	0,0265	0,0181	0,237	0,224	0,747
4	0,37	0,306	-0,048	-	0,317	0,992	0,673	0,105	0,134	0,064	0,051	0,225	0,193	0,0011
5	0,253	0,210	-0,023	0,082	-	0,370	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0002
6	0,028	0,018	-0,013	-0,00079	0,075	-	0,0001	0,963	0,418	0,610	0,768	0,811	0,879	0,747
7	0,140	0,119	-0,005	0,035	0,557	-0,781	-	00,0001	0,0003	0,0012	0,0016	0,0001	0,0001	0,038
8	0,519	0,506	0,150	0,134	0,579	-0,0038	0,372	-	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001
9	0,563	0,562	0,193	0,123	0,555	0,068	0,297	0,961	-	0,0001	0,0001	0,0001	0,0001	0,0001
10	0,452	0,461	0,183	0,152	0,345	-0,043	0,268	0,915	0,882	-	0,0001	0,0001	0,0001	0,0001
11	0,492	0,500	0,194	0,161	0,360	-0,024	0,262	0,900	0,873	0,962	-	0,0001	0,0001	0,0001
12	0,494	0,466	0,098	0,100	0,699	0,020	0,417	0,921	0,879	0,703	0,689	-	0,0001	0,0001
13	-0,498	-0,470	-0,100	-0,107	-0,693	-0,012	-0,419	-0,923	-0,880	-0,711	-0,696	-0,998	-	0,0001
14	0,480	0,406	-0,026	0,265	-0,302	-0,0272	-0,1740	-0,462	-0,451	-0,455	-0,401	-0,398	0,397	-

1: Peso corporal (kg); 2: Peso de carcaça (kg); 3: Rendimento de carcaça (%); 4: Escore de acabamento de gordura subcutânea; 5: Largura (m); 6: comprimento dorsal (m); 7: Elongação; 8: área dorsal (m²); 9: Volume corporal projetado (m³); 10: Perímetro (m); 11: Circularidade; 12: Redondez; 13: Relação perímetro/área; 14: Densidade (kg/m³).

As correlações entre o peso corporal e os parâmetros biométricos extraídos das imagens variaram de -0,498 a 0,563. A relação perímetro/área e o volume corporal projetado, dentre todos os parâmetros extraídos das imagens digitais, tiveram as correlações mais baixas e mais altas com o peso corporal dos bovinos, respectivamente. Os coeficientes de correlação encontrados entre peso corporal e largura foram baixos e significativos (0,25; $P < 0,05$), diferente das correlações relatadas por Piazzon et al. (2018) e Mota et al. (2015) que foram de 0,67 e 0,90, respectivamente. Os coeficientes de correlação entre o peso, e a área e o volume corporal projetado foram de 0,51 e 0,56, respectivamente. Inferiores aos que foram relatados por Le Cozler et al. (2019), trabalhando com dispositivos 3D para determinar o peso corporal a partir da área e volume de vacas leiteiras, obtendo correlações de 0,72 e 0,93 para área e volume, respectivamente.

O coeficiente de correlação encontrado entre o peso corporal e o perímetro dorsal foi significativo ($P < 0,05$), obtendo um valor de 0,45, superior ao coeficiente de correlação relatado por Weber et al. (2020), que foi de 0,36. As correlações entre a área e as variáveis volume corporal projetado, perímetro, circularidade e redondez foram altas ($r^2 > 0,90$) e significativas ($P < 0,05$). O comprimento dorsal somente correlacionou de forma significativa ($P < 0,05$) com a alongação.

O coeficiente de correlação encontrado entre a densidade e as variáveis peso corporal e peso de carcaça foram significativas ($P < 0,05$), obtendo um valor de 0,48 e 0,40, respectivamente. Os coeficientes de correlação encontrados entre a densidade e as variáveis área e volume corporal projetado foram significativos ($P < 0,05$) e negativos, obtendo valores de -0,46 e -0,45, respectivamente. O comportamento apresentado por estas variáveis foi condizente com o esperado, uma vez que, quanto maiores a área e o volume corporal projetado, menor tende a ser a densidade, visto que, com o aumento do peso corporal, maior quantidade de gordura é depositada na carcaça, proporcionando mudanças nas características biométricas. No entanto, devido à menor densidade da gordura em comparação com a deposição de massa magra (músculos), ocorre pouca oscilação no peso corporal e, conseqüentemente, diminui a densidade.

O coeficiente de correlação encontrado entre o peso e o escore de acabamento de gordura subcutânea foi de 0,37. A densidade também foi

significativamente correlacionada com a gordura da carcaça ($P < 0,05$; 0,26). Embora todos os parâmetros estudados sejam considerados auxiliares na avaliação das características de carcaça, estes apresentaram, em geral, baixos e não significativos coeficientes de correlação com a gordura da carcaça. Em função disso, realizou-se um trabalho investigativo com o objetivo de verificar se o escore de acabamento de gordura da carcaça é influenciado pelos parâmetros corporais. Na Tabela 4 são apresentadas as médias dos parâmetros corporais em função dos escores de acabamento atribuídos às carcaças.

Tabela 4 - Efeito do escore de acabamento de gordura subcutânea sobre medidas biométricas obtidas por imagem dorsal em bovinos.

Variável	Escore de acabamento de gordura subcutânea			EPM	P-Valor	
	Escassa (n = 6)	Mediana (n = 111)	Uniforme (n = 30)		Gordura	Gordura*sexo
Peso corporal (kg)	519,6c	563,4b	592,5a	12,92	0,0001	0,0001
Peso de carcaça (kg)	285,5c	314,3b	327,5a	7,732	0,0001	0,0001
Área dorsal (m ²)	0,751b	0,801a	0,809a	0,019	0,033	0,0001
Densidade (kg/m ³)	310,5b	321,3b	332,5a	7,982	0,012	0,885
Largura (m)	0,635	0,634	0,644	0,006	0,399	0,024
Comprimento dorsal (m)	1,109	1,128	1,126	0,034	0,860	0,842
Elongação	0,574	0,565	0,573	0,019	0,760	0,459
Volume projetado (m ³)	1,678	1,757	1,782	0,042	0,086	0,0001
Perímetro (m)	3,521b	3,666a	3,685a	0,048	0,010	0,0001
Circularidade	1,121b	1,168a	1,174a	0,014	0,005	0,0001
Redondez	2,676	2,743	2,756	0,039	0,195	0,003
Relação perímetro/área	4,703	4,587	4,563	0,066	0,169	0,003
Rendimento de carcaça (%)	54,85	55,76	55,28	0,562	0,138	0,0001

EPM: erro padrão da média.

O escore de acabamento é influenciado pelo peso corporal. Assim, os animais mais pesados obtiveram os maiores escores de acabamento. Isso se deve ao fato de que, provavelmente, os animais abatidos mais pesados já estavam mais próximos à maturidade fisiológica e, conseqüentemente, apresentavam maior crescimento de tecido adiposo, o que também influencia a área dorsal, que aumentou acompanhando o aumento dos escores de acabamento de gordura subcutânea. Observação contrária a relatada por Weber et al. (2020), que abordam

que a deposição de gordura subcutânea pode não causar mudanças na forma corporal do bovino que seja visível a partir de imagens.

Observa-se, também, que existe uma tendência do volume corporal projetado ser diferente entre os escores de acabamento ($P= 0,086$). A largura e o comprimento não diferiram entre os escores, assim como os valores de redondez, relação perímetro/área e alongação. A área dorsal, perímetro, circularidade e densidade diferiram ($P<0,05$) entre os escores, apresentando as menores médias no escore escasso e os maiores valores para os escores mediano e uniforme, que não diferiram estatisticamente entre si.

Houve interação entre o acabamento de gordura e o sexo (Tabela 5). Nesse sentido, os dados obtidos neste trabalho permitiram realizar comparações entre os sexos, tendo sido avaliados os escores de acabamento de gordura separadamente para fêmeas e machos. Uma vez que a classe sexual influencia a qualidade final da carcaça, os animais atingem o acabamento desejado com pesos e idades diferentes. Animais não castrados, quando abatidos de acordo com o acabamento, são mais pesados e necessitam de maior tempo para terminação, enquanto animais castrados necessitam de menos tempo para atingir o mesmo ponto de acabamento. As fêmeas, devido à maturidade precoce, apresentam maior deposição de gordura subcutânea com menor peso corporal (Paulino et al., 2008). Neste trabalho, as fêmeas obtiveram os escores mediano e uniforme a um peso inferior ao observado em machos castrados. Ao se observar os dados obtidos para fêmeas e machos separadamente, verifica-se que os parâmetros biométricos apresentaram diferenças significativas entre os escores apenas para os machos.

Tabela 5 - Efeito do escore de acabamento de gordura subcutânea sobre medidas biométricas obtidas por imagem dorsal em bovinos, separados por classe sexual.

Variável	Escore de acabamento de gordura subcutânea			EPM	P-Valor
	Escassa	Mediana	Uniforme		
Macho castrado					
	n = 6	n = 92	n = 20		
Peso corporal (kg)	519,6c	582,9b	614,6a	12,69	0,0001
Peso de carcaça (kg)	285,5c	329,7b	347,1a	7,861	0,0001
Área dorsal (m ²)	0,751b	0,823a	0,833a	0,019	0,001
Densidade (kg/m ³)	310,5b	321,7b	334,2a	7,979	0,011
Largura (m)	0,635	0,644	0,652	0,014	0,508
Comprimento dorsal (m)	1,109	1,134	1,125	0,033	0,705
Elongação	0,574	0,571	0,580	0,019	0,755
Volume corporal projetado (m ³)	1,678b	1,815a	1,840a	0,042	0,004
Perímetro (m)	3,521b	3,720a	3,748a	0,048	0,0003
Circularidade	1,121b	1,186a	1,195a	0,014	0,0001
Redondez	2,676b	2,777a	2,794a	0,039	0,033
Relação perímetro/área	4,703a	4,530b	4,499b	0,066	0,026
Rendimento de carcaça (%)	54,85b	56,56a	56,48a	0,550	0,012
Fêmea					
	n = 0	n = 19	n = 10		
Peso corporal (kg)	-	544,0	570,4	10,74	0,056
Peso de carcaça (kg)	-	298,9	308,0	5,545	0,195
Área dorsal (m ²)	-	0,779	0,784	0,015	0,811
Densidade (kg/m ³)	-	320,9	330,7	6,192	0,209
Largura (m)	-	0,623	0,636	0,008	0,249
Comprimento dorsal (m)	-	1,122	1,127	0,027	0,894
Elongação	-	0,559	0,565	0,015	0,755
Volume corporal projetado (m ³)	-	1,699	1,725	0,034	0,532
Perímetro (m)	-	3,613	3,623	0,037	0,831
Circularidade	-	1,150	1,153	0,011	0,846
Redondez	-	2,708	2,718	0,030	0,806
Relação perímetro/área	-	4,644	4,628	0,052	0,804
Rendimento de carcaça (%)	-	54,95	54,07	0,475	0,144

EPM: erro padrão da média.

Os escores de acabamento de gordura foram influenciados pelo peso corporal, e como era esperado, à medida que houve aumento do peso corporal, houve também aumento dos escores de acabamento. O escore de acabamento diferiu ($P < 0,05$), nos machos, conforme o peso, tendo sido escasso aos 519,6 kg, mediano aos 582,9 kg e uniforme aos 614,6 kg. Os valores de largura, comprimento e alongação não diferiram entre os escores. Entretanto, houve efeito do escore de acabamento sobre a área, volume corporal projetado, perímetro, circularidade e redondez, sendo que os menores valores para estas variáveis foram obtidos no escore escasso e os maiores valores nos escores mediano e uniforme, que não diferiram entre si ($P > 0,05$), indicando que os animais mais pesados estavam próximos de atingir ou já haviam atingido o peso à maturidade.

Com o objetivo de quantificar as relações entre características cujas correlações foram importantes e significativas ($P < 0,05$), foram realizadas análises de regressão, visando obter modelos que permitam prever o escore de acabamento de gordura subcutânea e o peso de carcaça a partir de medidas biométricas (Tabela 6).

Tabela 6 - Equações para prever o escore de acabamento de gordura subcutânea e peso de carcaça utilizando medidas biométricas obtidas pela análise de imagens.

Modelo	Equação	R ²	MSE
Escore de acabamento			
Macho castrado	$-2,52 + (0,00656 \times PC) - (1,163 \times VOL) + (1,052 \times PER)$	0,27	0,153
Peso de carcaça (Kg)			
Macho castrado	$-325,94 - (61,20 \times LAR) + (204,42 \times VOL) + (1,006 \times DEN)$	0,88	63,25
Fêmea	$-193,29 + (135,58 \times VOL) + (0,813 \times DEN)$	0,81	64,48

PC: Peso corporal (kg); VOL: Volume corporal projetado (m³); PER: Perímetro (m); LAR: Largura (m); DEN: Densidade (kg/m³); R²: Coeficiente de determinação; MSE: Erro quadrático médio.

O baixo coeficiente de correlação obtido pela equação de predição do escore de acabamento para machos castrados ($r^2=0,27$) e a impossibilidade de se gerar um modelo de predição para fêmeas, pode ser explicado pelo fato da gordura ser um tecido extremamente variável por sofrer influência de diversos fatores, como idade de abate, genética, classe sexual e manejo nutricional. Além disso, as diferenças

entre as medidas obtidas no animal e as preditas nas carcaças podem ainda, ser atribuídas a fatores como: comprimento dos pêlos, método usado para remoção do couro, que pode remover uma quantidade considerável de gordura da carcaça; assim como o posicionamento do sensor e do animal. Obstáculos semelhantes foram encontrados por diversos autores que utilizaram técnica de ultrassom em tempo real como ferramenta potencial para predizer características de carcaça em bovinos (Perkins et al., 1992; Waldner et al., 1992; Greiner, 1999; Charagu et al., 2000). Portanto, acredita-se que a VIA possa apresentar resultados semelhantes ao ultrassom com a vantagem de não ser necessário manejar os animais.

O peso de carcaça possui relevância econômica para os produtores, ao considerar que a receita com a venda dos animais é proveniente deste peso. Em campo, uma maneira de estimar o peso de carcaça é pelo cálculo de rendimento de carcaça, uma relação entre o peso do animal a ser abatido (vivo) e o peso da carcaça. Neste cálculo, considera-se a carcaça como 50% do peso animal. Porém, o rendimento de carcaça é influenciado pelo peso, composição genética, conformação, classe sexual, sendo necessário desenvolver ferramentas que permitam melhorar a predição do peso de carcaça.

Neste sentido, predizer o peso de carcaça utilizando o peso corporal associado a medidas biométricas pode melhorar a acurácia e precisão das estimativas. A partir da equação estabelecida pelo método estatístico (LASSO), foram preditos os pesos de carcaça dos animais de um banco de dados independente, para validação (Figura 2). Foram utilizadas imagens de 28 animais, machos castrados, peso corporal médio de 594,5 Kg e peso de carcaça médio de 333,2 Kg (o peso de carcaça variou entre 273 Kg e 370 Kg). O peso da carcaça foi estimado com 85% de precisão.

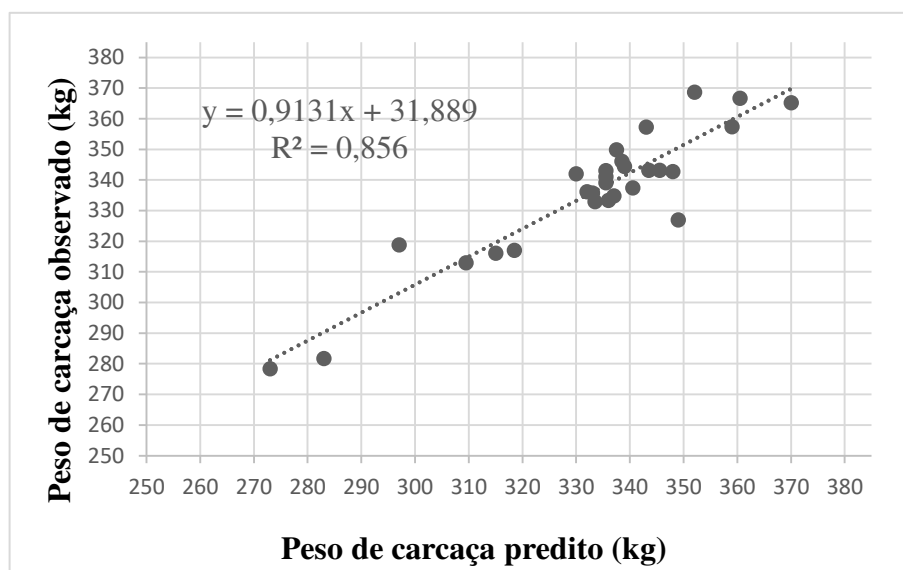


Figura 2 - Relação entre os valores preditos pela análise de imagem do peso de carcaça com os observados em bovinos castrados (equação para machos castrados).

Os resultados demonstram que o processamento de imagens tem a capacidade de extrair as medidas biométricas em bovinos e pode ser útil na predição do peso de carcaça e do grau de acabamento de gordura estimados por escores visuais. Considerando que as características genéticas influenciam a conformação corporal, as características morfológicas podem se diferenciar devido às diferentes raças e cruzamentos. Diante disso, faz-se necessário adquirir um maior número de imagens, processá-las com a mesma metodologia e avaliar as potenciais medidas extraídas.

