

FRANCISCO ALBIR LIMA JÚNIOR

**PREDIÇÃO DE CARACTERÍSTICAS DE CARÇA EM OVINOS A PARTIR DE
IMAGENS ULTRASSONOGRÁFICAS: APLICAÇÃO DE ALGORITMOS DE
VISÃO COMPUTACIONAL**

TERESINA, PI

2025

FRANCISCO ALBIR LIMA JÚNIOR

**PREDIÇÃO DE CARACTERÍSTICAS DE CARÇA EM OVINOS A PARTIR DE
IMAGENS ULTRASSONOGRÁFICAS: APLICAÇÃO DE ALGORITMOS DE
VISÃO COMPUTACIONAL**

Tese apresentada ao Programa de Pós-Graduação em Zootecnia Tropical da Universidade Federal do Piauí, como parte dos requisitos para obtenção do título de Doutor em Zootecnia Tropical, Área de Concentração: Produção Animal.

Orientador: Prof. Dr. José Lindenberg Rocha Sarmiento

Coorientador: Prof. Dr. Romuere Rodrigues Veloso e Silva

TERESINA, PI

2025

FICHA CATALOGRÁFICA
Universidade Federal do Piauí
Biblioteca Setorial CCA
Serviço de Representação da Informação

L732p Lima Júnior, Francisco Albir.
 Predição de características de carcaça em ovinos a partir de
 imagens ultrassonográficas: aplicação de algoritmos de visão
 computacional. / Francisco Albir Lima Júnior. -- 2025.
 85 f.

 Tese (Doutorado) – Universidade Federal do Piauí, Centro de
 Ciências Agrárias, Programa de Pós-Graduação em Zootecnia
 Tropical, 202.
 “Orientador: Prof. Dr. José Lindenberg Rocha Sarmento .”

 1. Carcaça. 2. Inteligência Artificial. 3. Produção de Carne. 4.
 Random Forest. 5. Yolov8. I. Sarmento, José Lindenberg Rocha. II.
 Título.

CDD 636.31

Bibliotecário: Rafael Gomes de Sousa - CRB3/1163

**PREDIÇÃO DE CARACTERÍSTICAS DE CARCAÇA EM OVINOS A PARTIR
DE IMAGENS ULTRASSONOGRÁFICAS: APLICAÇÃO DE ALGORITMOS
DE VISÃO COMPUTACIONAL**

FRANCISCO ALBIR LIMA JÚNIOR

Tese aprovada em: 28/03/2025

Banca Examinadora:

Documento assinado digitalmente
 JOSE LINDENBERG ROCHA SARMENTO
Data: 22/05/2025 15:25:17-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. José Lindenberg Rocha Sarmento (Presidente) / DZO/CCA/UFPI

Documento assinado digitalmente
 NATANAEL PEREIRA DA SILVA SANTOS
Data: 22/05/2025 16:25:38-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Natanael Pereira da Silva Santos (Interno) / DZO/CCA/UFPI

Documento assinado digitalmente
 DANIEL BIAGIOTTI
Data: 22/05/2025 16:45:16-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Daniel Biagiotti (Interno) / CTT/UFPI

Documento assinado digitalmente
 DEBORA ARAUJO DE CARVALHO
Data: 26/05/2025 16:01:52-0300
Verifique em <https://validar.itl.gov.br>

Profa. Dra. Débora Araújo de Carvalho (Externa) / UESPI

Documento assinado digitalmente
 ROMUERE RODRIGUES VELOSO E SILVA
Data: 23/05/2025 08:05:50-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Romuere Rodrigues Veloso e Silva (Interno) / CSHNB/UFPI

Documento assinado digitalmente
 GLEYSON VIEIRA DOS SANTOS
Data: 23/05/2025 21:36:16-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Gleyson Vieira dos Santos (Externo) / UESPI

*À **Deus**, por ter me dado força e sabedoria durante toda a minha carreira acadêmica.*

*Aos meus avós, **José Rodrigues Torres e Clarice Alves Torres** (in memoriam), por sempre terem sido por mim em vida.*

*À **minha família**, e em especial aos meus pais, **Francisco Albir Lima e Teresinha Alves Torres Lima** por todos os ensinamentos dados.*

*Aos meus irmãos, **José Rodrigues Torres Neto e Ariane Kelle Santos de Oliveira Lima** por sempre me apoiarem em todas as etapas da minha vida.*

*Ao meu grupo **J.O.N.A.S.** da pastoral da juventude da Paróquia N. Senhora de Fátima por todo o apoio nos momentos mais difíceis.*

*Ao meu namorado **Manoel Pereira da Mata Neto**, por todo o apoio e suporte durante o doutorado.*

AGRADECIMENTOS

À DEUS, por sempre ter estado comigo, me iluminando e dando forças para enfrentar os entraves da pesquisa.

À Universidade Federal do Piauí e ao Centro de Ciências Agrárias, em especial ao Programa de Pós-Graduação em Ciência Animal, pela oportunidade de conclusão de mais uma etapa da minha vida acadêmica, durante o doutorado.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de estudo durante o doutorado.

Ao Prof. Dr. José Lindenberg Rocha Sarmiento pela confiança, ensinamentos, paciência e orientações e suporte desde a graduação até o doutorado.

Ao Prof. Dr. Romuere Rodrigues Veloso e Silva por todos os ensinamentos e por ter desenvolvido toda a programação que possibilitou o desenvolvimento da minha pesquisa.

Aos Professores, Prof. Dr. Antônio de Sousa Júnior e o Médico Veterinário Dr. Luiz Antônio Silva Figueiredo Filho por sempre oferecer o ultrassom e apoio para o desenvolvimento da minha pesquisa.

Aos Professores do Programa de Pós-graduação em Zootecnia Tropical, em especial o Prof. Dr. Natanael Pereira da Silva Santos, pelos ensinamentos prestados, que não só se importaram em repassar os conhecimentos como também em incentivar, despertando o senso crítico de caráter profissional.

Ao Grupo de Estudos em Melhoramento Animal (GEMA) e ao Departamento de Sistemas de Informação da UFPI *campus* Senador Helvídio Nunes de Barros, pelo suporte dado durante o desenvolvimento da minha pesquisa.

Aos produtores do Piauí por ter permitido desenvolver meu experimento com os animais.

A todos aqueles que não foram citados, mas cujas contribuições foram de suma importância em meu desenvolvimento científico e pessoal, bem como na realização deste trabalho, os meus mais sinceros agradecimentos.