CONCLUSÕES

Diante ao exposto, pode-se concluir que os atributos biométricos obtidos pela análise de imagens digitais de bovinos de corte *in vivo* sofrem variação devido ao sexo e indicam que é possível monitorar o desenvolvimento corporal dos bovinos de corte para avaliar o acabamento de gordura, visto que carcaças de diferentes acabamentos apresentam diferentes atributos biométricos.

AGRADECIMENTOS

Este projeto recebeu apoio nº APQ-02577-14 da FAPEMIG, INCT-CA e nº 477399 / 2012-6 do CNPq, e SEBRAE MG 004253/2017, Brasil. Gostaríamos de

agradecer, ainda, ao Minerva Foods e Intergado por sua cooperação durante este projeto.

REFERÊNCIAS

- Altarriba, J., Varona, L., Moreno, C., Yagüe, G., Sañudo, C. (2005). Consequences of selection for growth on carcass and meat quality in Pirenaica cattle. *Livestock Production Science*, 95(1-2), 103-114.
- Bonilha, S. F. M., Tedeschi, L. O., Packer, I. U., Razook, A. G., Alleoni, G. F., Nardon, R. F., Resende, F. D. (2008). Evaluation of carcass characteristics of *Bos indicus* and tropically adapted *Bos Taurus* breeds selected for postweaning weight. *Journal of Animal Science*, 86(8), 1770-1780.
- Brasil, Ministério da Agricultura, Pecuária e Abastecimento. Divisão de Normas Técnicas. Instrução Normativa n. 3, de 17 de janeiro de 2000. Aprova o Regulamento Técnico de Métodos de Insensibilização para o Abate Humanitário de Animais de Açougue. *Diário Oficial da União*, Brasília, 24 jan. 2000. Seção I, p. 14-16, 2000.
- Charagu, P. K., Crews Jr, D. H., Kemp, R. A., & Mwansa, P. B. (2000). Machine effects on accuracy of ultrasonic prediction of backfat and ribeye area in beef bulls, steers and heifers. *Canadian Journal of Animal Science*, 80(1), 19-24.
- Cominotte, A., Fernandes, A. F. A., Dorea, J. R. R., Rosa, G. J. M., Ladeira, M. M., van Cleef, E. H. C. B., Pereira, G., Baldassini, W., Neto, O. M. (2020). Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases. *Livestock Science*, 232, 103904. <https://doi.org/10.1016/j.livsci.2019.1039feature04>.
- Cyrillo, J. N. D. S. G., Nardon, R. F., Mercadante, M. E. Z., Bonilha, S. F. M., Arnandes, R. H. B. (2012). Relações entre medidas biométricas, características de carcaça e cortes cárneos comerciais em bovinos Zebu e Caracu. *Boletim de Indústria Animal*, 69(1), 71-77.
- Fisher, A. V. (1975). The profile area of beef carcasses and its relationship to carcass composition. *Animal Science*, 20(3), 355-361.

- Gomes, R. A., Monteiro, G. R., Assis, G. J. F., Busato, K. C., Ladeira, M. M., Chizzotti, M. L. (2016). Estimating body weight and body composition of beef cattle through digital image analysis. *Journal of Animal Science*, 94(12), 5414-5422. <https://doi.org/10.2527/jas.2016-0797>
- Greiner, S.P. (1999). The use of ultrasound measurements in beef breeding programs. *Livestock Update*. Disponível em: https://www.sites.ext.vt.edu/newsletter-archive/livestock/aps-99_12/aps-0148.html. Acesso em: 06 de abril de 2021.
- Hyslop, J. J., Ross, D. W., Schofield, C. P., Navajas, E., Roehe, R., Simm, G. (2008). An assessment of the potential for live animal digital image analysis to predict the slaughter liveweights of finished beef cattle. In *Proceedings of the British society of animal science* (Vol. 2008, pp. 50-50). Cambridge University Press.
- Kempster, A. J., Owen, M. G. (1981). A note on the accuracy of an ultrasonic technique for selecting cattle of different breeds for slaughter at equal fatness. *Animal Science*, 32(1), 113-115.
- Koch, R. M., Cundiff, L. V., Gregory, K. E., Van Vleck, L. D. (2004). Genetic response to selection for weaning weight or yearling weight or yearling weight and muscle score in Hereford cattle: Efficiency of gain, growth, and carcass characteristics. *Journal of Animal Science*, 82(3), 668-682.
- Le Cozler, Y., Allain, C., Xavier, C., Depuille, L., Caillot, A., Delouard, J. M., Delattre, L., Luginbunl, T., Faverdin, P. (2019). Volume and surface area of Holstein dairy cows calculated from complete 3D shapes acquired using a high-precision scanning system: Interest for body weight estimation. *Computers and Electronics in Agriculture*, 165, 104977. ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2019.104977>.
- Mota, L. F. M., de Albuquerque Mariz, T. M., do Sacramento Ribeiro, J., da Silva, M. E. F., de Lima Júnior, D. M. (2015). Divergência morfométrica em bovinos Nelore em crescimento classificados para diferentes classes de Frame Size. *Revista Caatinga*, 28(2), 117-125.

Nir, O., Parmet, Y., Werner, D., Adin, G., Halachmi, I. (2018). 3D Computer-vision system for automatically estimating heifer height and body mass. *Biosystems engineering*, 173, 4-10.

OpenCV Team. OpenCV. URL: <https://opencv.org/>.

Paulino, P. V. R., Valadares Filho, S. D. C., Detmann, E., Valadares, R. F. D., Fonseca, M. A., Vêras, R. M. L., Oliveira, D. M. (2008). Desempenho produtivo de bovinos Nelore de diferentes classes sexuais alimentados com dietas contendo dois níveis de oferta de concentrado. *Revista Brasileira de Zootecnia*, 37, 1079-1087. <https://doi.org/10.1590/S1516-35982008000600019>

Perkins, T. L., Green, R. D., Hamlin, K. E., Shepard, H. H., Miller, M. F. (1992). Ultrasonic prediction of carcass merit in beef cattle: evaluation of technician effects on ultrasonic estimates of carcass fat thickness and longissimus muscle area. *Journal of Animal Science*, 70(9), 2758-2765.

Piazzon, C. J., De Oliveira, D. M., Saldanha, L., Escobar, M. G. D. D. R., Filho, V. R. A., Santos, Y. O.,..., Leite, F. G. V. (2018) Correlação entre mensurações biométrica e peso vivo em animais cruzados $\frac{3}{4}$ wagyu-black $\frac{1}{4}$ angus. *Zootecnia Brasil. Anais. Aquidauana, MS, Brasil*, p. 1-5.

Python Software Foundation. Python. URL: <https://www.python.org/>.

Qiao, Y., Truman, M., Sukkarieh, S. (2019). Cattle segmentation and contour extraction based on Mask R-CNN for precision livestock farming. *Computers and electronics in agriculture*, 165, 104958.

Rosa, B. L., Oliveira, E. A., Henrique, W., Pivarro, T. M., Carvalho, V. G., Mota, D. A., Paz, C. C. P., Andrade, A. T., Sampaio, A. A. M. (2015). Teores de óleo de linhaça para bovinos confinados: medidas corporais, carcaça e cortes cárneos. *Revista Brasileira de Saúde e Produção Animal*, 16, 850-864. <https://doi.org/10.1590/S1519-99402015000400009>

Silva, S. D. L., Leme, P. R., Putrino, S. M., Martello, L. S., Lima, C. G. D., Lanna, D. P. D. (2004). Estimativa da gordura de cobertura ao abate, por ultra-som, em tourinhos Brangus e Nelore. *Revista Brasileira de Zootecnia*, 33, 511-517.

- Sobrinho, T. L., Bonilha, S. F. M., Gonçalves, H. C., Castilhos, A. M. D., Magnani, E., Razook, A. G., Branco, R. H. (2013). Feedlot performance, feed efficiency and carcass traits in Nellore cattle selected for postweaning weight. *Revista Brasileira de Zootecnia*, 42, 125-129.
- Waldner, D. N., Dikeman, M. E., Schalles, R. R., Olson, W. G., Houghton, P. L., Unruh, J. A., Corah, L. R. (1992). Validation of real-time ultrasound technology for predicting fat thicknesses, longissimus muscle areas, and composition of Brangus bulls from 4 months to 2 years of age. *Journal of Animal Science*, 70(10), 3044-3054.
- Weber, V. A. D. M., Weber, F. D. L., Gomes, R. D. C., Oliveira, A. D. S., Menezes, G. V., Abreu, U. G. P. D., Belete, N. A. de S., Pistori, H. (2020). Prediction of Girolando cattle weight by means of body measurements extracted from images. *Revista Brasileira de Zootecnia*, 49. <https://doi.org/10.37496/rbz4920190110>.
- Weber, V. A. M., Weber, F. de L., Oliveira, A. da S., Astolfi, G., Menezes, G. V., Porto, J. V. de A., Rezende, F. P. C., Moraes, P. H., Matsubara, E. T., Mateus, R. G., Araújo, T. L. A. C., Silva, L. O. C., Queiroz, E. Q. A., Abreu, U. G. P., Gomes, R. da C., Pistori, H. (2020). Cattle weight estimation using active contour models and regression trees bagging. *Computers and Electronics in Agriculture*, 179, 105804. ISSN 0168-1699. doi.org/10.1016/j.compag.2020.105804.
- Xu, B., Wang, W., Falzon, G., Kwan, P., Guo, L., Chen, G., Schneider, D. (2020). Automated cattle counting using Mask R-CNN in quadcopter vision system. *Computers and Electronics in Agriculture*, 171, 105300.
- Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), 267-288.

CAPÍTULO 3

EFEITO DA CLASSE SEXUAL E ESCORE DE ACABAMENTO DE GORDURA SUBCUTÂNEA SOBRE MEDIDAS BIOMÉTRICAS OBTIDAS PELA ANÁLISE DE IMAGENS DIGITAIS DE CARÇAÇAS BOVINAS.

Gutierrez J. F. Assis*¹, Débora E. F. Assis*, Gustavo B. Carneiro*, André L.C.

Mendes*, Mario L. Chizzotti*¹.

* Departamento de Zootecnia, Universidade Federal de Viçosa, Viçosa, Minas Gerais, Brasil, 36.570-900.

¹Autores correspondentes. E-mail: gutierrez.assis@ufv.br; mariochizzotti@ufv.br

RESUMO

A carcaça é o elemento mais importante do animal, pois nela está contida a porção comestível e de maior valor comercial. Em virtude disso, faz-se necessário comparar características de carcaça visando identificar as melhores, uma vez que medidas da carcaça podem apresentar correlação com o peso e ser utilizadas como indicadores quantitativos e qualitativos. Portanto, podem ser adotadas em sistemas de classificação de carcaças bovinas. Diante disso, os objetivos neste estudo são avaliar o efeito da classe sexual sobre a morfologia da carcaça, e investigar as relações entre as medidas biométricas da carcaça com os escores de acabamento atribuídos em frigorífico comercial, por meio do processamento de imagens digitais coletadas na linha de abate. O experimento foi conduzido com dados coletados em frigorífico comercial. Foram utilizados dados de 266 animais de diferentes composições genéticas, classes sexuais (Fêmeas = 96 e Machos = 170), idades e pesos. Os animais foram aleatoriamente selecionados nos currais de espera dos frigoríficos, identificados, submetidos a jejum de sólidos durante 16 horas e, posteriormente, abatidos por meio de concussão cerebral e secção da veia jugular para sangramento total. Após o abate, a carcaça de cada animal foi dividida longitudinalmente em duas metades, o escore de acabamento foi mensurado pela observação visual, realizada por profissionais treinados e, em seguida, as carcaças foram resfriadas em câmara fria a 4 °C por 24 horas. As meia-carcaças foram utilizadas para obtenção de imagens digitais. Utilizou-se para isso o dispositivo Intel® RealSense™, implementado em Python (baseado em OpenCV, 2015). O sensor foi instalado no final da linha de abate. As imagens foram analisadas e foram obtidos os parâmetros biométricos a serem utilizados. Os dados coletados foram analisados pelo método dos quadrados mínimos por meio dos procedimentos gerais de modelos lineares (Proc GLM) contidos no pacote estatístico SAS 9.0 (Statistical Analysis System Institute, Inc.). Para medidas biométricas, o modelo utilizado incluiu o efeito do peso das meia-carcaças como covariável. As médias foram comparadas pelo teste de Tukey (5%) para estimar a significância das diferenças entre as mesmas. Houve influência da classe sexual para área, perímetro e circularidade, sendo os machos os que apresentaram maiores valores. Não foi observada diferença estatística ($P > 0,05$) entre as demais medidas biométricas. Com relação aos escores de acabamento, verifica-se que estes são influenciados pelas medidas

biométricas. A largura, área, volume projetado, redondez, relação perímetro/área e densidade, diferiram significamente ($P < 0,05$) entre os escores. Em geral, as maiores médias dos parâmetros biométricos foram observadas para o escore uniforme. Contrariamente ao esperado, as médias não apresentaram aumento linear, havendo sobreposição das médias (largura, área, redondez e relação perímetro/área) nos escores mais baixos atribuídos às carcaças, o que pode ser justificado pela presença de animais de diferentes classes sexuais e frames no banco de dados. Os resultados indicam que a análise de imagem pode ser utilizada para obter as medidas biométricas em carcaças.

Palavras-chave: biometria, correlação, predição, processamento de imagens, sensor, sexo.

INTRODUÇÃO

A carcaça é o elemento mais importante do animal, pois nela está contida a porção comestível e de maior valor comercial (Pires et al., 1999). Por esse motivo, diversos métodos foram desenvolvidos para estimar a composição da carcaça bovina, sendo a avaliação visual predominante em muitos países (Luchiari Filho, 2000). No entanto, as avaliações são realizadas de forma subjetiva, o que implica em padrões de qualidade diferenciados e impossibilidade de hierarquização de carnes de frigoríficos distintos, uma vez que os critérios de avaliação variam de acordo com o avaliador. Nesse sentido, são necessárias ferramentas que permitam aos frigoríficos avaliar de forma objetiva as carcaças.

Em virtude disso, comparar características de carcaça utilizando mensurações biométrica, permite identificar as possíveis diferenças entre elas, proporcionando hierarquizar as melhores, visto que medidas da carcaça apresentam correlação com o peso e podem ser utilizadas como indicadores quantitativos e qualitativos, e adotadas em sistemas de classificação de carcaças (Pinheiro & Jorge, 2010). Entretanto, informações sobre as medidas na carcaça e suas possíveis correlações ainda são escassas, sendo necessário um maior número de estudos que avaliem as medidas nas carcaças e, assim permita conhecer qual ou quais medidas são os melhores indicadores de rendimento e qualidade da carcaça. Diante disso, os objetivos neste estudo são avaliar o efeito da classe sexual sobre a morfologia da carcaça, e investigar as relações entre as medidas biométricas da carcaça com os escores de acabamento atribuídos em frigorífico comercial, por meio do processamento de imagens digitais coletadas na linha de abate.

MATERIAIS E MÉTODOS

Todos os procedimentos pré-abate e abate dos bovinos seguiram as normas estabelecidas pela Instrução Normativa n. 3, de 17 de janeiro de 2000, instituída pelo Ministério da Agricultura Pecuária e Abastecimento (BRASIL, 2000).

Local e animais

O experimento foi conduzido com dados coletados em frigorífico comercial. Foram utilizados dados de 266 animais de diferentes composições genéticas, classes sexuais (Fêmeas = 96 e Machos = 170), idades, pesos e,

conseqüentemente, diferentes escores de acabamento. Os animais foram aleatoriamente selecionados nos currais de espera dos frigoríficos. Estes foram identificados, submetidos a jejum de sólidos durante 16 horas e em seguida, os animais foram abatidos por meio de concussão cerebral e secção da veia jugular para sangramento total do animal. Após o abate, a carcaça de cada animal foi dividida longitudinalmente, pesada e o escore de acabamento mensurado pela observação visual realizada por profissionais treinados e, em seguida, as carcaças foram resfriadas a 4 °C por 24 horas. Todos os animais tiveram as carcaças avaliadas quanto ao acabamento de gordura, conforme descrito no Sistema Nacional de Tipificação de Carcaças Bovinas (Ausente (< 1 mm), Escassa (1 - 3 mm), Mediana (3 - 6 mm), Uniforme (6 - 10 mm) e Excessiva (> 10 mm de espessura de gordura)), instituído pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA). Não foi registrada nenhuma carcaça com escore excessivo de acabamento e, portanto, essa classe não pôde ser incluída na avaliação.

Obtenção de imagens

A infraestrutura de captura de imagem foi instalada em frigorífico comercial. O sensor foi posicionado no final da linha de abate, permitindo coletar imagens de uma carcaça por vez com o Intel® RealSense™. Este dispositivo combina uma câmera RGB e um sensor de profundidade. O sensor de profundidade consiste em um projetor de infravermelho e um sensor de infravermelho e usa o princípio de medição "Luz estruturada" para coletar informações de profundidade. Um padrão de pontos de laser infravermelho é projetado na cena. Sua deformação é detectada pelo sensor infravermelho e usada para calcular os valores de profundidade. O sensor possui um campo de visão de 85,2° na horizontal e 58° na vertical, uma resolução de 1280 x 720 pixels e pode gravar até 90 imagens de profundidade por segundo.

O *software* para operar as câmeras Intel® RealSense™ foi implementado em Python (baseado em OpenCV, 2015). As opções de imagens RGB, mapa de profundidade ou ambos, na sobreposição, foram exibidos no monitor para verificação da qualidade dos dados coletados. Os fluxos de dados foram nomeados automaticamente para evitar a substituição.

O tratamento das imagens, bem como as medições foram realizados automaticamente no Python. As imagens foram segmentadas com auxílio da função

threshold_otsu do módulo Skimage, o que permitiu obter a região correspondente à carcaça. A função threshold_otsu recebe uma imagem e separa os objetos da imagem de forma binária. O retorno da função é um limiar que foi utilizado como uma máscara na filtragem dos pixels da imagem. O código foi capaz de processar as imagens e extrair as medidas de interesse.

Parâmetros corporais avaliados

Nas imagens, foram obtidos os seguintes parâmetros biométricos: área da carcaça (AC), densidade (DEN), largura (LAR), comprimento (COM), alongação (ELON), volume projetado (VOL), perímetro (PER), circularidade (CIR), redondez (RED), e relação perímetro/área (RPA). As medidas de largura e comprimento foram feitas cruzando-se uma linha para cada medida (Figura 1).

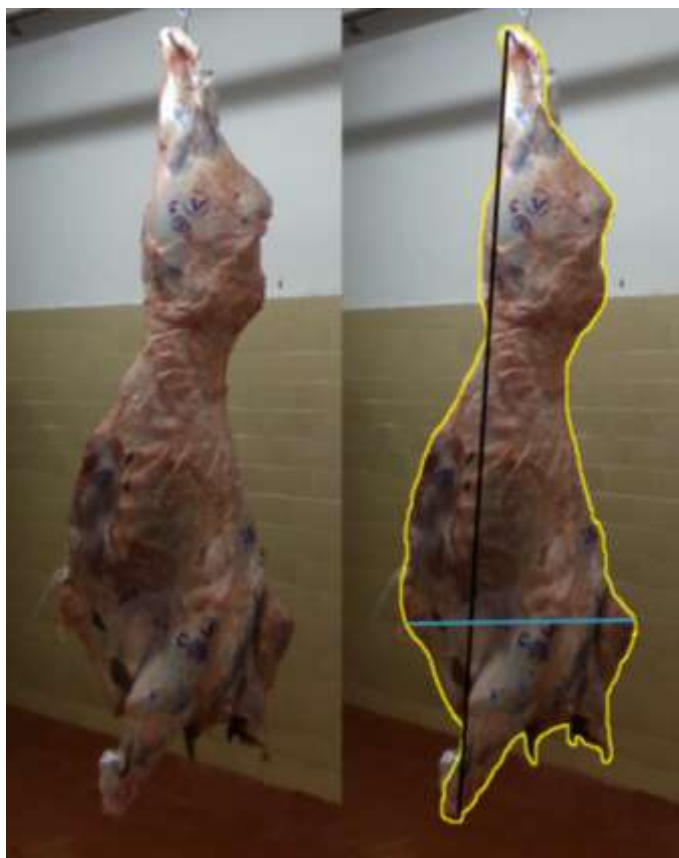


Figura 1 - Ilustração das medidas obtidas pela análise de imagens, área da carcaça (contorno em amarelo), largura (linha azul), comprimento total (linha preta).

Área da carcaça: quantidade de espaço bidimensional presente no quadro, em metros quadrados (m^2). Densidade: Razão do tamanho e a dimensionalidade, ou seja, a quantidade de massa que está contida em um espaço (volume).

$$D = \frac{\text{Massa (meia carcaça, kg)}}{\text{Volume (m}^3\text{)}}$$

Largura: maior diâmetro da carcaça no menor eixo da imagem, em metros (m). Comprimento total: uma linha na superfície da carcaça, desde a porção distal do tarso (jarrete) até a porção distal do carpo (joelho), em metros. Elongação: Razão computada entre a largura do menor eixo e o comprimento do maior eixo. Quanto maior o resultado, mais a forma da carcaça se aproxima da forma quadrada e/ou redonda e, conforme a razão diminui, mais alongada é a carcaça.

$$E = \frac{\text{Largura}}{\text{Comprimento}}$$

O volume projetado da carcaça: foi considerado como um casco convexo. Foi calculado o volume do menor conjunto convexo que contém o conjunto de pontos referentes à carcaça, em metros cúbicos (m³). Perímetro: medida do contorno da imagem (m). Circularidade (diâmetro circular equivalente): Refere-se ao quanto a forma do objeto se aproxima à de um círculo (adimensional).

$$C = \frac{\text{Perímetro}}{\pi}$$

Redondez: Razão baseada nos descritores de área e perímetro.

$$R = \frac{4\pi * \text{área}}{\text{Perímetro}}$$

Relação Perímetro /Área: Razão entre o perímetro da carcaça e a área.

$$RPA = \frac{\text{Perímetro}}{\text{Área}}$$

Análise estatística

Os dados coletados foram analisados pelo método dos quadrados mínimos por meio dos procedimentos gerais de modelos lineares (Proc GLM) contidos no pacote estatístico SAS 9.0 (Statistical Analysis System Institute, Inc.). Para avaliação das medidas biométricas o modelo utilizado incluiu apenas o efeito de sexo. Para o escore de acabamento de gordura subcutânea o modelo utilizado incluiu os efeitos de sexo e interação entre sexo e acabamento de gordura. As médias foram

comparadas pelo teste de Tukey (5%) para estimar a significância das diferenças entre as mesmas.

RESULTADOS E DISCUSSÃO

A estatística descritiva dos dados utilizados no presente estudo são apresentadas na Tabela 1.

Tabela 1 - Estatística descritiva das variáveis utilizadas.

Variável	N	Média	Desvio padrão	Mínimo	Máximo
Peso de carcaça total (kg)	266	292,5	59,00	138,4	425,0
Peso da meia-carcaça (kg)	266	147,0	29,85	71,50	208,9
Área (m ²)	266	1,618	0,154	1,120	2,130
Densidade (kg/m ³)	265	89,74	15,33	46,59	131,3
Largura (m)	266	0,726	0,054	0,520	0,880
Comprimento total (m)	254	2,885	0,301	1,650	3,240
Elongação	266	0,807	0,096	0,550	0,980
Volume projetado (m ³)	265	1,636	0,174	1,090	2,450
Perímetro (m)	266	6,282	0,244	5,420	6,890
Circularidade	266	1,999	0,077	1,730	2,190
Redondez	266	3,231	0,221	2,370	3,910
Relação perímetro área	266	3,908	0,279	3,210	5,310

Na Tabela 2, estão apresentados os coeficientes de correlação e respectivo nível de significância entre peso de carcaça total, peso da meia-carcaça, medidas biométricas e escore de gordura subcutânea. As correlações entre o peso da meia carcaça e os parâmetros biométricos extraídos das imagens variaram de -0,544 a 0,871. A relação perímetro/área e a densidade, dentre todos os parâmetros extraídos das imagens digitais, tiveram as correlações mais baixa e mais alta com o peso das meia-carcaças bovinas, respectivamente.

Tabela 2 - Coeficientes de correlação (abaixo da diagonal) e valores P (acima da diagonal) entre peso de carcaça, medidas biométricas e escore de acabamento de gordura subcutânea.

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	-	0,0001	0,855	0,0001	0,359	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001
2	0,997	-	0,815	0,0001	0,370	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001
3	-0,011	-0,014	-	0,020	0,049	0,451	0,046	0,860	0,830	0,247	0,300	0,0361	0,266
4	0,346	0,319	0,141	-	0,479	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,420
5	-0,057	-0,056	0,123	-0,044	-	0,079	0,862	0,879	0,884	0,013	0,021	0,559	0,260
6	0,622	0,615	0,046	0,651	-0,110	-	0,0001	0,0001	0,0001	0,0001	0,0001	0,0009	0,0001
7	0,529	0,519	0,122	0,591	0,010	0,865	-	0,0001	0,0001	0,0001	0,0001	0,0001	0,347
8	0,608	0,616	-0,010	0,383	0,009	0,811	0,663	-	0,0001	0,0001	0,0001	0,282	0,0001
9	0,609	0,618	-0,013	0,380	0,009	0,809	0,661	0,999	-	0,0001	0,0001	0,317	0,0001
10	0,540	0,526	0,071	0,698	-0,154	0,946	0,843	0,581	0,580	-	0,0001	0,0001	0,0172
11	-0,544	-0,531	-0,063	-0,699	0,144	-0,938	-0,840	-0,582	-0,580	-0,992	-	0,0001	0,0146
12	-0,304	-0,277	-0,128	-0,54	-0,036	-0,203	-0,244	-0,066	-0,061	-0,250	0,240	-	0,0003
13	0,871	0,875	-0,068	0,049	-0,071	0,233	0,057	0,338	0,340	0,146	-0,149	-0,222	-

1: Peso da meia carcaça (kg); 2: Peso de carcaça total (kg); 3: Escore de gordura subcutânea; 4: largura (m); 5: comprimento total (m); 6: Área (m²); 7: Volume projetado da carcaça (m³); 8: Perímetro (m); 9: Circularidade; 10: Redondez; 11: Relação Perímetro/Área (RPA); 12: Elongação; 13: Densidade (kg/m³).

O coeficiente de correlação encontrados entre peso da meia-carcaça e a largura total foi baixo e significativo ($r^2=0,346$, $P<0,05$). A estimativa de correlação entre as características peso da meia carcaça e área foi moderada e significativa ($P<0,05$), assim como a correlação entre peso da meia-carcaça e o volume projetado, apresentando valores de 0,62 e 0,53, respectivamente. Nesse sentido, a área e o volume projetado podem ser consideradas medidas relevantes quando se objetiva estimar o peso, haja vista, que o peso, por sua vez, é o principal preditor do rendimento de cortes cárneos.

O coeficiente de correlação encontrado entre peso da meia-carcaça e gordura subcutânea foi baixo e não significativo ($P<0,05$). Contrariamente à correlação encontrada neste estudo, Kuss et al. (2005), ao avaliarem o efeito de diferentes pesos de abate sobre a composição física da carcaça e características qualitativas da carne em vacas mestiças Nelore x Charolês, encontraram coeficiente de correlação de 0,83 entre peso da carcaça e gordura total da carcaça. Esta diferença se deu, provavelmente, devido à diferença na obtenção dos dados de gordura. No presente estudo, a gordura foi obtida por meio de escore de acabamento, avaliado por um avaliador treinado.

Embora o comprimento total possua importância significativa na avaliação dos bovinos, visto que apresenta alta correlação com as características de crescimento (Cyrillo et al., 2002), as correlações estimadas entre o comprimento total das carcaças e as demais características biométricas foram, em geral, não significativas ($P>0,05$) e, na maioria, baixas. A área apresentou estimativa de correlações altas e significativas ($P <0,05$) com volume projetado, perímetro, circularidade e redondez (r^2 entre 0,80 e 0,94), o que mostra a forte associação existente entre a área e as demais variáveis corporais.

Frente ao exposto acima, objetivou-se avaliar os parâmetros biométricos das carcaças separados por classe sexual (Tabela 3).

Tabela 3 - Efeito do sexo nas medidas biométricas das carcaças bovinas.

Variável	Classe sexual		EPM	P-valor
	Fêmea (n = 96)	Macho (n = 170)		
Peso carcaça total (kg)	292,7	292,3	0,570	0,610
Área (m ²)	1,579b	1,639a	0,016	0,012
Densidade (kg/m ³)	91,21	88,92	1,068	0,129
Largura (m)	0,726	0,727	0,007	0,927
Comprimento total (m)	2,886	2,885	0,043	0,982
Elongação	0,788	0,818	0,012	0,110
Volume projetado (m ³)	1,610	1,651	0,021	0,162
Perímetro (m)	6,199b	6,329a	0,026	0,0006
Circularidade	1,973b	2,014a	0,008	0,0006
Redondez	3,198	3,249	0,026	0,163
Relação perímetro área	3,952	3,883	0,032	0,136

EPM: erro padrão da média.

Observa-se que houve diferença significativa ($P < 0,05$) entre machos e fêmeas quando se avalia área, perímetro e circularidade, sendo os machos os que apresentaram resultados superiores. Para os demais parâmetros biométricos, não houve diferença ($P > 0,05$) entre machos e fêmeas. Resultado este condizente com o esperado, já que é sabido que a classe sexual tem relação direta com as medidas biométricas e com a composição corporal, visto que as fêmeas atingem a maturidade fisiológica mais precocemente se comparadas aos machos. Paulino et al. (2008) relatam que a classe sexual determina diferenças no crescimento e nas taxas de deposição dos tecidos corporais e da carcaça, uma vez que machos inteiros apresentam maior taxa de crescimento (10 a 20%) em relação a machos castrados e fêmeas, que apresentam carcaças acabadas em um menor intervalo de tempo, devido à precocidade de deposição do tecido adiposo nestes animais, sendo necessários estudos sobre características de carcaça para a classe sexual. Nesse sentido, realizou-se um trabalho investigativo com o objetivo de verificar se o escore de acabamento de gordura da carcaça é influenciado pelos parâmetros biométricos. Na Tabela 4 são apresentadas as médias dos parâmetros biométricos em função dos escores de acabamento atribuídos às carcaças.

Tabela 4 - Efeito do escore de acabamento de gordura subcutânea sobre as medidas biométricas das carcaças.

Variável	Escore de acabamento de gordura subcutânea				EPM	P-valor		
	Ausente (n =21)	Escassa (n = 90)	Mediana (n = 98)	Uniforme (n = 57)		EAGS	Classe sexual	EAGS*Classe sexual
Peso carcaça total (kg)	292,2	292,7	292,7	291,8	1,319	0,543	0,587	0,738
Área (m ²)	1,599ab	1,591b	1,594b	1,654a	0,038	0,013	0,032	0,607
Densidade (kg/m ³)	91,55a	91,12a	91,08a	87,09b	2,408	0,007	0,170	0,652
Largura (m)	0,732ab	0,713b	0,722b	0,747a	0,006	0,002	0,539	0,451
Comprimento total (m)	2,799	2,860	2,887	2,934	0,099	0,480	0,985	0,812
Elongação	0,832	0,809	0,811	0,777	0,012	0,092	0,633	0,761
Volume projetado (m ³)	1,561b	1,595b	1,613b	1,696a	0,046	0,0005	0,039	0,175
Perímetro (m)	6,239	6,216	6,273	6,281	0,061	0,258	0,001	0,222
Circularidade	1,987	1,979	1,997	1,999	0,008	0,270	0,002	0,235
Redondez	3,215ab	3,210b	3,188b	3,305a	0,059	0,002	0,266	0,770
Relação perímetro área	3,933ab	3,935a	3,964a	3,817b	0,074	0,002	0,218	0,678

EPM: erro padrão da média; EAGS: Escore de acabamento de gordura subcutânea

Verifica-se que existe uma relação entre as medidas biométricas e o escore de acabamento de gordura. Contrariamente ao encontrado por Boito et al., (2018), o peso de carcaça não aumentou com o aumento da espessura de gordura, e, portanto, não foi observada diferença estatística entre estes. Verificou-se diferenças significativas entre o escore de acabamento e as variáveis de largura, área, volume projetado, redondez, relação perímetro/área e densidade. As maiores médias, na maioria das variáveis, foram observadas para o escore uniforme, indicando que os animais, ao serem abatidos, provavelmente já haviam atingindo o total desenvolvimento corporal.

O volume projetado apresentou a maior média para o escore de acabamento uniforme e as menores médias para os escores ausente, escasso e mediano, que não diferiram entre si. Comportamento contrário pode ser observado para a densidade, menor média para o escore de acabamento uniforme e as maiores médias para os escores ausente, escasso e mediano, que não diferiram entre si. Este resultado é condizente com o esperado, uma vez que, quanto maior o teor de gordura na carcaça, maior tende a ser o volume projetado e menor a densidade, visto que a gordura, ao ser depositada, proporciona mudança nas características biométricas. No entanto, devido à menor densidade da gordura em comparação com a deposição de massa magra (músculos), ocorre pouca oscilação no peso da carcaça.

A largura total apresentou menores médias nos escores de acabamento escasso e mediano, maior média no escore uniforme e valor intermediário no escore de acabamento ausente, o que pode ser justificado, provavelmente, pela diferença no grupo genético. Animais com maior porte à maturidade apresentam crescimento mais acelerado e maior deposição muscular (Bianchini et al., 2008), porém necessitam de mais tempo para depositar tecido adiposo em quantidade apropriada para abate. Portanto, animais de grande porte atingirão o nível de gordura corporal em peso mais elevado que animais de tamanho corporal pequeno (Block et al., 2001). O que colabora com essa afirmação é o fato dessas carcaças apresentarem área e volume projetado similares a outros escores de acabamento, direcionando que as carcaças podem ser provenientes de um animal de maior porte, que ainda não completou seu desenvolvimento corporal (Berg & Butterfield, 1976).

A classe sexual também influencia a composição corporal, sendo que as fêmeas apresentam maior deposição de tecido adiposo do que os machos não castrados, e os machos castrados são intermediários (Paulino, 2006). Assim, as fêmeas possuem deposição de gordura mais precoce que os machos, resultando em idade ao abate distinta entre as diferentes classes sexuais. No entanto, na amostra estudada, não se observou interação entre a classe sexual e o escore de acabamento das carcaças, o que, provavelmente, se justifica pelo grau de maturidade e porte dos animais abatidos, conforme foi discutido anteriormente.