SUMÁRIO

1. INTRODUÇÃO GERAL.....	13
2. REFERÊNCIAS BIBLIOGRÁFICAS.....	15
CAPÍTULO I.....	17
1. Introdução.....	19
<i>2.1. Métodos para avaliação de carcaça.....</i>	<i>21</i>
<i>2.2. Importância da padronização na coleta de dados.....</i>	<i>22</i>
<i>2.3. Avanços em visão computacional na agropecuária.....</i>	<i>24</i>
<i>2.4. Aplicações na predição de características de carcaça.....</i>	<i>28</i>
<i>2.5. Desafios e perspectivas futuras.....</i>	<i>30</i>
3. Conclusões.....	31
Referências bibliográficas.....	32
CAPÍTULO II.....	40
1. Introdução.....	43
2. Materiais e Métodos.....	44
2.1. Coleta de dados.....	44
2.2. Pré-processamento de imagens.....	46
2.3. Segmentação da EGS.....	47
2.4. Métricas de segmentação.....	47
2.5. Extração de características.....	48
2.6. Estimação da EGS.....	48
2.7. Métricas de Regressão.....	49
2.8. Estatísticas descritivas e comparação de médias.....	49
3. Resultados.....	50
3.1. Resultados da segmentação.....	50

	12
3.2. Resultados da estimação da EGS.....	52
4. Discussão.....	55
5. Conclusão.....	59
Referências Bibliográficas.....	59
CAPÍTULO III.....	67
1. Introdução.....	70
2. Materiais e Métodos.....	72
2.1. Coleta de dados.....	72
2.2. Pré-processamento de imagens.....	73
2.3. Segmentação da região de interesse.....	74
2.4. Métricas de segmentação.....	74
2.5. Extração de características.....	74
2.6. Análise de Regressão.....	75
2.7. Métricas de Regressão.....	76
2.8. Estatísticas descritivas e comparação de médias.....	76
3. Resultados.....	77
3.1. Resultados da segmentação.....	77
3.2. Resultados da análise de regressão.....	77
4. Discussão.....	83
5. Conclusão.....	87
Referências Bibliográficas.....	88
Considerações Finais.....	91

LIMA JÚNIOR, Francisco Albir. **PREDIÇÃO DE CARACTERÍSTICAS DE CARCAÇA EM OVINOS A PARTIR DE IMAGENS ULTRASSONOGRÁFICAS: APLICAÇÃO DE ALGORITMOS DE VISÃO COMPUTACIONAL**. 2025. 92f. Tese (Doutorado em Zootecnia Tropical), Universidade Federal do Piauí, Teresina. 2025.

Resumo: A ovinocultura é uma atividade pecuária em constante expansão, necessitando, portanto, de carne de boa qualidade e que atenda às demandas do mercado. Com o intuito de estudar características de carcaça, a área do músculo *Longissimus dorsi* é uma medida importante, por estar associada positivamente com o rendimento de carne, enquanto a espessura do músculo tem influência sobre a qualidade da carcaça. Assim, o conhecimento e a determinação destas medidas são essenciais para o produtor, e a determinação na realização destas medidas pode ser realizada com o auxílio de métodos e ferramentas de visão computacional. Portanto, o objetivo com a presente pesquisa é prever a espessura de gordura subcutânea por meio do reconhecimento de imagens de ultrassom utilizando ferramentas de visão computacional. Foram coletadas 358 imagens de ultrassom do músculo em questão de ovinos criados em ambiente tropical. A medida da espessura de gordura subcutânea (EGS), a comprimento (COL) e profundidade (POL), foram registradas em mm, cm e cm, respectivamente, além da relação *Ratio*. A determinação das medidas EGS, POL e COL foram realizadas a partir de imagens ultrassonográficas capturadas por profissional treinado. As imagens coletadas foram levadas para anotação e, em seguida, compiladas em uma versão para processamento e extração das medidas da EGS utilizando a ferramenta online Roboflow. O conjunto de imagens foi dividido em imagens originais e imagens com limites EGS (máscaras de segmentação) para encontrar a região de interesse (EGS) nas imagens com dimensão padronizada (224-224-3 pixels). Durante a segmentação, a rede YOLOv8 foi usada para processar e ajustar as imagens, enquanto os métodos shape, VGG e ResNet foram usados para validar e apresentar os resultados. As imagens foram agrupadas entre conjuntos treinamento do algoritmo (80%), validação (10%) e teste (10%). As métricas Jaccard Index e F1 score da segmentação foram usadas para verificar a similaridade entre os dois conjuntos de imagens. Para analisar os resultados da segmentação, três algoritmos de regressão foram utilizados na análise de regressão, Adabooster (ABR), Random Forest (RFR) e GradientBoosting (GBR). Para avaliar a qualidade da regressão, utilizaram-se as métricas de quadrados médios de resíduos (QMR), erro médio absoluto (EMA) e coeficiente de determinação de regressão (R^2). Para comparar as médias reais e previstas de COL, POL, *Ratio* e EGS, foi realizada análise de variância e teste t de Student a 5% de probabilidade. Dentre os regressores utilizados, o RFR foi o que apresentou melhor desempenho, demonstrando a robustez deste regressor. As médias previstas pela ferramenta e as medidas pelo especialista não apresentaram diferenças significativas e o valor previsto apresentou menor variância que o valor real, o que confirma o potencial da ferramenta treinada e executada. Portanto, a mensuração automática desta medida pelo método computacional proposto a partir de imagens de ultrassom é promissora, pois apresenta maior precisão que as mensurações realizadas por técnico treinado. Além disso, não requer intervenção humana na delimitação da EGS, COL, POL e *Ratio* em ovinos.

Palavras-chave: Carcaça, Inteligência Artificial, Produção de Carne, Random Forest, YOLOv8.

LIMA JÚNIOR, Francisco Albir. **PREDICTION OF CARCASS CHARACTERISTICS IN SHEEP FROM ULTRASOUND IMAGES: APPLICATION OF COMPUTATIONAL VISION ALGORITHMS.** 2025. 92f. Thesis (Doctorate in Tropical Animal Science), Federal University of Piauí, Teresina. 2025.

Abstract: Sheep farming is a livestock activity present in all continents, therefore requiring good quality meat to meet market demand. In order to study carcass characteristics, the area of the Longissimus dorsi muscle is an important measurement, as it is positively associated with meat yield, while muscle thickness has an influence on carcass quality. Thus, knowledge and determination of these measurements are essential for the producer, and determination in the performance of these measurements can be performed with the aid of computer vision methods and tools. Therefore, the objective of this research is to predict the thickness of subcutaneous fat through the recognition of ultrasound images using computer vision tools. A total of 358 ultrasound images of the muscle in question were collected from sheep raised in a tropical environment. The measurement of subcutaneous fat thickness (SFT), length (COL) and depth (POL) were recorded in mm, cm and cm, respectively, in addition to the Ratio relationship. The determination of the SFT, POL and COL measurements were performed from ultrasound images captured by a trained professional. The collected images were taken for annotation and then compiled into a version for processing and extraction of the EGS measurements using the online tool Roboflow. The image set was divided into original images and images with SFT boundaries (segmentation masks) to find the region of interest (SFT) in the images with standardized dimension (224-224-3 pixels). During segmentation, the YOLOv8 network was used to process and adjust the images, while the shape, VGG and ResNet methods were used to validate and present the results. The image set was divided between algorithm training (80%), validation (10%) and testing (10%). The Jaccard Index and F1 score metrics were used to verify the similarity between the two image sets. To evaluate the segmentation results, three regressors were used in the regression analysis, Adabooster (ABR), Random Forest (RFR) and GradientBoosting (GBR). To evaluate the quality of the regression, the mean square error (MSE), mean absolute error (MAE) and coefficient of determination (R^2) were calculated. To compare the real and predicted means of COL, POL, Ratio and SFT, analysis of variance and Student's t-test at 95% probability were performed. Among the regressors used, RFR was the one that presented the best performance, demonstrating the robustness of this regressor. The means predicted by the tool and those found by the expert did not present significant differences, and the predicted value presented lower variance than the real value, which confirms the success of the trained and executed tool. Therefore, the automatic measurement of this measurement by the proposed computational method from ultrasound images is promising, as it presents greater precision than measurements performed by trained personnel. Furthermore, it does not require human intervention in the delimitation of SFT, COL, POL and Ratio in sheep.

Keywords: Carcass, Artificial intelligence, Meat production, Random forest, YOLOv8.

INTRODUÇÃO GERAL

No atual contexto da pecuária, a ovinocultura de corte no Brasil faz parte de um mercado em evidente expansão. Esta atividade encontra-se presente em todos os continentes e isso deve-se a ampla adaptabilidade aos mais diferentes tipos de ambientes (GADELHA *et al.*, 2020).

A produção de ovinos encontra diversas limitações, sendo que a oferta de alimento depende de condições ambientais favoráveis, além da falta de reprodutores e matrizes selecionados para melhor a produção e a produtividade (LIRA *et al.*, 2017).

O processo de seleção nos rebanhos ovinos é dificultado, principalmente, pela falta ou ineficiente escrituração zootécnica, que prejudica as tomadas de decisões de manejo e seleção empregados por falta de informações sobre o animal. Soma-se isto o baixo uso de tecnologias que também afeta diretamente à produtividade, visto que alternativas inovadoras incrementam consideravelmente a produtividade e disponibiliza de maneira rápida e eficiente mais informações sobre o animal. Além disso, acrescenta-se uma dificuldade em realizar avaliações precisas e rápidas de características de carcaça em ovinos, o que limita o uso eficiente da seleção genética e a padronização dos lotes (SUGUISAWA *et al.*, 2013).

Sendo assim, torna-se essencial buscar alternativas tecnológicas para auxiliar o produtor na avaliação de animais em busca na produção de carne ovina de qualidade. A ultrassonografia, que permite avaliar características de carcaça por predições *in vivo*, principalmente em sistemas de produção de animais jovens, possibilitando a geração de um produto mais competitivo atendendo a demanda do mercado consumidor além de geração de informações para uso na seleção de animais para melhoria de carcaça. Este método possibilita de forma não-destrutiva e não-invasiva, a estimativa da área de olho de lombo e espessura da gordura subcutânea, dentre outras medidas, indicativas da quantidade e qualidade do produto final (MC MANUS *et al.*, 2013).

Umas das medidas mais utilizadas e avaliadas pela ultrassonografia é a área de olho de lombo (AOL) que corresponde a uma medida tomada do músculo *Longissimus dorsi*, localizado entre a 12ª e 13ª costela e prediz a quantidade total de carne, sendo então utilizada para se ter uma previsão do rendimento da carcaça. Observa-se, ainda que a AOL tem relação favorável com a musculosidade e é utilizada como indicador de rendimento dos cortes de alto valor comercial, além da medida apresentar uma correlação positiva com a porção comestível da carcaça (LIRA *et al.*, 2017).

A espessura de gordura subcutânea (EGS) é uma medida mensurada acima do músculo *Longissimus dorsi*, situado entre as 12^a e 13^a vértebras da ovelha, que evita o enrijecimento e escurecimento da carne, ou seja, a gordura atua como isolante térmico atuando como um protetor dos músculos durante o resfriamento e ainda possibilita que ela resfrie de forma lenta, dentro dos limites aceitáveis, evitando, assim o encurtamento das fibras musculares (*cold shortening*), melhorando ainda a maciez da carne e a durabilidade da carne. O conhecimento dessas medidas na criação de animais possibilita a formação de lotes padronizados com base na separação de animais com potencial genético para ganho de peso e grau de acabamento de carcaça (SOUZA *et al.*, 2016).

Outra característica da carcaça é o grau de marmoreio que confere qualidade ao produto, já que é correlacionada positivamente com a maciez e a suculência da carne. Os consumidores preferem carnes com alto grau de marmoreio e estão dispostos a pagar por essa carne de qualidade superior (HAUSMAN *et al.*, 2014). Além disso, carcaças com características superiores de qualidade (maior grau de acabamento e marmoreio, por exemplo) podem ser direcionadas para mercados específicos e obter maior lucro aos produtores (DU *et al.*, 2013).

Apesar da consolidação da ultrassonografia para avaliação de carcaça no animal vivo, a mensuração das principais medidas é realizada de forma manual ao processar a imagem no próprio ultrassom ou em sistemas que auxiliam na mensuração de medidas a partir de imagens. Neste sentido, a visão computacional, utilizando algoritmos baseados em imagens ultrassonográficas, é capaz de mensurar de forma precisa e automatizada, características como Espessura de Gordura Subcutânea, Profundidade de Olho de Lombo e Comprimento de Olho de Lombo em animais, contribuindo para uma avaliação eficiente da carcaça. Através das medidas mensuradas pelo especialista utilizando o ultrassom pode-se desenvolver algoritmos de visão computacional, para estimar as medidas de interesse a partir do processamento digital dessas imagens (BACKES *et al.*, 2019).

Esta pesquisa aborda um problema central na ovinocultura brasileira: a falta de tecnologias que possibilitam a avaliação precisa e rápida para contribuir para melhorar e padronizar carcaças, essencial para aumentar a produtividade e atender às exigências de mercados especializados na cadeia da ovinocultura. A combinação de ultrassonografia com visão computacional representa uma abordagem inovadora e acessível que pode gerar impactos econômicos e tecnológicos significativos no setor.

Sendo assim, o objetivo com esta pesquisa é propor um sistema automatizado para mensurar a Espessura de Gordura Subcutânea (EGS), Profundidade de Olho de Lombo

(POL) e Comprimento de Olho de Lombo (COL), além de medidas relacionadas, tais como, Área de Olho de Lombo ajustada para 30 kg de peso corporal (AOL30) e *Ratio* em ovinos com o intuito de auxiliar na avaliação da carcaça utilizando algoritmos de visão computacional.

- **Capítulo I** – é abordada uma introdução e uma revisão de literatura sobre todos os aspectos relacionados a avaliação de carcaça em ovinos com ênfase na mensuração da espessura de gordura subcutânea, profundidade de olho de lombo e comprimento de olho de lombo do músculo *Longissimus dorsi*, a técnica da ultrassonografia nas suas mais variadas vertentes, além das aplicações da visão computacional (Este capítulo foi elaborado com base nas normas da revista Ciência Rural – ISSN 1678-4596).

- **Capítulo II** – predição da espessura de gordura subcutânea do músculo *Longissimus dorsi* a partir de imagens ultrassonográficas em ovinos utilizando visão computacional (Este capítulo foi elaborado com base nas normas da revista Ciência Rural – ISSN 1678-4596).