CONCLUSÕES

As medidas biométricas das carcaças são influenciadas pela classe sexual. As medidas biométricas simples são influenciadas pelo acabamento de gordura subcutânea, no entanto, um maior número de imagens é necessário para se obter uma melhor delimitação das médias referentes a cada escore de acabamento

AGRADECIMENTOS

Este projeto recebeu apoio nº APQ-02403-17 da FAPEMIG, INCT-CA e nº 477399 / 2012-6 e 443718/2018-0 do CNPq, SEBRAE MG 004253/2017, Brasil. Gostaríamos de agradecer, ainda, ao Minerva Foods e a Intergado por sua cooperação durante este projeto.

REFERÊNCIAS

- Berg, R. T., Butterfield, R. M. (1976). *New concepts of cattle growth*. Sydney University Press, University of Sydney.
- Bianchini, W., Silveira, A. C., Arrigoni, M. D. B., Jorge, A. M., Martins, C. L., Rodrigues, É. (2008). Crescimento e características de carcaça de bovinos superprecoces Nelore, Simental e mestiços. *Revista Brasileira de Saúde e Produção Animal*, 9(3), 554-564.
- Block, H. C., McKinnon, J. J., Mustafa, A. F., Christensen, D. A. (2001). Manipulation of cattle growth to target carcass quality. *Journal of animal science*, 79(1), 133-140.

- Boito, B., Kuss, F., Menezes, L. F. G. D., Lisbinski, E., Paris, M. D., Cullmann, J. R. (2018). Influence of subcutaneous fat thickness on the carcass characteristics and meat quality of beef cattle. *Ciência Rural*, 48. <https://doi.org/10.1590/0103-8478cr20170333>
- Bonilha, S. F. M., Tedeschi, L. O., Packer, I. U., Razook, A. G., Nardon, R. F., Figueiredo, L. A., Alleoni, G. F. (2011). Chemical composition of whole body and carcass of *Bos indicus* and tropically adapted *Bos Taurus* breeds. *Journal of animal science*, 89(9), 2859-2866. Doi: 10.2527/jas.2010-3649
- Brasil, Ministério da Agricultura, Pecuária e Abastecimento. Divisão de Normas Técnicas. Instrução Normativa n. 3, de 17 de janeiro de 2000. Aprova o Regulamento Técnico de Métodos de Insensibilização para o Abate Humanitário de Animais de Açougue. *Diário Oficial da União*, Brasília, 24 jan. 2000. Seção I, p. 14-16, 2000.
- Bullock, K. D., Bertrand, J. K., & Benyshek, L. L. (1993). Genetic and environmental parameters for mature weight and other growth measures in Polled Hereford cattle. *Journal of Animal Science*, 71(7), 1737-1741.
- Cyrillo, J. N. S. G., Razook, A. G., Mercadante, M. E. Z., Figueiredo, L. A., Ruggieri, A. C. (2002). Genetic changes to selection for yearling weight and correlated responses on body measurements in Nelore cattle. In *World Congress Of Genetics Applied To Livestock Production* (Vol. 7, pp. 02-83).
- Kuss, F., Restle, J., Brondani, I. L., Alves Filho, D. C., Perottoni, J., Missio, R. L., Amaral, G. A. D. (2005). Composição física da carcaça e qualidade da carne de vacas de descarte de diferentes grupos genéticos terminadas em confinamento com distintos pesos. *Revista Brasileira de zootecnia*, 34, 1285-1296.
- Lu, W., Tan, J. (2004). Analysis of image-based measurements and USDA characteristics as predictors of beef lean yield. *Meat science*, 66(2), 483-491.
- Luchiari Filho, A. *Pecuária da carne bovina*. São Paulo: LinBife, 2000, 134 p.
- OpenCV Team. OpenCV. URL: <http://opencv.org>

- Paulino, P. V. R. (2006). Desempenho, composição corporal e exigências nutricionais de bovinos Nelore de diferentes classes sexuais. Tese (DoctorScientae) – Universidade Federal de Viçosa.
- Paulino, P. V. R., Valadares Filho, S. D. C., Detmann, E., Valadares, R. F. D., Fonseca, M. A., Vêras, R. M. L., Oliveira, D. M. (2008). Desempenho produtivo de bovinos Nelore de diferentes classes sexuais alimentados com dietas contendo dois níveis de oferta de concentrado. *Revista Brasileira de Zootecnia*, 37, 1079-1087.
- Pinheiro, R. S. B., Jorge, A. M. (2010). Medidas biométricas obtidas in vivo e na carcaça de ovelhas de descarte em diferentes estágios fisiológicos. *Revista Brasileira de Zootecnia*, 39, 440-445. ISSN 1806-9290. <http://dx.doi.org/10.1590/S1516-35982010000200030>
- Pires, C. C., Carvalho, S., Grandi, A. D., Kleszta, R., Falleiro, V. (1999). Características quantitativas e composição tecidual da carcaça de cordeiros terminados em confinamento. *Ciência Rural*, 29, 539-543.
- Tedeschi, L. O., Fox, D. G., Guiroy, P. J. (2004). A decision support system to improve individual cattle management. 1. A mechanistic, dynamic model for animal growth. *Agricultural Systems*, 79(2), 171-204.
- Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), 267-288.

CAPÍTULO 4

SEGMENTAÇÃO AUTOMÁTICA DE IMAGENS DIGITAIS DE CARÇAÇAS BOVINAS UTILIZANDO REDES NEURAS CONVOLUCIONAIS (CNN)

**Gutierrez J. F. Assis^{*1}, André Henrique F. Costa*, Antônio Almeida S. Neto*,
José Augusto M. Nacif*, Lucas Bragança da Silva*, Ricardo Ferreira, Mario L.
Chizzotti^{*1}.**

* Departamento de Zootecnia, Universidade Federal de Viçosa, Viçosa, Minas Gerais, Brasil, 36.570-900.

¹Autores correspondentes. E-mail: gutierrez.assis@ufv.br; mariochizzotti@ufv.br.

RESUMO

A avaliação e tipificação de carcaças permite aos frigoríficos assegurarem a qualidade dos produtos e, conseqüentemente, direcionar a carcaça e a carne para diferentes mercados consumidores. No entanto, os processos de avaliação e tipificação são geralmente realizados de maneira subjetiva e, portanto, sujeita a erros. Para aumentar a precisão de tal tarefa, sistemas de avaliação automática de carcaças, baseados em análise de imagens, são cada vez mais estudados e propostos na literatura. Neste sentido, a segmentação de imagens é uma das etapas mais importantes e complexas, visto que a segmentação pode favorecer o desempenho das etapas subsequentes. Diante disso, o objetivo neste estudo foi desenvolver um algoritmo de segmentação de imagens baseada em arquitetura de rede neural convolucional (CNN - *convolutional neural network*) para a tarefa de segmentação automática da carcaça e dos tecidos em sua superfície. O experimento foi conduzido com dados coletados em frigorífico comercial. Foram utilizadas imagens das meia-carcaças de animais de diferentes composições genéticas, classes sexuais, idades e pesos. A face lateral das meia-carcaças foram utilizadas para obtenção de imagens digitais com resolução espacial de 1280 x 720 pixels. Para obtenção das imagens, foi utilizado o dispositivo Intel® RealSense™. As imagens coletadas foram utilizadas como entrada (*input*) da rede neural Mask R-CNN. Para validar o modelo, utilizou-se a validação através da métrica mAP (mean Average Precision) com os limiares 0,25, 0,5 e 0,75. Os resultados demonstraram que a rede neural desenvolvida teve uma precisão de 98,2% na segmentação da carcaça, representando a robustez do método de segmentação de imagens de carcaças. A Mask R-CNN teve um desempenho satisfatório na estimativa dos tecidos muscular, conectivo e adiposo. A rede foi capaz de detectar com uma acurácia de 66,5, 42,4 e 11,3 % os tecidos, utilizando 200 épocas e sobreposição (IoU) de 25, 50 e 75%, respectivamente. Em função disso, a contribuição neste trabalho é a proposição de um método de segmentação de carcaças e predição da proporção de tecidos em sua superfície, o que pode auxiliar no desenvolvimento de sistemas automatizados de classificação de carcaças em frigoríficos.

Palavras-chave: avaliação, composição corporal, processamento de imagens, predição.

INTRODUÇÃO

A avaliação, classificação e tipificação de carcaças bovinas constitui a base para o fortalecimento das relações entre os produtores de gado e a indústria de processamento de carne. Esses processos são definidos com base em indicadores quantitativos e qualitativos, que determinam o valor da carcaça e, conseqüentemente, da carne produzida. Frequentemente, estes processos são temas de controvérsia. Sendo assim, é importante que estes sejam justos, padronizados e assertivos. Em grande parte dos sistemas existentes, a avaliação da qualidade da carcaça é realizada visualmente por um especialista treinado. No entanto, acredita-se que esta inspeção visual possa ser aprimorada por análise computadorizada. A distinção entre os principais tecidos na superfície da carcaça, em especial a distinção entre a gordura e o tecido conectivo pode ser difícil em estágios iniciais, podendo confundir o especialista. Esta subjetividade associada com a restrição de tempo nas operações frigoríficas, podem ocasionar imprecisões e inconsistências em relação à classificação das carcaças.

Em resposta a esses problemas, algumas tecnologias baseadas em análise de imagens têm sido desenvolvidas para serem utilizadas na avaliação objetiva das carcaças (Tian et al., 2019; De La Iglesia et al., 2020). As tecnologias incluem câmeras de alta definição, ultrassonografia, tomografia computadorizada, espectroscopia no infravermelho próximo (NIRS), imagem de raios-X e outros sistemas. A análise por imagens de vídeo (VIA) é a mais promissora e já está sendo utilizada dentro dos frigoríficos, melhorando a consistência da classificação por remover a subjetividade da avaliação visual (Cannell et al., 2002; Craigie et al., 2012; Beak et al., 2021). Neste sentido, o avanço da tecnologia permitiu o uso de câmeras associadas a programas de processamento de imagens como uma ferramenta eficiente para a avaliação das características de carcaças (Teira et al., 2003; Bittencourt, 2009; Geraldo et al., 2017; Miller et al., 2019; Weber et al., 2020). Estas abordagens estão baseadas em *Machine Learning*, que objetiva a elaboração de algoritmos com capacidade de adquirir conhecimento ao extrair padrões a partir de dados e efetuar a tarefa de predição (Goodfellow et al., 2016), permitindo, assim, realizar a classificação automática das carcaças.

Uma das principais etapas de um sistema baseado em imagens é a segmentação, que visa identificar as regiões de interesse na imagem. A

segmentação é essencial em ambientes não controlados (fundo inconstante), como ocorre na linha de abate. No entanto, mesmo em um ambiente controlado, a segmentação pode ajudar a reduzir o ruído, tornando o sistema ainda mais robusto (Gonçalves et al., 2020). Erros na etapa de segmentação afetam diretamente o desempenho do sistema. Uma boa segmentação aumenta a precisão das etapas posteriores, em sistemas de visão computacional, e, portanto, a escolha do método de segmentação é extremamente importante. Diante do exposto, o objetivo neste estudo foi desenvolver um algoritmo de segmentação de imagens baseada em arquitetura de rede neural convolucional (CNN - *convolutional neural network*) para a tarefa de segmentação automática da carcaça e dos tecidos em sua superfície. Acredita-se que a análise da superfície da carcaça, quantificando as áreas de músculo exposto, tecido conectivo, gordura e suas relações possa contribuir na classificação de carcaças, visto que, quanto maior a área exposta dos tecidos muscular e conectivo, menor será a área recoberta pela gordura subcutânea e, conseqüentemente menor será o escore de acabamento atribuído à carcaça.

MATERIAIS E MÉTODOS

O experimento foi conduzido com dados coletados em frigorífico comercial. Foram utilizadas imagens de meia-carcaças de animais de diferentes composições genéticas, classes sexuais, idades e pesos. A face lateral das meia-carcaças foi utilizada para obtenção de imagens digitais com resolução espacial de 1280 x 720 pixels. As imagens coletadas foram utilizadas como entrada (*input*) da rede neural. Esta foi responsável por segmentar as carcaças e os diferentes tecidos na superfície das mesmas, utilizando, para isso, técnicas de reconhecimento de padrões.

Obtenção de imagens

A infraestrutura de captura de imagem foi instalada em frigorífico comercial. O sensor foi posicionado no final da linha de abate, permitindo coletar imagens de uma carcaça por vez com o Intel® RealSense™. Este dispositivo combina uma câmera RGB e um sensor de profundidade. O sensor de profundidade consiste em um projetor de infravermelho e um sensor de infravermelho e usa o princípio de medição "Luz estruturada" para coletar informações de profundidade. Um padrão de pontos de laser infravermelho é projetado na cena. Sua deformação é detectada pelo

sensor infravermelho e usada para calcular os valores de profundidade. O sensor possui um campo de visão de 85,2° na horizontal e 58° na vertical, resolução de 1280 x 720 pixels e pode gravar até 90 imagens de profundidade por segundo.

O *software* para operar as câmeras Intel® RealSense™ foi implementado em Python (baseado em OpenCV, 2015). As opções de imagens RGB, mapa de profundidade ou ambos, na sobreposição, foram exibidos no monitor para verificação da qualidade dos dados coletados. Os fluxos de dados foram nomeados automaticamente para evitar a substituição.

Rede neural proposta

Recursos de *Hardware* e ferramentas

A rede neural utilizada neste trabalho foi do tipo Mask R-CNN. Utilizou-se a linguagem de programação Python devido à disponibilidade de bibliotecas relacionadas com processamento de imagens e redes neurais. A biblioteca OpenCV foi utilizada para os processos relacionados com a aquisição e preparo das imagens e TensorFlow e Keras para implementação e registo das informações relacionadas com o treinamento, teste e validação da Rede Neural proposta. A máquina utilizada para o pré-processamento e para o treinamento da rede neural possui a seguinte configuração: Processador Intel (R) Core (TM) i7-7700 CPU @ 3.60GHz, unidade de processamento gráfico GeForce GTX 1070 8Gb e memória principal RAM DDR4 16Gb.

Conjunto e preparação das imagens

O desenvolvimento deste projeto teve acesso a um conjunto de 700 imagens RGB-D, obtidas pelo sensor Intel® RealSense™. Todas as imagens foram convertidas para o formato PNG. O conteúdo das imagens foi composto pela carcaça (objeto de interesse) e o fundo. Parte das imagens passaram por um processo de seleção da região de interesse manualmente, utilizando-se para isso, o *software* LabelMe (Russell et al., 2008). Assim, as imagens passaram a possuir um ficheiro de texto associado com as segmentações manuais correspondentes, de modo a obter as máscaras de referência necessárias para o treinamento da rede.

A ferramenta LabelMe gera um arquivo no formato JSON para cada imagem, contendo a marcação dos polígonos que representam as classes de interesse, carcaça e tecidos em sua superfície (tecido muscular exposto, tecido conectivo e tecido adiposo (tudo aquilo que não se enquadra como tecido muscular e conectivo)). Entretanto, a Mask R-CNN espera como entrada um único arquivo JSON com as informações de todas as imagens. Para resolver essa incompatibilidade, foi criado um módulo que recebe como entrada os JSON's de cada imagem, os formata para o padrão de entrada que a rede espera e então os concatena em um único JSON.

As imagens de referências possuem exatamente as mesmas dimensões das imagens de entrada. Devido a motivos de qualidade e presença de artefatos na imagem, algumas imagens foram excluídas do banco de dados. No final deste passo, obteve-se um conjunto de 565 imagens RGB-D e suas respectivas máscaras. Vale ressaltar que as imagens selecionadas foram aquelas com as classes de interesse bem definidas.

Divisão em conjuntos de treinamento, teste e validação

Para treinar a rede neural, o conjunto de imagens foi dividido em três grupos distintos: treinamento, teste e validação. Para obtenção dos conjuntos de treinamento e teste, o conjunto de dados foi dividido utilizando uma proporção 80%/20% (treinamento e teste, respectivamente), conforme descrito por Kenton (2018). O conjunto de validação foi obtido a partir de um banco de dados independente. Portanto, o conjunto de imagens foi dividido, aleatoriamente, em 115 (20% de 565) imagens de teste, 450 (80% de 565) imagens de treinamento, e 100 imagens para validação.

Implementação - Arquitetura da rede

Segundo He et al. (2018), a rede neural Mask R-CNN obteve resultado superior, quando comparada com os métodos considerados mais modernos em segmentação. Isso inclui MNC (Dai et al., 2016) e FCIS (Li et al., 2017). Neste sentido, a rede neural utilizada neste estudo foi a Mask R-CNN (He et al., 2017). Esta consiste, principalmente, de duas partes: backbone para extração de recursos e detecção de objetos (localização e classificação) e previsão de máscara. A rede de proposta de região (RPN, Ren et al., 2017) é usada para gerar a caixa delimitadora

(bounding box) do candidato para segmentação da instância adicional. Além disso, para obter a máscara predita do objeto, a camada ROI Align é usada para mapear o mapa de feições da região de interesse (ROI) para um tamanho fixo (He et al., 2017).