- **Capítulo III** – predição da profundidade e do comprimento de olho de lombo do músculo *Longissimus dorsi* a partir de imagens ultrassonográficas em ovinos utilizando visão computacional (Este capítulo foi elaborado com base nas normas da revista Ciência Rural – ISSN 1678-4596).

Referências Bibliográficas

- BACKES, AR.; SÁ JUNIOR, JJM. **Introdução à visão computacional usando Matlab**. Rio de Janeiro: Alta Books Editora, 2019. 288p.
- DU, M.; HUANG, Y.; DAS, AK.; YANG, Q.; DUARTE, MS.; DODSON, MV.; ZHU, MJ. Manipulating mesenchymal progenitor cell differentiation to optimize performance and carcass value of beef cattle 1,2. **Journal of Animal Science**, v.91, p.1419–1427, 2013. Available from: <<https://doi.org/10.2527/jas.2012-5670>>. Accessed: Nov. 18, 2024. doi: jas.2012-5670.
- GADELHA, JAF.; SILVA, RA.; MARQUES, AVM.; GADELHA, HS.; MELO, WF.; DANTAS, OKM.; SILVA, JCF.; LINS, JGG.; MEDEIROS, AC.; MARACAJÁ, PB. Influência do melhoramento genético em rebanhos ovinos de corte. **Research, Society and Development**, v.9, p.e129107774, 2020. Available from: <<https://doi.org/10.33448/rsd-v9i10.7774>>. Accessed: Nov. 18, 2024. doi: 10.33448/rsd-v9i10.7774.
- HAUSMAN, GJ.; BASU, U.; DU, M.; CULVER, MF; DODSON, MV. Intermuscular and intramuscular adipose tissues: Bad vs. good adipose tissues. **Adipocyte**, v.3, p. 242–

255, 2014. Available from: <<https://doi.org/10.4161/adip.28546>>. Accessed: Nov. 18, 2024. doi: 10.4161/adip.28546.

LIRA, AB.; GONZAGA NETO, S.; SOUSA, WH.; RAMOS, JPF.; CARTAXO, FQ.; SANTOS, EM.; CÉZAR, MF.; FREITAS, FF. Desempenho e características de carcaça de dois biótipos de ovinos da raça Santa Inês terminados a pasto suplementados com blocos multnutricionais. **Revista Brasileira de Saúde e Produção Animal**, v.18, p.313-326, 2017. Available from: <<https://www.scielo.br/j/cr/a/JFFbQcSYT3mgJZ4VCvRs5VM>>. Accessed: Nov. 18, 2024. doi: 10.1590/0103-8478cr20230576.

MCMANUS, C. et al. Avaliação ultrasonográfica da qualidade de carcaça de ovinos Santa Inês. **Ciência Animal Brasileira**, v.14, p.8–16. 2013. Available from: <https://doi.org/10.5216/cab.v14i1.12336>. Accessed: Nov. 25, 2024. doi: 10.5216/cab.v14i1.12336.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. **Medical image computing and computer-assisted intervention–MICCAI**. p.234–241. 2015. Available from: <<https://arxiv.org/abs/1505.04597>>. Accessed: Nov. 18, 2024. doi: 10.48550/arXiv.1505.04597.

SOUZA, SF.; BOAVENTURA NETO, O.; MORENO, GM.; MUNIZ, EN. Aplicação da ultrassonografia para avaliação de condição corporal e acabamento de carcaça em pequenos ruminantes. **Ciência Veterinária nos Trópicos**, v.19, p.34–42, 2016. 143p.

SUGISAWA, L. et al. Uso da ultrassonografia na avaliação de características de carcaça e de qualidade da carne. **Melhoramento genético aplicado em gado de corte**. Brasília, DF: Embrapa; 2013. p.97-107.

CAPÍTULO I

Avaliação de carcaça ovina: uma revisão geral sobre os principais aspectos relacionados com a ovinocultura de corte e a visão computacional

Avaliação de carcaça ovina: uma revisão sobre os principais avanços e perspectivas relacionados com a avaliação de carcaça ovina e a visão computacional

Francisco Albir Lima Júnior^{a,*}, José Weyner Rodrigues Farias^b, Natanael Pereira da Silva Santos^c, Daniel Biagiotti^d, Débora Araújo de Carvalho^e, Gleyson Vieira dos Santos^e, João Vitor Moreira Passos^f, Romuere Rodrigues Veloso e Silva^f José Lindenberg Rocha Sarmento^c

^a Programa de Pós-Graduação em Zootecnia, Centro de Ciências Agrárias, Universidade Federal do Piauí, Campus Universitário Ministro Petrônio Portella, Bairro Ininga, 64049-550, Teresina, PI, Brasil.

^b Zootecnista

^c Departamento de Zootecnia, Centro de Ciências Agrárias, Universidade Federal do Piauí, Campus Universitário Ministro Petrônio Portella, Bairro Ininga, 64049-550, Teresina, PI, Brasil.

^d Docente Colégio Técnico de Teresina – UFPI

^e Universidade Estadual do Piauí (UESPI), Teresina, PI, Brasil

^f Universidade Federal do Piauí (UFPI), Picos, PI, Brasil.

*Autor correspondente.

Endereços de e-mail: albirjunior@hotmail.com (F.A. Lima Júnior)

Resumo: A ovinocultura de corte no Brasil, mesmo sendo uma atividade promissora, no mercado agropecuário, ainda possui alguns problemas que dificultam avanços na produtividade, tais como, a falta de escrituração zootécnica, que prejudica o conhecimento do desempenho animal quando submetidos a diferentes manejos e o baixo uso de tecnologias inovadoras que impulsionam consideravelmente a produtividade e disponibiliza de maneira rápida e eficiente mais informações sobre o animal. Neste sentido, o estudo das características de carcaça é essencial para identificar as diferenças existentes entre os animais, buscando a seleção de animais que possuem carcaças com boa deposição de tecidos comestíveis, sendo de fundamental importância, pois estão diretamente relacionadas ao produto final que é a carne. Objetivou-se com esta revisão, descrever alguns aspectos da mensuração de medidas da carcaça por meio do reconhecimento de imagens ultrassonográficas de ovinos utilizando ferramentas de visão computacional. A ultrassonografia de carcaça é uma metodologia não-invasiva para realizar avaliação de carcaça por predições in vivo de algumas medidas da carcaça, tais como a estimativa da área de olho de lombo (AOL) e espessura da gordura subcutânea (EGS), dentre outras medidas que dão indicativo sobre a quantidade e qualidade do produto final, o rendimento da carne. Neste contexto, a visão computacional pode ser utilizada para automatizar as medidas das características da carcaça de animais, por meio do reconhecimento de imagens ultrassonográficas das regiões anatômicas do animal apropriadas para realizar as medidas. Através das medidas mensuradas pelo especialista utilizando o ultrassom pode-se desenvolver algoritmos de visão computacional, para estimar as medidas de interesse a partir da segmentação dessas imagens. O uso dessas ferramentas pode trazer vários benefícios, tais como, otimização da coleta de dados, informações mais precisas, retorno mais rápido das informações para o produtor e maior agilidade nas tomadas de decisões, tanto de manejo como de seleção, o que pode refletir em melhoria na produção e produtividade da carne ovina.

Palavras-chave: AOL, EGS, Ovinocultura, Segmentação de imagens, Ultrassonografia de carcaça.

Abstract: Sheep farming in Brazil, despite being a promising activity in the agricultural market, still has some problems that cause decreased productivity, such as the lack of zootechnical records, which hinders the management employed due to lack of information about the animal and the low use of technologies, since these innovative alternatives considerably boost productivity and provide more information about the animal quickly and efficiently. Therefore, the study of carcass characteristics is essential to identify the differences between animals, seeking the selection of animals that have carcasses with good deposition of edible tissues, which is of fundamental importance, since they are directly related to the final product, which is meat. The objective of this review was to describe some aspects of the measurement of carcass measurements through the recognition of ultrasound images of sheep using computer vision tools. Carcass ultrasound is a non-invasive methodology for performing carcass assessment by in vivo predictions of some carcass measurements, such as the estimation of the loin eye area (LEA) and subcutaneous fat thickness (SFT), among other measurements that provide an indication of the quantity and quality of the final product and are positively correlated with meat yield. In this context, computer vision can be used to study animal carcass characteristics by recognizing ultrasound images of the animal's body. Using the measurements taken by the specialist using ultrasound, computer vision algorithms can be developed to estimate the measurements of interest from the segmentation of these images. The use of these tools can bring several benefits, such as optimizing data collection, more accurate information, and increased production and productivity. However, sheep farming still faces several challenges, such as the limited amount of information available, energy consumption when using computational tools, and the need to provide tools that are easy for the producer to use.

Keywords: Carcass ultrasound, Image segmentation, REA, SFT, Sheep farming.

1. Introdução

No Brasil, encontram-se presente em torno de 21 milhões de ovinos, sendo o Nordeste a região com maior número de efetivos, tendo a Bahia como maior produtora da espécie com cerca de 5 milhões de cabeças e o Piauí é o 5º maior produtor com 8,3% do total de todo o rebanho de ovinos do Brasil (IBGE, 2024).

Os ovinos têm-se mostrado como animais que são fonte de carne essencial a ser produzida e comercializada. A ovinocultura é uma atividade ampla, já que a espécie tem alto poder adaptativo, entretanto os ambientes tropicais e subtropicais se destacam e se estabelecem como ambientes mais favoráveis no sistema de produção (JIMENEZ-SANZ et al., 2016).

À falta de escrituração zootécnica, ocasiona a falta de informações sobre o animal e limita o uso de tecnologias, o que pode comprometer avanços na produtividade. O uso de tecnologias no sistema de produção torna-se importante, pois otimiza o processo de produção, como o uso da ultrassonografia e de ferramentas computacionais, trazendo

melhorias significativas no processamento de imagens e, consequentemente, na produção (BACKES & SÁ JÚNIOR, 2019; LIMA JÚNIOR et al., 2024).

O estudo das características de carcaça é essencial para identificar as diferenças existentes entre os animais, buscando a seleção de animais que possuem carcaças de qualidade, sendo de fundamental importância, pois estão diretamente relacionadas ao produto final que é a carne (LIRA et al., 2017)

A ultrassonografia de carcaça é uma metodologia utilizada no processo de avaliação de carcaça por predições *in vivo* de algumas medidas da carcaça, principalmente em sistemas de produção de animais jovens, buscando a economia do processo de produção de ovinos. Esta metodologia proporciona de maneira não-invasiva, a estimativa da área de olho de lombo (AOL), espessura da gordura subcutânea (EGS), comprimento de olho de lombo (COL) e profundidade de olho de lombo (POL), medidas essas que dão indicativo sobre a quantidade e qualidade do produto final (SUGUISAWA et al., 2006).

A área de olho de lombo (AOL) que corresponde a uma medida tomada do músculo *Longissimus dorsi*, localizado entre a 12^a e 13^a costela e prediz a quantidade total de carne, sendo então utilizada para se ter uma previsão do rendimento da carcaça. A AOL é uma das medidas mais estudadas, apresentando correlação positiva com a musculosidade geral da carcaça, além de dar informações para incluir modelos de crescimento e seleção dos animais e auxiliar na identificação dos animais a serem abatidos. Além disso, quando a ultrassonografia é realizada pelo especialista possui alta correlação com as medidas obtidas na carcaça do animal abatido (HASHIMOTO et al., 2012; LIRA et al., 2017)

Já a espessura de gordura subcutânea (EGS) é uma outra medida mensurada acima do músculo que evita os efeitos prejudiciais de enrijecimento e escurecimento da carne tendo influência na qualidade da carne, tendo correlação positiva com a adiposidade e com o acabamento da carcaça. O conhecimento dessas medidas na criação de animais possibilita a formação de lotes de animais padronizados com base na separação de animais com potencial genético para ganho de peso e grau de acabamento de carcaça (SILVA et al., 2023).

O comprimento de olho de lombo (COL) e a profundidade de olho de lombo (POL) são outras duas medidas obtidas por meio da ultrassonografia de carcaça, mensuradas em cm, e que possuem correlação positiva com a AOL e com a conformação da carcaça, além de possibilitar a avaliação da quantidade de músculo (SENA et al., 2016).

A visão computacional é uma área da inteligência artificial que trata-se da área de estudo que permite a captura, extração e interpretação de características de imagens, ou

seja, possibilita a extração de informações a partir de imagens digitais (BACKES & SÁ JÚNIOR, 2019).

Esta delimitação ou também denominada segmentação das regiões de interesse é realizada com auxílio de diversos algoritmos presentes na literatura, tais como YOLOv8, ResNet, VGG, dentre outros (LI et al., 2020; HE et al., 2016; MAGGIORI et al., 2017). Estes algoritmos serão responsáveis por obter a partir de uma imagem a região delimitadora de interesse mais conhecido como ROI (*Region of interest*). Estes algoritmos irão possibilitar extrair de um conjunto de imagens o que realmente interessa (MARENGONI & STRINGHINI, 2010).

A visão computacional pode fornecer estimativas precisas das características da carcaça de animais, reduzindo a subjetividade das mensurações manuais e aumentando a eficiência do processo de seleção. Através das medidas mensuradas pelo especialista utilizando o ultrassom pode-se desenvolver algoritmos de visão computacional, para estimar as medidas de interesse a partir do processamento digital dessas imagens (RONNEBERGER et al., 2015).

Portanto, objetivo desta revisão é apresentar os avanços e perspectivas da visão computacional na avaliação de carcaças ovinas, destacando a viabilidade e limitações em relações aos métodos tradicionais.

2.1. Métodos tradicionais para avaliação de carcaça

A avaliação de carcaça por predição *in vivo* otimiza o processo de produção ovina, podendo determinar o ponto ideal para abate e o grau de desenvolvimento muscular dos animais, sendo a avaliação feita através da palpação ou observação visual (TAROUCO et al., 2005).