Antes do treinamento do modelo, a aprendizagem de transferência foi introduzida, visto que começar um Deep Network exige milhões de hiperparâmetros treináveis, o que significa que o número de imagens rotuladas deve ser grande. Frente a isso, a Mask R-CNN foi implementada para reconhecer 80 classes distintas, a fim de limitar o número de imagens necessárias para treinar toda a rede. Em Machine Learning, transferência de aprendizagem refere-se à aplicação do conhecimento adquirido na resolução de um problema para resolver um problema diferente, mas relacionado. Isso significa que, em vez de treinar os parâmetros de rede do zero, utiliza-se os pesos da rede treinada com as 80 classes em um novo conjunto de dados como ponto de partida para o ajuste fino dos pesos para o problema de identificar tecidos nas carcaças. Isso reduz o número de imagens necessárias para treinar a rede e diminui o tempo necessário para treinar os modelos, uma vez que quantidades limitadas de dados de treinamento rotulados à mão são necessárias. Para obter maior precisão de reconhecimento, a rede mais profunda ResNeXt-101 (He et al., 2016), combinada com Feature Pyramid Network (FPN, Lin et al., 2017), foi usada como o backbone para extração de recursos. Como a carcaça é o objeto de interesse na cena, todos os objetos, exceto as carcaças, são classificados como plano de fundo. A resolução da imagem de entrada foi de 1280×720 pixels.

Especificamente, a rede Mask R-CNN, aplicada nesta pesquisa, é composta por quatro módulos funcionais: (i) a imagem é fornecida para a rede, (ii) a arquitetura de backbone convolucional é usada para extração de recursos na imagem inteira, (iii) as regiões que contêm as classes são delimitadas (bounding box) e a rede gera as máscaras das classes identificadas; e (iv) a rede retorna a imagem original com o acréscimo das marcações das classes identificadas e suas respectivas bounding boxes.

A configuração da Mask R-CNN foi 1 GPU, resolução máxima 1280×780 pixels, taxa de aprendizado de 0,002, 500 passos por época, total de 200 épocas e mínimo de acurácia igual a 0,7.

Critério de avaliação

Para validar o modelo, utilizou-se a validação através da métrica mAP (mean Average Precision). Este é um método eficiente e popular para estimação da taxa de erro em reconhecimento de padrões. Para cada instância de uma classe identificada em uma imagem, a bounding box predita é sobreposta à bounding box real. Dessa sobreposição, é calculado o coeficiente IoU (Intersection over Union), o qual é obtido por meio da divisão da área da interseção pela área da união das bounding boxes. O coeficiente IoU é um valor que varia entre 0 e 1, quanto mais próximo de 1, maior a semelhança entre os bounding boxes. Através do IoU de cada instância, é calculado o AP (Average Precision) da imagem. Posteriormente, definiu-se os limiares 0,25, 0,50 e 0,75 e os comparou com o IoU. Limiar maior que o IoU significa um verdadeiro positivo, caso contrário, existe um falso positivo. O AP da imagem é a quantidade de verdadeiros positivos dividido pela quantidade de instâncias encontradas na imagem (verdadeiros positivos + falsos positivos). Já o mAP consiste na média aritmética do AP de todas as imagens do conjunto de validação.

A capacidade preditiva da rede foi avaliada em termos de coeficiente de determinação (R^2) e o quadrado médio do erro de predição (MSPE), que foi decomposto em enviesamento médio (MB), viés sistemático (SB) e erros aleatórios (RE) (López-Campos, et al., 2018). Essas três frações foram calculadas e expressas como porcentagens, como sugerido por Benchaar et al. (1998), para descrever o erro residual nos modelos. MB indica como a média dos valores preditos pela rede se desvia das médias das observações reais. SB mede o desvio do coeficiente de regressão de quadrados mínimos de um. Esse é o valor que seria obtido se as predições e o observado real estiverem em total acordo. O RE é a variação nas medidas preditas que não é explicada (Theil, 1966).

RESULTADOS E DISCUSSÃO

Este artigo apresentou uma nova abordagem estatística e de reconhecimento de padrões baseada no aprendizado de máquina para automatizar o processo de identificação da carcaça e tecidos em sua superfície, em ambientes frigoríficos. A principal novidade do estudo é a aplicação do algoritmo Mask R-CNN e a demonstração de sua eficácia para a tarefa de avaliar carcaças bovinas. A essência da avaliação das carcaças neste artigo é a segmentação das carcaças

individualmente, que representa o contorno da carcaça, e a classificação dos diferentes tecidos, ou seja, identificar o tecido muscular exposto, tecido conectivo e tecido adiposo (gordura). Os resultados (Tabela 1) demonstram que a rede neural desenvolvida obteve uma precisão de 98,2%, representando a robustez do método de segmentação para a classe carcaça individualmente, resultado superior ao encontrado por Gonçalves et al. (2020), em estudo realizado para investigar dois métodos de segmentação de imagens (Superpixel + CNN e SegNet), que obtiveram uma precisão de 96% para a segmentação da carcaça bovina.

Tabela 1 - Mean Average Precision (mAP) obtido na segmentação dos tecidos de interesse (muscular, conectivo e adiposo) e da carcaça, individualmente.

	Tecidos de interesse (%)	Carcaça (%)
AP25	66,4	98,2
AP50	42,7	98,2
AP75	11,3	98,2

AP: Average Precision.

A rede neural artificial teve um desempenho satisfatório na estimativa dos tecidos muscular, conectivo e adiposo. A rede foi capaz de detectar com uma acurácia de 11,37% com 200 épocas e sobreposição (IoU) máxima de 75% de intersecção correta entre as bounding boxes. A variação de IoU interfere na acurácia do método, visto que a carcaça pode estar parcialmente oculta pela proximidade com outras carcaças. Visando aumentar a acurácia, diminuiu-se o IoU para 50% e, pôr fim, a 25%, sendo obtida a acurácia de 66,4%. É possível observar que, quanto menor a IoU do objeto a ser encontrado, maior tende a ser a eficácia da identificação. O IoU é fator determinante para acurácia, já que é possível encontrar carcaças abaixo de 100% de sobreposição, levando a um resultado eficaz com carcaças avaliadas sob outros ângulos. Em princípio, estes valores podem parecer baixos, no entanto, o modelo desenvolvido obteve um valor de mAP (50%) de 42,7 %, pouco abaixo dos 60% obtidos a partir do melhor modelo desenvolvido por He et al. (2018) para segmentação multiclasse, superando os modelos MNC (Dai et al., 2016) e FCIS (Li et al., 2017), vencedores do COCO (Common Objects in Context) 2015 e 2016. Esses resultados indicaram que a rede neural desenvolvida com base no uso de recursos de imagem digital teve a precisão aceitável para estimativa dos diferentes tecidos na superfície da carcaça.

Comparação Inter-Observador

Como referido anteriormente, o conjunto de imagens possui segmentações manuais disponíveis. De forma a validar os resultados obtidos pelo método desenvolvido, estes foram comparados com os resultados obtidos manualmente. Os resultados a serem considerados são provenientes de um banco de dados independente, e, portanto, não possuem nenhuma relação com o treinamento e expressam melhor o quão genérica a rede treinada está. No geral, a rede neural foi capaz de prever com alta precisão os tecidos da superfície das carcaças. Estes resultados ficam mais evidentes ao analisar a Tabela 2, na qual são apresentados os valores observados em relação aos valores preditos de cada tecido analisado (Figura 1).

Tabela 2 - Comparação entre as previsões realizadas pela rede neural Mask R-CNN e as mensurações realizadas manualmente.

Variável	R ²	Rest r ²	MSE	Mayer's Test	CCC			MSEP decomposition				
					Cb	P [^] c	r ²	RMSEP	MSEP	MB%	SB%	RE%
CON (%)	0,95	0,94	0,29	0,00001	0,99	0,97	0,97	0,58	0,33	3,30	10,3	86,4
MUS (%)	0,82	0,95	1,22	0,00001	0,99	0,90	0,90	1,14	1,31	0,02	8,45	91,5
GOR (%)	0,82	0,91	1,44	0,00001	0,99	0,90	0,90	1,28	1,65	0,29	14,1	85,5

CON=Tecido conectivo (%); MUS= Tecido muscular exposto (%); GOR: Gordura de cobertura (%); Rest. r² = r² resistente; Mayer's test = H0: a = 0 e b = 1; CCC = coeficiente de correlação de concordância, varia de 0 a 1; Cb = correção de viés, varia de 0 a 1; 1 indica nenhum desvio de Y = X, RMSEP = raiz do erro quadrático médio; MSEP = erro quadrático médio de predição; MB = enviesamento médio (% de MSEP); SB = viés sistemático (% de MSEP); RE = erros aleatórios (% de MSEP).

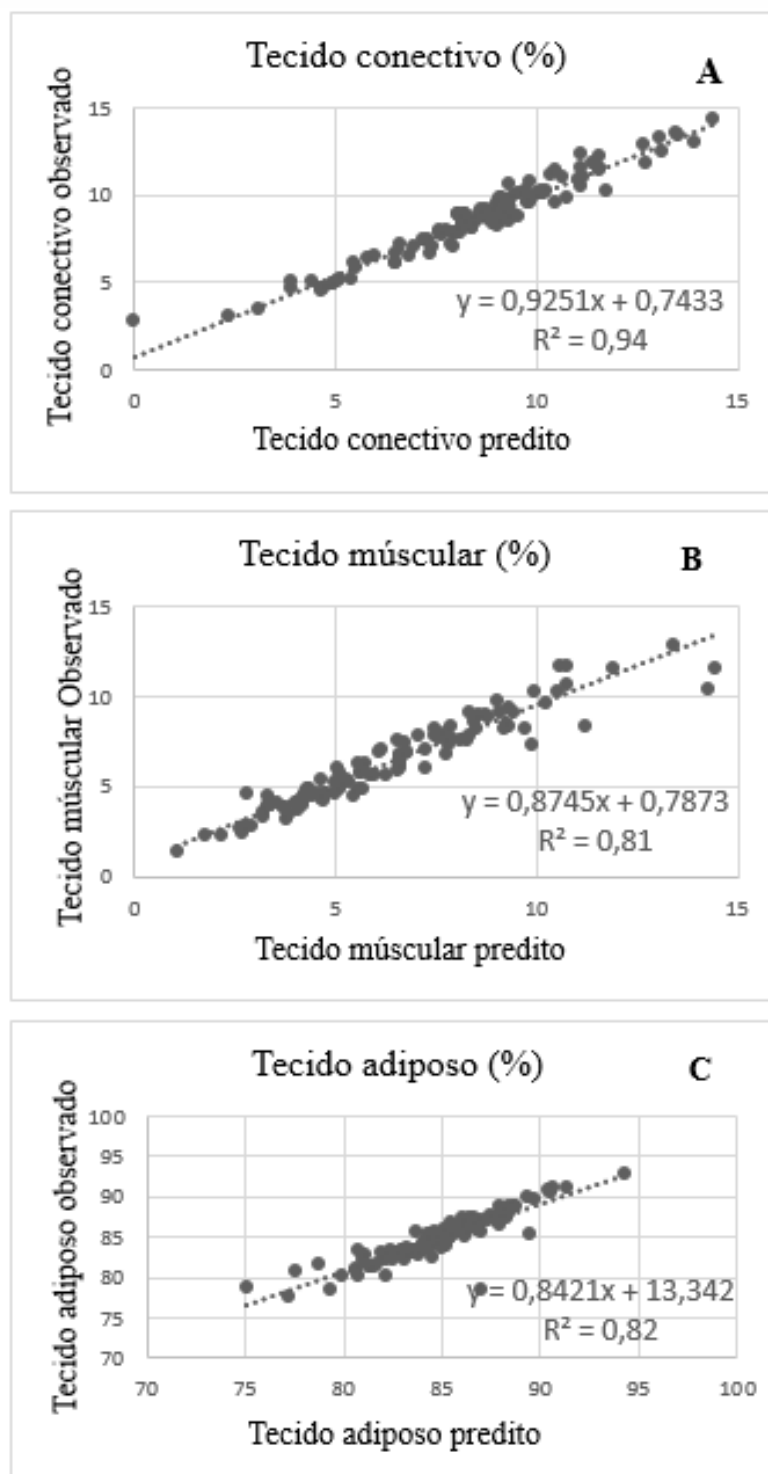


Figura 1 - Relação entre os valores preditos pela rede neural e os observados das áreas cobertas pelo tecido conectivo (A), tecido muscular (B) e tecido adiposo (C) em porcentagem da área total.

Os valores das áreas dos tecidos (conectivo, adiposo e muscular) são expressos em porcentagem da área total da carcaça. Essas áreas tiveram os valores de correlação e coeficiente de concordância (CCC) próximos de um. A rede

desenvolvida previu com boa acurácia e precisão o tecido conectivo (CCC = 0,97), tecido muscular exposto (CCC = 0,90) e a cobertura de gordura subcutânea (tecido adiposo; CCC = 0,90). O MSPE apresentou valores relativamente baixos e foi definido por RE em uma porcentagem superior a 85 % para estimativas de tecido adiposo e conectivo, e superior a 90 % para estimativas de tecido muscular exposto (Tabela 2). De fato, o RE explicou a maior parte dos valores de MSPE, implicando que as diferenças entre os valores preditos e observados (segmentação manual) são associadas a fatores externos, como a qualidade da imagem e o processo de calibração da câmera, posicionamento das carcaças, iluminação ambiente e a tomada de decisão por parte dos observadores quando da identificação das áreas.

Neste sentido, verifica-se que, na maioria das vezes, a rede tende a gerar máscaras semelhantes às máscaras originais, conforme pode se observar na Figura 2. No entanto, existem imagens em que o tecido conectivo apresenta tons similares aos tons da gordura, o que dificultou, em parte a segmentação dessas áreas. Nesse caso, a imagem predita apresentou área maior, quando comparada com a imagem original, como pode-se observar na Figura 3. Todavia, nas imagens em que existem tecidos aparentes não selecionados (músculo e conectivo), como na Figura 4, a rede foi capaz gerar uma máscara com estas segmentações, o que não está indicado na máscara original. Logo, pode-se concluir que as máscaras obtidas para um conjunto de imagens têm o mesmo grau de precisão que as máscaras obtidas manualmente por técnicos experientes.

Os resultados obtidos permitem concluir que a solução proposta é capaz de lidar com o ruído, artefatos e variações de contraste característicos das imagens RGB-D, evidenciando que o modelo foi capaz de generalizar adequadamente os dados. Desta maneira, prova-se a capacidade e o potencial deste modelo para ser usado em condições práticas.




Figura 2 - Máscara gerada pela rede semelhante à máscara original. A imagem predita está à esquerda. No centro, está a imagem de referência e, à direita, está a imagem original com os contornos das feições.




Figura 3 - Máscara gerada pela rede apresentando maior área de colágeno em comparação com a máscara original. A imagem predita está à esquerda. No centro, está a imagem de referência e, à direita, está a imagem original com os contornos das feições.




Figura 4 - Máscara gerada pela rede apresentando tecidos não selecionados (músculo e conectivo) na máscara original. A imagem predita está à esquerda. No centro, está a imagem de referência e, à direita, está a imagem original com os contornos das feições.

Estudos anteriores demonstraram a demanda por sistemas automáticos de avaliação de carcaça em tempo real. Mas as pesquisas existentes utilizam de outras técnicas e recursos computacionais (Bittencourt, 2009; De La Iglesia et al., 2020; Gonçalves et al., 2020; Nucci et al., 2020). Uma grande vantagem da abordagem Mask R-CNN é a capacidade de realizar detecção e classificação, bem como segmentação de objetos presentes nas imagens (He et al., 2017), o que permite o desenvolvimento de algoritmos adicionais para realizar tarefas, como a tipificação das carcaças em tempo real em ambientes frigoríficos.

Neste estudo, a rede de aprendizagem profunda Mask R-CNN foi adotada, a qual foi modificada e ajustada com os dados de treinamento para detectar e classificar tecidos na superfície das carcaças. Devido ao número de imagens e à qualidade dessas, o sistema apresentou as capacidades potenciais de monitoramento rápido das carcaças, proporcionando os benefícios de baixo custo, eficiência de tempo e operação conveniente. A abordagem de classificação multiclasse atingiu uma boa precisão, sem a necessidade de quaisquer etapas de pré-processamento. Isso ocorre, principalmente, porque o conjunto de dados foi coletado em um ambiente relativamente complexo, com muita interferência, e com carcaças que apresentavam diferentes características, o que permitiu obter um modelo com boa capacidade de generalização, quando se trata de segmentar tecidos na superfície de carcaças. Neste sentido, é provável que outros possam alcançar resultados similares aos nossos, devido, principalmente, à heterogeneidade do banco de dados utilizado e, especialmente, porque os tecidos na superfície das carcaças se diferenciam e se destacam em virtude da coloração e potencial de ocorrência em áreas pré-determinadas.

CONCLUSÕES

A segmentação de imagens é uma das etapas mais importantes e complexas, pois favorece o desempenho das etapas subsequentes. A contribuição deste trabalho é a proposição de um método de segmentação de diferentes tecidos na superfície da carcaça, que pode auxiliar no desenvolvimento de sistemas automatizados de avaliação de carcaças em frigoríficos. Os resultados obtidos demonstram que o modelo apresentou resultados satisfatórios e generalizaram o

problema ao ponto de extrair a segmentação das carcaças e dos diferentes tecidos, demonstrando que o modelo desenvolvido foi eficaz e robusto.

AGRADECIMENTOS

Este projeto recebeu apoio nº APQ-02577-14 da FAPEMIG, INCT-CA e nº 477399 / 2012-6 do CNPq, SEBRAE MG 004253/2017, Brasil. Gostaríamos de agradecer, ainda, ao Minerva Foods e a Intergado por sua cooperação durante este projeto.