Um dos métodos de se avaliar a carcaça é a tomografia computadorizada que ainda está em desenvolvimento no mundo, mas é alternativa mais precisa para estudar o crescimento animal e das medidas de carcaça de ovinos. Porém, devido a pouca acessibilidade ao equipamento e ao alto custo de execução, a técnica não difundida para avaliação de carcaça de ovinos (CLELLAND et al., 2014).

Outro método é o peso ideal ao abate que é aquele onde a proporção de musculosidade presente na carcaça é máxima e a gordura é suficiente para proporcionar propriedades sensoriais adequadas que atendam a demanda de mercado. Com o aumento de peso corporal, conseqüentemente, aumenta-se o rendimento da carcaça, a AOL, a EGS, melhorando a conformação da carcaça. Em ovinos de corte, objetiva-se com este método, obter animais que direcionam grandes quantidades de nutrientes para a produção de

músculos. A metodologia, porém, não é a mais viável pois não leva em conta, a qualidade do animal como um todo. Para que a qualidade seja determinada, torna-se necessário avaliar os componentes do peso vivo, visto que a carcaça tem maior valor comercial, mas não é o único componente (AZEREDO et al., 2005).

A ultrassonografia é uma outra alternativa viável para avaliar a carcaça de ovinos *in vivo*, pois é uma metodologia relativamente de baixo custo e rápida, que possibilita estudar e/ou monitorar o crescimento do músculo *Longissimus dorsi* através das características de comprimento, profundidade e área do músculo (AOL), além da avaliação da espessura de gordura subcutânea (EGS), com o intuito de identificar o ponto ideal de abate. Entretanto, esta técnica ainda é uma metodologia susceptível de erros, a qual depende em grande parte da habilidade do técnico e da qualidade do ultrassom utilizado, tornando-se complicada a comparação entre resultados científicos (SUGUISAWA et al., 2013).

O aparelho de ultrassom mede a reflexão das ondas de alta frequência que acontece quando estas passam pelos tecidos. Após a colocação do transdutor, os pulsos elétricos são convertidos em ondas de alta frequência (ultrassons), que ao encontrar diferentes densidades dentro do animal refletem parcialmente (eco), em tecidos de menor densidade ou total nos de maior densidade. Logo após, as ondas de alta frequência permanecem se propagando pelo corpo do animal e as informações enviadas pelas por essas reflexões ao transdutor são convertidas em imagem (SUGUISAWA et al., 2013).

A utilização da ultrassonografia para se avaliar a carcaça é uma técnica não-invasiva eficiente para estudo das características produtivas e reprodutivas, podendo ser realizada de maneira fácil e objetiva em experimentos com o aparelho de ultrassom, demonstrando alta repetibilidade, baixo custo e fácil operação, atendendo às demandas do mercado, sem causar danos ao produto final (RIPOLL et al., 2010).

Estudos recentes estudaram a viabilidade da tecnologia de ultrassonografia na previsão da composição da carcaça baseado em mensurações *in vivo* e encontraram correlações significativas entre medições de ultrassom e medições de características da carcaça (GOMES et al. 2021; BERIAIN et al. 2021).

2.2. Importância da padronização na coleta de dados

Experimentos padronizados e métodos acurados para calcular as respostas e objetivos bem definidos possibilitam aceitar ou rejeitar a hipótese inicial, mesmo com um conjunto de dados reduzido (BOO et al., 2005).

A FELASA (Federation of European Laboratory Animal Science Association) recomenda que o profissional seja capacitado e com experiência adequada para coleta de dados em campo. BERSET et al. (2021), afirmam ao trabalhar com monitoramento de ovelhas, afirmam que um pré-requisito fundamental no gerenciamento do rebanho é que ele seja realizado por um especialista responsável competente e habilidoso e que o experimento seja conduzido por este profissional. Além disso, o especialista deve tomar as medidas adequadas, seguidas de boa habilidade de comunicação.

VOIPIO et al. (2008) e POIRIER et al. (2015) afirmam que um veterinário competente e experiente para trabalhar com ovelhas é fundamental durante a coleta de dados e do gerenciamento do rebanho, garantindo assim o bem-estar animal e uma maior agilidade no experimento nas fazendas.

LIMA JÚNIOR et al. (2024) ao mensurar a área de olho de lombo em ovinos para prever o rendimento da carcaça, ao utilizar a padronização na coleta de dados e trabalhar com 121 animais, obteve dados preditos pela ferramenta computacional próximos aos dados reais e coeficiente de determinação – R^2 (0,56) considerado bom conforme observado por MCMANUS et al. (2013), ao trabalhar com características de carcaça de ovelhas.

OSÓRIO et al. (2009), também, observaram que a ausência de padronização para os níveis de EGS em bovinos confinados, muitas vezes ocasiona em diminuições na carcaça e na qualidade da carne devido ao resfriamento, escurecimento e encurtamento das fibras musculares, e maior teor de gordura e excesso de EGS também podem diminuir o rendimento geral da carcaça.

Sendo assim, torna-se importante ocorrer uma padronização de atribuições durante a coleta, ou seja, apenas um especialista coletar as imagens ultrassonográficas, com o intuito de aumentar a precisão da predição da área de olho de lombo, contribuindo de forma significativa para o melhoramento genético de ovinos, pois desta forma o produtor terá uma segurança maior ao realizar a seleção destes animais pela precisão dos dados (LIMA JÚNIOR et al., 2024; OSÓRIO et al., 2009).

É importante destacar que além de aumentar a precisão obtida com a padronização durante a coleta, a fenotipagem dos ovinos em larga escala é fundamental na pesquisa, processo este fundamental para os programas de melhoramento genético e para outras áreas da produção animal de ovinos de corte que podem fazer uso dessa informação

para a tomada de decisões, pois possibilita um monitoramento maior dos indivíduos facilitando na seleção dos animais (LIMA JÚNIOR et al., 2024).

Para obter uma predição com elevada acurácia e resultados satisfatórios, torna-se necessária a utilização de algoritmos com resultados já consolidados na literatura. Através destes algoritmos é possível realizar a segmentação das imagens ultrassonográficas.

2.4. Avanços em visão computacional na pecuária

A classificação de imagens tem por objetivo organizar um banco de dados de imagens com regiões de interesse, de maneira a armazenar tais informações computacionalmente. A tarefa de classificação de imagens compreende o pré-processamento, extração de características, o treinamento do algoritmo utilizado e o registro da informação final (CHANDRA et al., 2021).

Um dos procedimentos mais complexos e importantes da visão computacional é a segmentação de imagens, cujo objetivo é a separação de regiões que correspondem a objetos presentes na imagem, geralmente levando em consideração similaridade, proximidade e descontinuidade, obtendo características de imagens e interpretando-as (GONZALEZ, 2009).

As áreas de interesse da segmentação de imagens podem ser usadas na medição do fenótipo, tais como de medidas da carcaça de ovinos. O algoritmo de *deep learning*, por exemplo, que aprende a extrair informações importantes dos dados, mostrou excelente desempenho na análise de imagens e análise de carcaças suínas (LI et al., 2019; FONT-I-FURNOLS et al., 2019). Trabalhos recentes em *deep learning* geraram avanços em tarefas de visão computacional e mostraram alto desempenho em segmentação de imagens (HESAMIAN et al., 2019).