REFERÊNCIAS

- Beak, S. H., Park, S. J., Fassah, D. M., Kim, H. J., Kim, M., Jo, C., Baik, M. (2021). Relationships among carcass traits, auction price, and image analysis traits of marbling characteristics in Korean cattle beef. *Meat Science*, 171, 108268.
- Bittencourt, C. D. R. (2009). Classificação automática do acabamento de gordura em imagens digitais de carcaças bovinas. Dissertação (Mestrado em Informática), Universidade de Brasília. Disponível em: https://repositorio.unb.br/bitstream/10482/4958/1/Dissertacao_Carmen_Bittencourt.pdf. Acesso em: 19 maio 2020.
- Brasil, Ministério da Agricultura, Pecuária e Abastecimento. Divisão de Normas Técnicas. Instrução Normativa n. 3, de 17 de janeiro de 2000. Aprova o Regulamento Técnico de Métodos de Insensibilização para o Abate Humanitário de Animais de Açougue. *Diário Oficial da União*, Brasília, 24 jan. 2000. Seção I, p. 14-16, 2000.
- Cannell, R. C., Belk, K. E., Tatum, J. D., Wise, J. W., Chapman, P. L., Scanga, J. A., Smith, G. C. (2002). Online evaluation of a commercial video image analysis system (Computer Vision System) to predict beef carcass red meat yield and for augmenting the assignment of USDA yield grades. United States Department of Agriculture. *Journal of Animal Science*, 80(5), 1195-1201.
- Craigie, C. R., Navajas, E. A., Purchas, R. W., Maltin, C. A., Bünger, L., Hoskin, S. O., Ross, D. W., Morris, S.T., Roehe, R. (2012). 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 subjective systems. *Meat science*, 92(4), 307-318. Doi: 10.1016/j.meatsci.2012.05.028

Dai, J., He, K., Sun, J. (2016). Instance-aware semantic segmentation via multi-task network cascades. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3150-3158).

Daniel, H., González, G. V., García, M. V., Rivero, A. J. L., De Paz, J. F. (2020). Non-invasive automatic beef carcass classification based on sensor network and image analysis. *Future Generation Computer Systems*, 113, 318-328. ISSN 0167-739X, <https://doi.org/10.1016/j.future.2020.06.055>.

Geraldo, A. T., Quirino, C. R., da Costa Henry, F., da Costa, R. L. D., Beltram, R. T. (2017). Técnicas de vídeo imagem para avaliação de carcaça: Revisão. *PUBVET*, 12, 150.

Gonçalves, D. N., de Moares Weber, V. A., Pistori, J. G. B., da Costa Gomes, R., de Araujo, A. V., Pereira, M. F., Gonçalves, W. N., Pistori, H. (2020). Carcass image segmentation using CNN-based methods. *Information Processing in Agriculture*. ISSN 2214-3173. <https://doi.org/10.1016/j.inpa.2020.11.004>

Goodfellow, I., Bengio, Y., Courville, A. (2016). *Deep Learning*. MIT Press. Disponível em: <http://www.deeplearningbook.org>. Acesso em 16 de fevereiro de 2021.

He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).

He, K., Gkioxari, G., Dollár, P., Girshick, R. (2018). Mask R-CNN. *IEEE International Conference on Computer Vision (ICCV)*. pp. 2980–2988. Disponível em: <https://doi.org/10.1109/ICCV.2017.322>

Kenton, W. (2018). Pareto Principle. Disponível em: <https://www.investopedia.com/terms/p/paretoprinciple.asp>. Acesso em: 02 de setembro de 2020.

- Lee, C. Y., Gallagher, P. W., Tu, Z. (2016). Generalizing pooling functions in convolutional neural networks: Mixed, gated, and tree. In *Artificial intelligence and statistics* (pp. 464-472). PMLR.
- Li, Y., Qi, H., Dai, J., Ji, X., Wei, Y. (2017). Fully convolutional instance-aware semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2359-2367).
- Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., Belongie, S. (2017). Feature pyramid networks for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2117-2125).
- López-Campos, Ó., Roberts, J. C., Larsen, I. L., Prieto, N., Juárez, M., Dugan, M. E., Aalhus, J. L. (2018). Rapid and non-destructive determination of lean fat and bone content in beef using dual energy X-ray absorptiometry. *Meat science*, 146, 140-146. Doi: 10.1016/j.meatsci.2018.07.009.
- Miller, G. A., Hyslop, J. J., Barclay, D., Edwards, A., Thomson, W., Duthie, C. A. (2019). Using 3D imaging and machine learning to predict liveweight and carcass characteristics of live finishing beef cattle. *Frontiers in Sustainable Food Systems*, 3, 30.
- Nucci, H. H. P., Ishii, R. P., da Costa Gomes, R., Costa, C. S., Feijó, G. L. D. (2020). Classification of Carcass Fatness Degree in Finishing Cattle Using Machine Learning. In *International Conference on Computational Science and Its Applications* (pp. 519-535). Springer, Cham. https://doi.org/10.1007/978-3-030-58799-4_38
- OpenCV Team. OpenCV. URL: <https://opencv.org/>.
- Python Software Foundation. Python. URL: <https://www.python.org/>.
- Ren, S., He, K., Girshick, R. (2017). Faster R-CNN: towards real-time object detection with region proposal networks *IEEE Trans Pattern Anal Mach Intell*, 39 (6), 1137-1149

- Russell, B. C., Torralba, A., Murphy, K. P., Freeman, W. T. (2008). LabelMe: a database and web-based tool for image annotation. *International journal of computer vision*, 77(1-3), 157-173.
- Teira, G. A., Tinois, E., Lotufo, R. D. A., Felício, P. E. D. (2003). Digital-image analysis to predict weight and yields of boneless subprimal beef cuts. *Scientia Agricola*, 60, 403-408.
- TensorFlow Team. TensorBoard: Visualizing Learning | TensorFlow. URL: https://www.tensorflow.org/guide/summaries_and_tensorboard.
- Theil, H. *Applied economic forecasting*. Amsterdam: North-Holland Publishing Company. 1966.
- Tian, H., Wang, T., Liu, Y., Qiao, X., Li, Y. (2019). Computer vision technology in agricultural automation—A review. *Information Processing in Agriculture*, 7(1), 1-19.
- Weber, V. A. M., de Lima Weber, F., da Silva Oliveira, A., Astolfi, G., Menezes, G. V., de Andrade Porto, J. V., ... & Pistori, H. (2020). Cattle weight estimation using active contour models and regression trees bagging. *Computers and Electronics in Agriculture*, 179, 105804.

CAPÍTULO 5

DESENVOLVIMENTO DE EQUAÇÕES PARA ESTIMAR O GRAU DE ACABAMENTO DE GORDURA E COMPOSIÇÃO DE CARÇA EM BOVINOS

**Gutierrez J. F. Assis*¹, Breno de C. Silva*, Sebastião de Campos Valadares
Filho*, Mario L. Chizzotti*¹.**

* Departamento de Zootecnia, Universidade Federal de Viçosa, Viçosa, Minas Gerais, Brasil, 36.570-900.

¹Autores correspondentes. E-mail: gutierrez.assis@ufv.br; mariochizzotti@ufv.br.

RESUMO

Ferramentas que auxiliem na modelagem do crescimento dos tecidos, na avaliação da condição corporal e, também, no desenvolvimento de sistemas de pagamento baseados em mérito da carcaça, se fazem necessárias, visto que podem possibilitar a homogeneização das carcaças bovinas *in vivo*. Assim, esta meta-análise foi realizado com o objetivo de estimar e validar equação para prever a espessura de gordura subcutânea (EGS) da carcaça em bovinos *in vivo*. Foi utilizado um banco de dados composto por 820 animais, englobando machos não castrados, machos castrados e novilhas de diferentes grupos genéticos (Nelore, cruzado de corte e cruzado de leite) e dois tipos de abate (comercial e experimental). Para gerar a equação foi testado um modelo misto incluindo os efeitos fixos de grupo genético, gênero e condição de abate, e efeitos aleatórios do estudo. A estrutura dos componentes de variância foi utilizada para determinar o modelo com melhor ajuste, com base nos critérios de informação de Akaike (AIC). Os dados coletados foram analisados pelo procedimento MIXED contidos no SAS 9.0 (Statistical Analysis System Institute, Inc.). O nível de 0,05 foi estabelecido como o nível crítico de probabilidade para o erro do tipo I. As análises de validação foram realizadas por meio do Model Evaluation System (MES; College Station, EUA), utilizando um banco de dados independente compostas por 134 observações. A EGS pode ser estimada pela seguinte equação: $EGS \text{ (mm)} = - 2,37 + 0,709 \times GMD \text{ (kg)} + (PCar \text{ (kg)} \times Y)$, onde GMD = ganho médio diário, PCar (kg) = peso de carcaça e Y = representa o ajuste para a classe sexual e grupo genético, conforme descrito a seguir: Nelore = 0,02380; Cruzado de Corte = 0,02705 e Cruzados de Leite = 0,01770 (para machos não castrados); Nelore = 0,03043; Cruzado de Corte = 0,03368 e Cruzados de Leite = 0,02433 (para machos castrados) e Nelore = 0,03545; Cruzado de Corte = 0,03871 e Cruzados de Leite = 0,02935 (para fêmeas). A equação proposta apresentou coeficientes de correlação que variaram entre 0,25 e 0,78 para os bovinos que compuseram o conjunto de dados de validação. A partir da validação da equação, recomenda-se o uso dessa para animais Nelore e cruzados de corte e leite, de diferentes classes sexuais, como uma ferramenta para estimar a qualidade da carcaça bovina em relação à cobertura de gordura.

Palavras-chave: classe sexual, grupo genético, meta-análise, precisão

INTRODUÇÃO

Em sistemas de produção de carne, o conhecimento dos fatores que determinam o crescimento e o desenvolvimento dos tecidos são de grande importância para a adequação do manejo nutricional e definição do melhor ponto de abate, objetivando o máximo de rendimento à desossa e qualidade da carne produzida. Estes processos estão intimamente relacionados com a quantidade de ossos, músculos e gordura na carcaça (Sakamoto, 2012), e são influenciados por fatores como a idade, grupo genético, classe sexual, alimentação, maturidade e condição corporal (Osório et al., 1995; Osório et al., 2012). O entendimento de como ocorre a deposição dos tecidos permite a manipulação do crescimento e a obtenção de melhores índices produtivos e, conseqüentemente, a produção de carcaças de qualidade.

Diante do exposto acima, ferramentas que auxiliem na modelagem do crescimento dos tecidos, na avaliação da condição corporal e, também, no desenvolvimento de sistemas de pagamento baseados em mérito da carcaça, se fazem necessárias, visto que possibilitam a homogeneização das carcaças bovinas *in vivo*, reduz perdas econômicas e atende as demandas mercadológicas específicas em pesos de cortes cárneos (Cardoso et al., 2013). Nesse sentido, associações de produtores e frigoríficos têm proposto a criação de programas que estimulam a produção de carne com qualidade superior. Tais programas são focados em avaliar, classificar e tipificar as carcaças, a fim de hierarquizá-las.

Entre as características de carcaça, o rendimento dos cortes comerciais, o peso e o grau de acabamento são as principais variáveis de interesse comercial para os frigoríficos (Costa et al., 2002; Arboitte et al., 2004). A classe sexual e a maturidade também são avaliadas, uma vez que influenciam a qualidade final da carne (Restle et al., 1999). O peso de carcaça normalmente exigido pelos frigoríficos é acima 180 kg (12 arrobas) para fêmeas e 225 kg (15 arrobas) para machos inteiros e castrados. Neste sentido, o produtor necessita de um parâmetro entre o peso vivo, na propriedade, e quanto deste peso é representado pela carcaça. Para chegar à decisão correta, o produtor precisa entender e considerar os fatores que influenciam o peso de carcaça. Entre eles, pode-se citar sexo, peso de abate, tipo de alimentação, grau de acabamento (quantidade de gordura), raça e limpeza (toalete). A quantificação adequada da carcaça permite aumentar o retorno

econômico dos produtores, uma vez que estes geralmente são pagos de acordo com o peso da carcaça. Além disso, o peso de carcaça é um pré-requisito para calcular o rendimento de carcaça, o que é importante para definir a rentabilidade do gado terminado em pasto ou em confinamento.

Quanto ao grau de acabamento, os frigoríficos exigem carcaças com espessura de gordura subcutânea mínima de 2,5 a 3 mm (Bridi, 2019). Abaixo deste limite, ocorre escurecimento da parte externa dos músculos expostos ao resfriamento, conferindo aspecto visual indesejável, o que prejudica a comercialização (Magnabosco et al., 2006; Moreira et al., 2017), aumenta a perda de peso da carcaça devido à perda de líquidos durante a refrigeração (Restle et al., 1999; Costa et al., 2002) e produz carne menos macia (Kazama et al., 2008; Bridi, 2019). O excesso de gordura subcutânea também não é indicado, pois tem correlação negativa com o rendimento da porção comestível da carcaça e pode promover prejuízos ao produtor e ao frigorífico, uma vez que o excesso de gordura subcutânea recebe toailete mais intenso antes da pesagem da carcaça e, conseqüentemente, diminui o peso da carcaça e aumenta o custo operacional envolvido no processo (Costa et al., 2002). Neste sentido, o produtor receberá incentivos financeiros apenas para carcaças que apresentem condições ideais de acabamento, sendo este estabelecido pelo frigorífico e mercado consumidor.

Outro ponto é que animais com pesos elevados e alta proporção de gordura na carcaça são considerados inadequados, pois reduzem consideravelmente sua eficiência de produção, devido à menor eficiência biológica em acumular gordura. Neste contexto, o fator-chave é a alimentação contínua e de qualidade para o rebanho. Assim, é um risco para o produtor manter, dentro do rebanho, animais já terminados, uma vez que o custo de produzir este animal é alto e pode diminuir a rentabilidade de todo o sistema produtivo.

Por esta razão, tecnologias que proporcionem maior probabilidade de sucesso econômico são essenciais. Com isso, o produtor terá acesso a dados que auxiliarão na tomada mais eficiente da decisão, permitindo produzir animais com melhor conformidade com os critérios de carcaça, com menor custo de produção e maior obtenção de subsídios (Pereira et al., 2016). Assim, foram geradas equações para prever o acabamento de gordura subcutânea da carcaça em bovinos *in vivo*, em função do peso de carcaça e ganho médio diário de animais criados em

condições tropicais. Este modelo dará suporte aos pecuaristas na tomada de decisão, visando aumentar a qualidade da carne produzida e a rentabilidade do sistema, por ajudar a definir a melhor hora do abate animal em virtude do acabamento.

DESCRIÇÃO DO BANCO DE DADOS

O banco de dados foi composto por 820 animais obtidos de 29 estudos realizados em condições brasileiras (Tabela 1). O banco de dados continha informações individuais de peso corporal em jejum (PCj), peso de carcaça quente (PCQ), espessura de gordura subcutânea (EGS) e ganho médio diário (GMD) obtidos em frigorífico comercial (249 animais) e no frigorífico Escola da Universidade Federal de Viçosa-MG (571 animais). Antes do abate, os animais foram submetidos a jejum de sólidos por 16 horas. O abate foi realizado via atordoamento e secção da veia jugular, para sangramento total. Os dados foram coletados e codificados por gênero (não castrados, castrados e novilhas) e grupo genético (Nelore, cruzado de corte, cruzado de leite). O grupo genético com maior representatividade no banco de dados foi o Nelore, com 594 animais (483 não castrados, 66 castrados e 45 novilhas). O grupo de animais Cruzados de Leite foi constituído de 137 animais (94 não castrados, 16 castrados e 27 novilhas). Já o grupo de animais Cruzados de Corte foi formado por 89 animais (58 não castrados, 9 castrados e 22 novilhas).

Análise estatística

Para gerar a equação para estimar a EGS, foi testado um modelo misto incluindo os efeitos fixos de grupo genético, gênero e condição de abate (comercial ou experimental), e efeitos aleatórios do estudo. A estrutura dos componentes de variância foi utilizada para determinar o modelo com melhor ajuste, com base nos critérios de informação de Akaike (AIC). Os dados coletados foram analisados pelo procedimento MIXED contidos no pacote estatístico SAS 9.0 (Statistical Analysis System Institute, Inc.). O nível de 0,05 foi estabelecido como o nível crítico de probabilidade para o erro do tipo I.

Tabela 1 - Estatística descritiva dos dados utilizados para gerar a equação.

Item	PCj (kg)	Pcarcq (kg)	EGS (mm)	GMD (kg)
Macho cruzado de corte não castrado (n = 58)				
Média	471,5	269,7	5,67	1,363
Mínimo	228,0	122,7	0	0,200
Máximo	641,0	364,6	13,00	2,300
Desvio padrão	85,60	52,56	2,859	0,463
Fêmea cruzado de corte (n = 22)				
Média	357,5	191,0	5,318	1,400
Mínimo	169,0	100,3	0,700	0,200
Máximo	466,0	254,1	8,500	2,100
Desvio padrão	87,46	41,88	2,632	0,437
Macho cruzado de corte castrado (n = 9)				
Média	391,4	223,7	5,088	1,228
Mínimo	265,0	155,2	1,00	0,700
Máximo	487,0	260,5	8,400	1,700
Desvio padrão	74,16	40,83	2,552	0,303
Macho cruzado de leite não castrado (n = 94)				
Média	400,3	223,2	2,161	1,230
Mínimo	166,0	96,10	0	0
Máximo	594,0	324,5	7,500	2,100
Desvio padrão	98,95	55,06	1,468	0,492
Fêmea cruzado de leite (n = 27)				
Média	315,2	165,7	2,729	0,907
Mínimo	232,0	117,0	0,800	0,400
Máximo	411,0	226,3	5,700	1,400
Desvio padrão	57,34	31,66	1,498	0,277
Macho cruzado de leite castrado (n = 16)				
Média	431,1	236,1	3,531	0,757
Mínimo	325,0	173,5	1,300	0,100
Máximo	524,0	303,2	7,000	1,300
Desvio padrão	62,89	36,72	1,500	0,354
Macho Nelore não castrado (n = 483)				
Média	440,3	257,4	4,350	1,111
Mínimo	165,0	90,50	0	0
Máximo	660,0	391,4	12,00	2,200
Desvio padrão	89,57	52,90	2,108	0,358
Fêmea Nelore (n = 45)				
Média	246,4	140,2	2,977	0,511
Mínimo	125,0	68,70	0,500	0
Máximo	437,0	257,1	9,200	1,400
Desvio padrão	70,71	45,36	2,207	0,347
Macho Nelore castrado (n = 66)				
Média	402,2	228,0	4,971	0,845
Mínimo	122,0	67,20	0,400	0,100
Máximo	582,0	322,4	11,70	1,400
Desvio padrão	121,4	67,61	2,829	0,315

PCj: peso corporal em jejum (kg), Pcarcq: peso de carcaça quente (kg), EGS: espessura de gordura subcutânea (mm) e GMD: ganho médio diário (kg).

EQUAÇÕES PARA PREDIÇÃO DO ACABAMENTO DE CARÇAÇA POR ESPESSURA DE GORDURA SUBCUTÂNEA (EGS)

A curva de crescimento animal apresenta forma sigmóide. Durante a primeira etapa, o crescimento é lento, seguido por um período de aceleração, atingindo o máximo crescimento próximo à puberdade e, em seguida, ocorre uma fase de desaceleração (Berg & Butterfield, 1976). Após a fase de desaceleração, o animal atinge a maturidade fisiológica e a curva tende a atingir o platô. A partir desse momento, o crescimento é lento e representado, principalmente, pela deposição do tecido adiposo (Almeida et. al., 2001). Assim, um aspecto importante para a qualidade da carcaça é a quantidade e distribuição do tecido adiposo. Dessa forma, pode-se definir a carcaça ideal como uma carcaça pesada e que apresente proporção adequada de gordura subcutânea, definida pelos parâmetros de qualidade do mercado consumidor. Em virtude disso, todos os sistemas avaliam o grau de acabamento das carcaças utilizando escores visuais (subjetivo) ou mensurações objetivas. A avaliação subjetiva é realizada visualmente na altura da 6^a, 9^a e 12^a costelas, na região lombar e no coxão (Bridi, 2002). Desta forma, as carcaças podem ser classificadas com escore ausente (< 1 mm), escassa (1 - 3 mm), mediana (3 - 6 mm), uniforme (6 - 10 mm) e excessiva (> 10 mm de espessura de gordura). Para avaliação objetiva, utiliza-se o paquímetro para mensurar a espessura de gordura subcutânea entre a 12^a e 13^a costelas (Luchiari Filho, 2000). Esta avaliação é mais precisa se comparada com a avaliação visual. No entanto, não é comumente praticada no Brasil, pois danifica um corte de alto valor comercial (contra-filé) e demanda maior tempo de permanência das carcaças nos frigoríficos, já que as carcaças devem estar resfriadas.

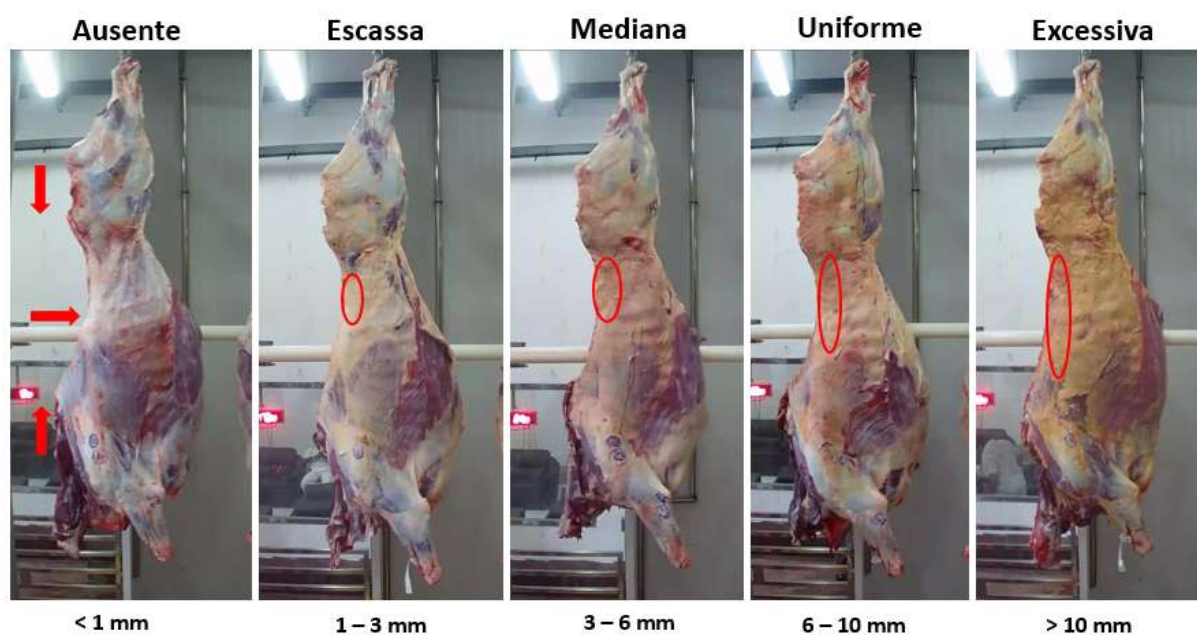


Figura 1 - Escore de acabamento de gordura

Métodos rápidos e confiáveis para avaliar a composição corporal são necessários em sistemas de produção de bovinos para minimizar a ausência ou excesso de gordura nas carcaças, aumentando a consistência dos produtos fornecidos, devido à homogeneização das carcaças bovinas *in vivo*. O nível alimentar influencia o ganho de peso, a composição corporal (Nour et al., 1981; Williams et al., 1983; Nour e Thonney, 1994), e a espessura de gordura subcutânea (EGS), que pode ser correlacionada com o ganho médio diário (GMD) e o peso de carcaça.

Os animais desse banco de dados foram da raça Nelore, puros ou cruzados com raças de corte ou com raças de origem leiteira. Com isso, avaliaram-se os efeitos de classe sexual (não castrados, castrados e fêmeas) e grupo genético (Nelore, cruzados de corte e cruzados de leite). Assim, a equação geral de predição da EGS foi desenvolvida (Eq.1).

$$\text{EGS (mm)} = - 2,37 + 0,709 \times \text{GMD (kg)} + (\text{Peso Carcaça (kg)} \times Y) \quad \text{Eq.1}$$

($R^2 = 0,49$; RMSE = 1,67; AIC = 2840), em que Y representa o ajuste para a classe sexual e grupo genético, conforme tabela 2.

Para todos os componentes avaliados verificou-se não existir efeito da classe sexual e grupo genético no tocante ao ganho médio diário. Por outro lado, houve

interação entre classe sexual e grupo genético para o coeficiente relacionado à carcaça e o desmembramento dessa interação pode ser visualizado na Tabela 2.

Tabela 2 - Desmembramento do efeito de classe sexual e grupo genético sobre o coeficiente relacionado ao peso de carcaça.

Classe sexual	Grupo genético	Intercepto	GMD (Kg)	Peso de carcaça (Kg)	Erro padrão	P-valor
Macho não castrado	Nelore			0,02380		
	Cruzado de Corte			0,02705		
	Cruzados de Leite			0,01770		
Macho castrado	Nelore			0,03043		
	Cruzado de Corte	-2,37	0,709	0,03368	0,0017	0,03
	Cruzados de Leite			0,02433		
Fêmea	Nelore			0,03545		
	Cruzado de Corte			0,03871		
	Cruzados de Leite			0,02935		

O modelo proposto ajusta as diferenças entre grupos genéticos, classes sexuais e efeito da taxa de crescimento e, portanto, do nível de consumo e da dieta sobre o rendimento de carcaça. Dentre as variáveis utilizadas para gerar a equação, a que explicou maior parte da variação foi o ganho médio diário (GMD).

O desenvolvimento de equações matemáticas para prever características de carcaça, antes do abate, pode auxiliar na tomada de decisão do ponto ideal de abate, melhorar os índices de produtividade e a qualidade das carcaças, permitindo prever a remuneração a ser obtida na comercialização com os frigoríficos.

Validação das equações

Para validar a equação que estima a espessura de gordura subcutânea (EGS), utilizou-se um banco de dados independente, com animais abatidos em frigorífico comercial e em condições experimentais. O conjunto de dados utilizado para validação não foi incluído no conjunto de dados usado para ajustar a equação testada. O conjunto de dados experimentais foi composto por 17 estudos,

totalizando 76 observações, abrangendo animais de diferentes genótipos (Nelore, Cruzado de corte e Cruzado de leite). O conjunto de dados comerciais foi composto por 58 animais de diferentes genótipos (Nelore, Cruzado de corte e Cruzado de leite). Não foi possível avaliar a equação para machos cruzado de corte castrado, machos cruzados de leite castrado, fêmeas cruzadas de leite e fêmeas cruzadas de corte, devido à ausência de dados (Tabela 3).

Tabela 3 – Estatística descritiva dos dados utilizados para validar as equações

Item	PCj (kg)	Pcarcq (kg)	EGS (mm)	GMD (kg)
Macho cruzado de corte não castrado (n = 14)				
Média	501,1	284,3	6,107	1,550
Mínimo	278,0	158,6	1,700	1,200
Máximo	658,0	366,6	11,90	1,900
Desvio padrão	111,1	61,01	3,305	0,326
Macho cruzado de leite não castrado (n = 10)				
Média	408,6	230,3	1,820	1,444
Mínimo	199,0	112,2	0,500	1,200
Máximo	526,0	302,4	5,00	1,800
Desvio padrão	106,1	62,64	1,314	0,194
Macho Nelore não castrado (n = 89)				
Média	447,1	260,0	4,484	1,061
Mínimo	205,0	105,2	0	0
Máximo	627,0	360,6	10,30	1,800
Desvio padrão	85,62	49,32	2,213	0,361
Fêmea Nelore (n = 7)				
Média	264,5	152,2	3,328	0,516
Mínimo	205,0	106,5	1,60	0,200
Máximo	306,0	174,6	4,600	0,900
Desvio padrão	33,93	24,75	1,178	0,248
Macho Nelore castrado (n = 14)				
Média	335,8	194,6	3,904	0,655
Mínimo	121,0	64,40	0,600	0,100
Máximo	528,0	306,3	9,400	1,300
Desvio padrão	128,9	76,51	2,790	0,360

PCj: peso corporal em jejum (kg), Pcarcq: peso de carcaça quente (kg), EGS: espessura de gordura subcutânea (mm) e GMD: ganho médio diário (kg)

A avaliação desses modelos fundamentou-se na análise da regressão linear entre os valores observados e preditos, sob as seguintes hipóteses: hipótese nula (H_0): $\beta_0 = 0$, hipótese alternativa (H_A): $\beta_0 \neq 0$; H_0 : $\beta_1 = 1$, H_A : $\beta_1 \neq 1$. O modelo é considerado um preditor adequado quando ambas as hipóteses forem aceitas. Os modelos foram avaliados pela estimativa do coeficiente de correlação de concordância (CCC), sendo que valores mais altos indicam um modelo mais preciso ou acurado, conforme descrito por Lin (1989). A eficiência dos modelos foi avaliada utilizando os valores estimados do quadrado médio do erro de predição (MSEP), raiz MSEP (RMSEP) e componentes do MSEP, como o viés quadrado (MB, média dos desvios), o erro sistemático (SB, representa o erro associado à inclinação da regressão) e o erro aleatório (RE, representa o erro não explicado pelo modelo). O

CCC, MSEP e RMSEP foram estimados utilizando o Model Evaluation System (MES; Tedeschi, 2006).

O modelo desenvolvido estimou a espessura de gordura subcutânea para machos Nelore não castrados (CCC = 0,49), machos cruzados de corte não castrado (CCC = 0,53), machos Nelores castrados (CCC = 0,88) e fêmeas Nelore (CCC = 0,61). Estes modelos apresentaram os maiores valores de CCC, C_b e P[^]c, indicando maior precisão e acurácia. O MSPE apresentou valores relativamente baixos e foi definido por RE em uma porcentagem superior a 75% para estimativas de EGS para macho Nelore não castrado, macho cruzado de corte não castrado, macho Nelore castrado e fêmea Nelore. De fato, o RE explicou a maior parte dos valores de MSPE, implicando que as diferenças entre os valores preditos e observados são associadas a fatores externos, como, por exemplo, retirada de parte da EGS devido a erros operacionais no momento da esfola. O modelo para macho Nelore castrado apresentou a maior proximidade entre EGS observada e predita. O modelo proposto para estimar a EGS em animais machos cruzados de leite não castrados possui limitações, visto que grande parte do erro de predição foi associada ao modelo (44,35 % do MSEP), indicando que 50,75 % do erro foram associados aleatoriamente. O modelo proposto foi desenvolvido com base em medidas obtidas em animais mestiços de diferentes proporções sanguíneas (gado de corte e gado de leite), sendo, portanto, a natureza empírica o principal motivo da inadequação do modelo, por ser dependente da população. Para melhor exemplificar o exposto acima, os dados preditos pela equação foram comparados com a EGS observada. (Figura 1).

Tabela 4 - Análise de regressão entre valores observados e preditos da espessura de gordura subcutânea de acordo com a classe sexual e grupo genético.

Classe sexual	Grupo genético	R ²	Rest. r ²	MSE	Mayer's Test	CCC			RMSEP	MSEP	MSEP decomposition		
						Cb	P ^c	r ²			MB. %	SB. %	RE. %
MI	Nelore	0,32	0,46	3,18	0,00001	0,86	0,49	0,49	1,764	3,111	0,277	0,003	99,72
	CCorte	0,55	0,61	4,52	0,00001	0,68	0,50	0,53	2,201	4,844	0,394	21,73	77,87
	CLeite	0,25	0,49	1,46	0,00001	0,70	0,35	0,36	1,496	2,240	44,35	4,892	50,75
MC	Nelore	0,78	0,92	1,78	0,00001	0,98	0,87	0,88	1,242	1,544	1,579	0,711	97,70
F	Nelore	0,33	0,63	1,17	0,00001	0,98	0,56	0,61	0,95	0,905	2,264	11,48	86,25

MI = macho não castrado, MC= Macho Castrado, F=Fêmea, CCorte=Cruzado de corte, CLeite=Cruzado de leite, Rest. r² = r² resistente; Mayer's test = H0: a = 0 e b = 1; CCC = coeficiente de correlação de concordância, varia de 0 a 1; Cb = correção de viés, varia de 0 a 1; 1 indica nenhum desvio de Y = X, RMSEP = raiz do erro quadrático médio; MSEP = erro quadrático médio de predição; MB = enviesamento médio (% de MSEP); SB = viés sistemático (% de MSEP); RE = erros aleatórios (% de MSEP).

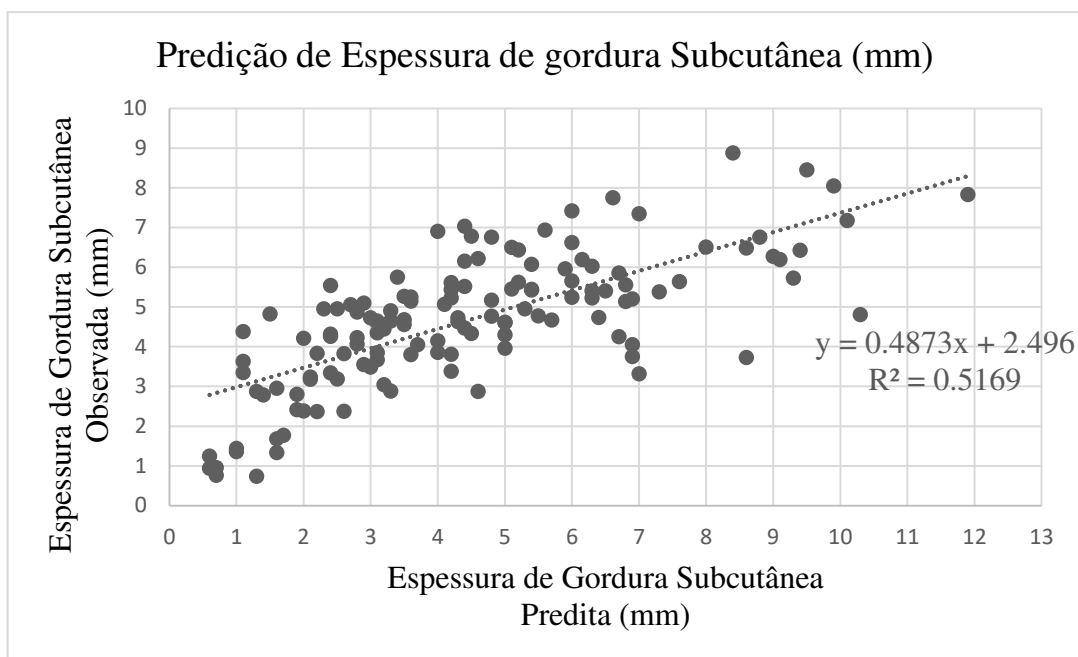


Figura 1 - Relação entre os valores preditos e observados da espessura de gordura subcutânea.