A maior parte dos algoritmos de segmentação trabalha com os princípios de similaridade, que agrupa os pixels que possuem propriedades similares, e de descontinuidade, que utiliza os contornos da imagem para dividi-la em regiões menores (MASOOD et al., 2015).

A arquitetura básica de uma CNN (*Convolutional Neural Network*) possui camadas alternadas de convolução e *pooling* (agrupamento), seguidas por uma ou mais camadas totalmente conectadas. No caso das redes de convolução para segmentar a imagem, as camadas totalmente conectadas (FC) serão substituídas por uma camada final

de convolução, sendo, assim, chamadas de Redes Totalmente Convolucionais (FCN). O objetivo das CNN é realizar a segmentação de imagens fazendo uma adaptação na estrutura de redes neurais de classificação, como por exemplo, VGG, ResNet, U-Net, YOLOv8, dentre outros algoritmos capazes de realizar a segmentação de imagens.

É importante ressaltar que as redes de convolução são capazes de realizar outras tarefas no estado da arte, como detecção de objetos, segmentação semântica de imagens e segmentação de instâncias, fornecendo informações mais detalhadas no ambiente. A segmentação tem por objetivo compreender melhor a cena ao atribuir a cada pixel uma categoria de objeto, no interior da imagem. Essa compreensão possibilita que as máquinas extraiam informações de diferentes cenários do mundo real, possibilitando a realização de diferentes tarefas (ARNAB et al., 2018).

Essas redes podem reconhecer padrões escondidos e correlações em dados brutos e podem ser projetadas para classificar um objeto ao analisar suas características. Essas redes possuem uma estrutura comumente segmentada em camadas, entre elas estão as chamadas camadas de convolução. Essas são responsáveis pela identificação de características da imagem. Elas podem ser pensadas como filtros que irão percorrer a imagem, cada uma em busca de uma característica específica (LONG et al., 2015).

Esse reconhecimento de padrões e segmentação das regiões de interesse é realizada com auxílio de diversos algoritmos presentes na literatura. Estes algoritmos serão responsáveis por separar de uma imagem a região delimitadora de interesse mais conhecido como ROI. Estes algoritmos irão possibilitar extrair de um conjunto de imagens o que realmente interessa (MARENGONI e STRINGHINI, 2010).

A segmentação de imagens é uma tarefa fundamental na visão computacional e processamento de imagens, desempenhando um papel importante em ferramentas que trabalham com processamento de imagens, pois o resultado da segmentação influenciará diretamente no desempenho das etapas seguintes. A segmentação trata-se da divisão de uma imagem específica em um número de segmentos homogêneos, pois, a representação de uma imagem de uma maneira simples e fácil aumenta a eficiência do reconhecimento de padrões. (MINAEE et al., 2021)

Deste modo, a segmentação deve parar quando a região de interesse em uma aplicação estiver isolada. Os objetos nos conjuntos de dados reais ocupam apenas uma pequena parte da imagem, enquanto o restante da imagem é o fundo. No caso da aplicação

da segmentação no corpo de animais, as bordas são calculadas a fim de identificar a possível região do animal. Na segmentação do corpo de animais, as bordas são calculadas a fim de identificar a possível região do animal (ABDULATEEF & SALMAN, 2021).

Para avaliação da qualidade da segmentação utiliza-se algumas métricas presentes na literatura. Estas métricas servem para classificar e comparar a qualidade das previsões entre sistemas. Uma dessas métricas é a precisão dos objetos detectados, que indica quantas detecções estão corretas. Uma outra métrica a *recall* calcula a proporção de mensurações corretas, medindo a capacidade do modelo de identificar todas as partes da imagem. Já a métrica mAP50 refere-se à precisão média calculada de acordo com um limiar de intersecção sobre união (IoU) de 0,50 (a IoU indicando a similaridade entre dois conjuntos de imagens). A mAP50 é uma medida que avalia a precisão do modelo (ZHAO et al., 2023; XU et al., 2024; YU et al., 2022).

Uma imagem possui propriedades que podem ser mensuradas chamadas características do objeto. Tais características são normalmente agrupadas em uma matriz escalar denominadas “vetor de características” ou “descriptor de recursos”. Com o intuito de realizar a extração de características de uma imagem, geralmente aplica-se um descriptor que armazena informações importantes que representam a imagem em um vetor. Esta etapa objetiva encontrar características relevantes da imagem que possam ser usadas em tarefas como classificação ou reconhecimento de objetos. As novas técnicas baseadas em dados usam algoritmos de aprendizado de máquina para construir descritores de forma precisos e confiáveis (LÓPEZ et al., 2017).

As características podem incluir bordas, contornos, formas, padrões, cores e outras propriedades que possam ser obtidas das imagens. Essas características são selecionadas baseadas em sua capacidade de diferenciar objetos ou padrões de interesse em relação ao fundo. Para aplicar tal abordagem, é necessário destacar que uma das características básicas de um objeto é sua forma (SAMPATH et al., 2021).

Geralmente, as características de forma são uma representação simplificada de uma forma 2D, no qual é convertido em um vetor com um conjunto de valores numéricos, onde, será utilizada para descrever a forma da imagem de maneira geométrica ou possibilitando o uso desses valores para as etapas posteriores, tais como a predição de determinados valores. Este procedimento possibilita realizar processos de classificação e comparação para correspondência das imagens dos animais (LÓPEZ et al., 2017).

Posteriormente, a regressão linear apresenta um papel essencial na modelagem estatística. Esta etapa consiste em uma tarefa de aprendizado de máquina para prever valores reais, caracterizando a relação estatística entre uma ou mais variáveis preditoras e a variável resposta. Simplificando, a análise de regressão linear é uma maneira de modelar uma saída contínua, por meio de uma variável chamada 'Y' dependente, no qual será o valor previsto como uma função linear de um ou vários preditores 'X' independentes que consistem em valores reais (ANTTALAINEN et al., 2021).

Vale destacar, que uma etapa importante em qualquer modelo de aprendizado de máquina é avaliar a acurácia do modelo, ou seja, quanto a equação se ajusta aos dados. Para a avaliação da qualidade de ajuste da regressão, torna-se necessário avaliar e aplicar algumas métricas descritas na literatura para calcular a precisão do modelo, tais como coeficiente de determinação de regressão (R^2), quadrado médio dos resíduos (QMR) e erro médio absoluto (EMA) (CHICCO et al., 2021).

Um algoritmo bastante presente na literatura é o algoritmo U-Net que se trata de redes convolucionais para segmentar imagens biomédicas usando estratégia de rede e treinando o próprio algoritmo. Ele propõe, através da utilização de aumento de dados, o uso eficiente de amostras anotadas disponíveis. A arquitetura do algoritmo é composta de um caminho de contração que busca capturar o contexto ou conjunto de dados e um caminho de expansão simétrico que possibilita uma localização precisa. Entretanto este algoritmo necessita de maior aprimoramento para melhorar sua eficiência, acurácia e precisão nos resultados (RONNEBERG et al., 2015).