A partir da validação da equação, recomenda-se o uso da equação proposta para animais Nelore e cruzados de corte e leite, de diferentes classes sexuais, como uma ferramenta para estimar a qualidade da carcaça bovina em relação à cobertura de gordura. Espera-se que as equações geradas possam contribuir para a produção de carcaças mais homogêneas a serem entregues aos frigoríficos e auxiliar nas tomadas de decisão do sistema de produção de bovinos de corte.

AGRADECIMENTOS

Este projeto recebeu apoio da FAPEMIG, INCT-CA e CNPq 311545/2017-3.

REFERÊNCIAS

- Allen, P. (2009). Automated grading of beef carcasses. Improving the sensory and nutritional quality of fresh meat, 479-518.
- Almeida, M. I. V. D., Fontes, C. A. D. A., Almeida, F. Q. D., Valadares Filho, S. D. C., Campos, O. F. D. (2001). Conteúdo corporal e exigências líquidas de energia e proteína de novilhos mestiços Holandês-Gir em ganho compensatório. Revista Brasileira de Zootecnia, 30(1):205-214.

- Arboitte, M. Z., Restle, J., Alves Filho, D. C., Pascoal, L. L., Pacheco, P. S., Socal, D. C. (2004). Características da carcaça de novilhos 5/8 Nelore-3/8 Charolês abatidos em diferentes estádios de desenvolvimento. *Revista Brasileira de Zootecnia*, 33, 969-977.
- Berg, R. T., Butterfield, R. M. (1976). *New concepts of cattle growth*. Sydney University Press, University of Sydney.
- Bittencourt, C. D. R. (2009). Classificação automática do acabamento de gordura em imagens digitais de carcaças bovinas. Dissertação (Mestrado em Informática), Universidade de Brasília. Disponível em: https://repositorio.unb.br/bitstream/10482/4958/1/Dissertacao_Carmen_Bittencourt.pdf. Acesso em: 19 maio 2020.
- Bridi, A. M. (2019). Fatores que afetam a qualidade e o processamento dos produtos de origem animal. SD. Disponível em: <http://www.uel.br/pessoal/ambridi/Carnesecarcacasarquivos/FATORESQUEAFE TAMAQUALIDADEDACARNE.pdf>> Acesso em: 13 de julho de 2019.
- Bridi, A. M. (2002). Normas de avaliação, classificação e tipificação de carnes e carcaças. Univ. Est. Londrina. Disponível em: <http://www.uel.br/pessoal/ambridi/Carnesecarcacasarquivos/Avaliacaocarcacabovinosuinoeaves.pdf>. Acesso em: 18 julho 2020.
- Čandek-Potokar, M., Prevolnik, M., Škrlep, M., Font-i-Furnols, M., Novič, M. (2015). An attempt to predict conformation and fatness in bulls by means of artificial neural networks using weight, age and breed composition information. *Italian Journal of Animal Science*, 14(1):3198.
- Cardoso, L. L. (2013). Estimativas do rendimento comercial de novilhos com a utilização de ultrassom. Tese. Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, Brasil 119 p.
- Costa, E. C. D., Restle, J., Vaz, F. N., Alves Filho, D. C., Bernardes, R. A. L. C., Kuss, F. (2002). Características da carcaça de novilhos Red Angus superprecoces abatidos com diferentes pesos. *Revista Brasileira de Zootecnia*, 31, 119-128.

- Craigie, C.R.; Navajas, E.A.; Purchas, R.W.; Maltin, C.A.; Buenger, L.; Hoskin, S.O.; Ross, D.W.; Morris, S.T.; Roehe, R. (2012). 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 subjective systems. *Meat science*, 92(4), 307-318. Doi: 10.1016/j.meatsci.2012.05.028.
- Craigie, C. R., Ross, D. W., Maltin, C. A., Purchas, R. W., Bünger, L., Roehe, R., Morris, S. T. (2013). The relationship between video image analysis (VIA), visual classification, and saleable meat yield of sirloin and fillet cuts of beef carcasses differing in breed and gender. *Livestock Science*, 158(1-3), 169-178. Doi: 10.1016/j.livsci.2013.09.014
- De La Iglesia D. H., González, G. V., García, M. V., Rivero, A. J. L., De Paz, J. F. (2020). Non-invasive automatic beef carcass classification based on sensor network and image analysis. *Future Generation Computer Systems*, 113, 318-328. ISSN 0167-739X, <https://doi.org/10.1016/j.future.2020.06.055>.
- Gonçalves, D. N., de Moares Weber, V. A., Pistori, J. G. B., da Costa Gomes, R., de Araújo, A. V., Pereira, M. F., Gonçalves, W. N., Pistori, H. (2020). Carcass image segmentation using CNN-based methods. *Information Processing in Agriculture*.
- He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Kazama, R., Zeoula, L. M., Prado, I. N. D., Silva, D. C. D., Ducatti, T., Matsushita, M. (2008). Quantitative and qualitative carcass characteristics of heifers fed different energy sources on a cottonseed hulls and soybean hulls based diet. *Revista Brasileira de Zootecnia*, 37(2), 350-357.
- Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., Belongie, S. (2017). Feature pyramid networks for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2117-2125).
- Lin, L. I. K. (1989). A concordance correlation coefficient to evaluate reproducibility. *Biometrics* 45:255–268.

- López-Campos, Ó., Prieto, N., Juárez, M., Aalhus, J. L. (2019). New technologies available for livestock carcass classification and grading. *CAB Reviews*, 14(018), 1-10. Doi: 10.1079/PAVSNNR201914018
- Luchiari Filho, A. (2000). *Pecuária da carne bovina*. 1ed. São Paulo: LinBife, 134p
- Magnabosco, C. D. U., Sainz, R. D., Faria, C. U., Yokoo, M. J., Manicardi, F., Barbosa, V., ..., Magnabosco, C. U. (2006). Avaliação genética e critérios de seleção para características de carcaça em zebuínos: relevância econômica para mercados globalizados. *Simpósio internacional de produção de gado de corte*, 1, 239-271.
- McEvers, T. J., Hutcheson, J. P., Lawrence, T. E. (2012). Quantification of saleable meat yield using objective measurements captured by video image analysis technology. *Journal of animal science*, 90(9), 3294-3300. Doi: 10.2527/jas.2011-4223.
- Moreira, A. D., Siqueira, G. R., Lage, J. F., Benatti, J. M. B., Moretti, M. H., Miguel, G. Z., Oliveira, I. M., De Resende, F. D. (2017). Castration methods in crossbred cattle raised on tropical pasture. *Animal Production Science*, 58(7), 1307-1315.
- Nour, A. Y. M., Thonney, M. L. (1994). Chemical composition of Angus and Holstein carcasses predicted from rib section composition. *Journal of Animal Science*, 72(5), 1239-1241.
- Nour, A. Y. M., Thonney, M. L., Stouffer, J. R., White Jr, W. R. C. (1981). Muscle, fat and bone in serially slaughtered large dairy or small beef cattle fed corn or corn silage diets in one of two locations. *Journal of Animal Science*, 52(3), 512-521.
- Osório, J.C.S., Osório, M. T. M., Fernandes, A. R. M., de Oliveira Seno, L., de Almeida Ricardo, H., Rossini, F. C., Junior, M. A. P. O. (2012). Critérios para abate do animal e a qualidade da carne. *Agrarian*, 5(18), 433-443.
- Osório, J.C.S., Siewerdt, F., Osório, M. T. M., Guerreiro, J. L. V. (1995). Desenvolvimento alométrico das regiões corporais em ovinos. *Revista da Sociedade Brasileira de Zootecnia*, 24(2), 326-333.

- Pereira, M. A., Fairweather, J. R., Woodford, K. B., Nuthall, P. L. (2016). Assessing the diversity of values and goals amongst Brazilian commercial-scale progressive beef farmers using Q-methodology. *Agricultural Systems*, 144, 1-8.
- Restle, J., Vaz, F. N., Quadros, A. R. B. D., Müller, L. (1999). Características de carcaça e da carne de novilhos de diferentes genótipos de Hereford x Nelore. *Revista Brasileira de Zootecnia*, 28, 1245-1251.
- Sakamoto, L. S. (2012). Predição de rendimento de cortes cárneos e teor de gordura a partir de medidas de carcaça obtidas por ultrassonografia. Nova odessasp. Disponível em: <http://www.iz.sp.gov.br/pdfs/1332338444.pdf>. Acesso em: 30 junho de 2020.
- Scholz, A. M., Bünger, L., Kongsro, J., Baulain, U., Mitchell, A. D. (2015). Non-invasive methods for the determination of body and carcass composition in livestock: dual-energy X-ray absorptiometry, computed tomography, magnetic resonance imaging and ultrasound: invited review. *Animal*, 9(7), 1250-1264.
- Tedeschi, L. O. (2006). Assessment of the adequacy of mathematical models. *Agricultural systems*, 89(2-3), 225-247.
- Tian, H., Wang, T., Liu, Y., Qiao, X., Li, Y. (2019). Computer vision technology in agricultural automation—A review. *Information Processing in Agriculture*, 7(1), 1-19.
- Williams, J. E., Wagner, D. G., Walters, L. E., Horn, G. W., Waller, G. R., Sims, P. L., Guenther, J. J. (1983). Effect of production systems on performance, body composition and lipid and mineral profiles of soft tissue in cattle. *Journal of Animal Science*, 57(4), 1020-1028.

CONCLUSÕES GERAIS

O presente estudo abordou o desenvolvimento de uma metodologia de análise de imagens digitais, que pode ser utilizada para melhorar a extração de informações em bovinos e carcaça e, posteriormente, utilizar dessas informações para prever o acabamento de gordura nas carcaças de bovinos.

Tecnologias similares a esta ainda são escassas no Brasil e no exterior. Os métodos atualmente utilizados baseiam-se, principalmente, na avaliação subjetiva da musculatura e do acabamento de gordura, por meio da palpação e observação visual de pontos anatômicos específicos por um profissional treinado. Existem tecnologias que contornam o problema da subjetividade, como por exemplo a ultrassonografia, análise computadorizada de imagens de vídeo, reflectância próxima do infravermelho (NIRS), condutividade elétrica ou impedância bioelétrica, que apesar de apresentar bons resultados, tem sua utilização limitada pelos custos elevados.

Nesse sentido, o desenvolvimento de sistemas baseados no uso de sensores de baixo custo e análise de imagens, são uma alternativa interessante, fácil de adotar e justificável. Frente a isso, as contribuições desta tese são: apresentação das medidas biométricas de bovinos, separados por classe sexual, obtidas a partir de análise de imagem RGB-D; e relacioná-las com os escores de acabamento atribuídos às carcaças em frigorífico comercial. Portanto, a adoção desse sistema proporcionaria menos manipulação animal, reduzindo o estresse e aumentando o bem-estar. Outra contribuição é a proposição de um método de segmentação de imagens de carcaças coletadas dentro dos frigoríficos. É importante ressaltar que a eficiência de um sistema de extração de informações por análise de imagens depende de aspectos desde a captura da imagem, passando pelo seu armazenamento, pré-processamento e processamento propriamente dito, sendo a qualidade de cada uma dessas etapas um fator de grande influência no processo.

A utilização de diferentes grupos genéticos e pesos de abate na composição do conjunto de dados aumentou a variabilidade e representatividade dos valores das características investigadas. As medidas biométricas em bovinos diferiram significativamente ($P < 0,05$) entre os escores. Considerando as características da carcaça, o uso de imagens representa uma alternativa promissora na classificação e tipificação das carcaças de bovinos. As medidas biométricas, obtidas pela análise de imagem tiveram influência da classe

sexual e do escore de acabamento da gordura subcutânea. Esses resultados demonstram que, apesar do baixo número de amostras utilizadas, o processamento de imagens tem grande potencial para avaliação da carcaça bovina, seja *in vivo* ou *post mortem*, principalmente por possibilitar a inclusão de novas mensurações que permitam prever características de interesse.

De modo geral, as informações mais apuradas, extraídas das imagens, poderão complementar as avaliações que são rotineiramente realizadas. Nesse sentido, ao serem agregadas mais informações a respeito dos animais e das carcaças, o processo de tomada de decisão dentro da propriedade rural e frigoríficos certamente torna-se mais coerente, mais acurado e com reflexos positivos sobre toda a cadeia produtiva bovina.

Desafios para implementação do sistema

O sistema baseia-se na utilização de técnicas de Video image analysis (VIA) e sensores de infravermelho que permitem a captura de imagens detalhadas, sendo possível realizar a reconstrução em 3D e extração de medidas. O sistema não é invasivo, não destrutivo, não gera resíduos, não necessita de um profissional qualificado para interpretar os dados gerados, rápido e apresenta maior precisão se comparado com a avaliação subjetiva (visual). A seguir, serão apresentados alguns pontos que devem ser observados para que se possa obter resultados satisfatórios nas mensurações.

O primeiro ponto a ser levantado em consideração é o posicionamento dos animais, carcaças e equipamentos. Isso porque, para obter o máximo de proveito dos equipamentos e conseguir eliminar ao máximo a interferência humana, todos os equipamentos precisam estar posicionados de tal forma que o sensor de infravermelho seja capaz de capturar imagem de todo o corpo animal e da carcaça inteira, o que será definido principalmente pela distância do sensor e ao campo de visão do sensor (*field of view*). Para garantir a qualidade das mensurações, tratando-se de carcaças, deve existir um suporte atrás das carcaças para que estas sejam posicionadas frente ao sensor, este garantirá que a carcaça não rotacione, promovendo a coleta adequada das imagens.

A qualidade da imagem a ser analisada é um fator importante, essa dependerá principalmente do ambiente e do sensor. O sensor de infravermelho

utilizado foi o Intel® RealSense™, este combina uma câmera RGB e um sensor de profundidade. Como o princípio de operação deste tipo de sensor consiste na emissão de um sinal IR que viajam até o ponto medido, são refletidos e novamente recebidos pelo sensor, a incidência direta de iluminação sobre os sensores não é recomendada. Quando isso ocorre pode existir perda de dados comprometendo a qualidade das imagens. A iluminação pode “queimar” os pontos, comprometendo assim a extração das informações.

Os sensores devem ser resistentes ao ambiente hostil dos confinamentos e linha de abate, onde serão expostas as condições adversas de temperatura, umidade e iluminação. Além disso, a condensação de água, manchas e sujidades sobre a lente do sensor devem ser evitadas, vistos que causará interferência no feixe luminoso do sensor causando interferência nas imagens coletados. Outro ponto que pode limitar a utilização dos sistemas são os recursos tecnológicos e suporte computacional. O sistema de processamento e análise de imagens digitais devem ser robustos e rápidos o suficiente para permitir que as etapas de aquisição e digitalização, pré-processamento, segmentação e extração, classificação e reconhecimento de atributos sejam realizadas em tempo real sem prejudicar a eficiência da linha de produção.

Para isso, será necessário a utilização de computadores mais potentes e de uso específico. Ao utilizar computadores de propósito geral em aplicações industriais existe uma série de problemas diz respeito ao ambiente agressivo, caracterizado por vibrações, interferências eletromagnéticas, altas temperaturas, choques, dentre outros fatores. Ainda, por se tratar de uma arquitetura de propósito geral, problemas de performance podem ser enfrentados visto que são executados diversos processos concorrentes do próprio sistema operacional. Esta dificuldade pode ser contornada parcialmente com o uso de computadores especificamente construídos para o ambiente industrial. Porém, estes computadores industriais podem apresentar valores bastante elevados, a depender das suas configurações, quando comparados com computadores de propósito geral.

Considerando, que as características específicas de qualidade de carcaças como idade, acabamento e condição sexual, pode apresentar variações em detrimento da extensão territorial, as condições climáticas, épocas do ano e anos consecutivos, diferentes níveis tecnológicos e regiões, afetam a produção e oferta de bovinos enviados para abate e reflete diretamente na carcaça. Nesse sentido, a

coleta e a análise de imagens de diferentes regiões do Brasil, aumentará a variabilidade das características avaliadas e assim proporcionar o desenvolvimento de um modelo que permita hierarquizar as carcaças e carnes produzidas, mesmo estas sendo de diferentes regiões e frigoríficos.

Trabalhos futuros

A metodologia apresentada neste trabalho serve como parâmetro inicial para o desenvolvimento de tecnologias que objetivam diminuir a subjetividade na definição do ponto de abate e na classificação do acabamento de gordura das carcaças bovinas.

Os trabalhos futuros devem ser realizados para identificar a área de interesse e capturar os quadros de maneira automática, permitindo obter imagens onde os animais estarão em posições adequadas para extração das medidas. Outra alternativa é coletar e processar várias imagens do mesmo animal e carcaça, e calcular as medidas com médias dos vários quadros.

Os trabalhos devem focar, também, na melhora da qualidade das imagens durante o processo da aquisição, aumento da rusticidade dos equipamentos, tornando-os mais resistente ao ambiente hostil da linha de abate e na utilização de computadores mais potentes, que permitirão estudar e utilizar técnicas complexas de minimização de ruídos nas imagens digitais. Pode-se, ainda, realizar pesquisas no sentido de utilizar processamento de imagens para obter informações relevantes sobre localização e números de lesões nas carcaças. Além disso, a análise da coloração da carne e da gordura pode ser realizada, a fim de atender as exigências de cada mercado.

Assim sendo, mais pesquisas devem ser realizadas, considerando os pontos levantados no presente trabalho, de modo a melhorar a qualidade dos modelos gerados.