Um outro exemplo de algoritmo de segmentação de imagens é o VGG-16 (*Visual Geometry Group*) que utiliza camadas convolucionais 3 x 3 empilhadas umas sobre as outras com profundidade crescente. Esta rede demonstra precisão no reconhecimento de imagem em larga escala (MAGGIORI et al., 2017). ALSHAMMARI,et al. (2022), observou que quando o VGG-16 é utilizado para substituir a U-Net na extração de características em imagens de ovinos, apresenta precisão maior.

Já a rede ResNet (do inglês *Residual Network*) é uma rede neural convolucional oriunda da *Microsoft* presente no conjunto de dados ImageNet e está presente na biblioteca *Keras*. A ResNet mostra que os mapas residuais são mais fáceis de serem otimizados por meio dessa alteração no espaço de entrada (HE et al., 2016). XU et al.

(2024) ao trabalhar com a ResNet estudando peso em bovinos encontrou uma precisão de cerca de 96%.

Um outro exemplo é o algoritmo YOLOv8 que suporta múltiplas tarefas de visão, como detecção de objetos, segmentação, estimativa de pose, rastreamento e classificação. Este algoritmo utiliza um modelo definido para processar de forma independente objetividade, classificação e tarefas de regressão. Esta rede possibilita concentração em sua tarefa melhorando assim a precisão geral do modelo, demonstrando alta velocidade e eficiência. Entretanto, esta rede necessita aprimoramento em aprendizado profundo para melhoria de desempenho, robustez e eficiência do modelo (LI et al., 2020). O algoritmo YOLOv8 foi utilizado no presente trabalho para segmentar as imagens.

2.5. Aplicações na predição de características de carcaça

A pecuária de precisão é um sistema para monitorar e gerenciar a produção pecuária que se concentra em melhorar o bem-estar animal e otimizar a produção pecuária. Desta maneira, a tarefa da determinação de características de animais, dentro deste contexto, tem sido um dos desafios para o desenvolvimento da pecuária com o desenvolvimento da visão computacional e, conseqüentemente, da pecuária de precisão. Usar métodos alternativos, de baixo custo e sem contato de aquisição de máquinas para substituir a observação humana de animais sem perturbar seu comportamento normal tornou-se um estímulo para o desenvolvimento de pesquisa. Muitos pesquisadores estão utilizando processamento de imagem para obter precisão em rebanhos (BERCKMANS et al. 2014). CHEN et al. (2021), também observaram que eficácia da segmentação de imagens influencia diretamente na precisão da extração de características e visão computacional.

A ultrassonografia é um método eficiente na avaliação da área de olho de lombo, onde, de acordo com os dados obtidos, essa medida mensurada por ultrassonografia *in vivo* foi altamente ($P < 0,001$) correlacionada com a mesma medida na carcaça pós-abate, demonstrando ser um método eficaz de predição. Vale destacar ainda que essa técnica tem sido bastante utilizada para predizer a composição da carcaça dos animais, o grau de musculosidade da carcaça que pode ser obtido pela medida da área de olho de lombo (AOL), o teor de gordura (EGS e Marmoreio), o rendimento dos cortes cárneos e o escore corporal dos animais (SANTOS et al., 2018).

Neste contexto, a AOL medida entre as 12^a e 13^a vértebra do músculo *Longissimus dorsi* possui relação positiva com a composição corporal de animais, pois determina o conteúdo do músculo de cada animal e, assim, obtendo considerável influência no estudo do preço final da carne e classificação da carcaça (CEZAR E SOUSA, 2007).

Já a espessura de gordura subcutânea (EGS) é mensurada acima do músculo que evita o enrijecimento e escurecimento da carne tendo influência na qualidade da carne. Onde, a gordura atua como isolante térmico e protetor dos músculos dos efeitos negativos do resfriamento e ainda possibilita que ela resfrie de forma lenta, dentro dos limites aceitáveis, não ocasionando, assim, no encurtamento das fibras musculares (*cold shortening*), melhorando a maciez da carne e a durabilidade da carne. O conhecimento dessas medidas na criação de animais possibilita a formação de lotes de animais padronizados com base na separação de animais com potencial genético para ganho de peso e grau de acabamento de carcaça (SOUZA et al., 2016).

Vale ressaltar que, uma EGS entre 2 e 3 mm evita redução do peso da carcaça, queda rápida na temperatura da mesma e escurecimento da carne durante o resfriamento, possibilitando uma melhor visualização dos cortes bovinos e suas características sensoriais (MOREIRA et al., 2018; SUGUISAWA et al., 2006; GOIS et al., 2005).

Outra característica da carcaça é o grau de marmoreio que confere qualidade ao produto, já que é correlacionada positivamente com a maciez e a suculência da carne. Além disso, carcaças com características superiores de qualidade (maior grau de acabamento e marmoreio, por exemplo) podem ser direcionadas para mercados específicos e obter maior remuneração aos produtores (DU et al., 2013).

CAFFARINI et al. (2022), no estudo de bovinos, para determinação de AOL utilizando redes neurais, encontrou um R^2 de 0,74, indicando que os sistemas de visão computacional podem ser usados para prever a área olho de lombo em animais vivos, permitindo decisões de manejo ideais em direção ao agrupamento inteligente de animais em cruzamentos. Estes autores relataram estudos de predição para a área de olho de lombo utilizando imagens ultrassonográficas de bovinos utilizando o algoritmo ResNet (HE et al., 2016) e pelo algoritmo U-Net (RONNEBERG et al., 2015) com alto desempenho.

HU et al. (2020), também para detectar bovinos em imagens, aplicaram o modelo YOLO e então obtiveram a identificação de vacas usando uma rede neural convolucional e uma máquina de vetor de suporte (SVM) para avaliar a qualidade de segmentação de imagens dos animais em estudo.

QIAO et al. (2019) propuseram um modelo R-CNN que utiliza a ResNet-101 (um ResNet de 101 camadas) para extrair características e uma rede neural secundária para segmentar os corpos de bovinos adultos de imagens RGB (*Red-Green-Blue*) atingindo uma precisão de 92%.

ZHAO et al. (2023) relataram que a segmentação de ovinos terá um papel crucial na promoção da implementação da pecuária de precisão no futuro, o qual em seus estudos observaram uma precisão de 90%, é importante ressaltar que de acordo com estes autores nas fazendas, as características das ovelhas que têm a tendência de se aglomerar e contornos irregulares nas imagens causam dificuldades para tarefas de visão computacional, como identificação individual, reconhecimento de comportamento e estimativa de peso das ovinos.

Ainda no estudo da estimativa de peso de ovinos, HE et al. (2023), utilizaram, sucessivamente, detecção e segmentação semântica para obter dados mais eficazes da região das ovelhas para estimativa de peso. SANTANA et al. (2021) e SANTANA et al. (2022) também encontraram resultados precisos e robustos utilizando a segmentação de imagens para predição de peso de ovelhas Santa Inês com a rede *ResNet* e *VGG*, fornecendo uma metodologia não invasiva que pode dar suporte a outras implementações como rastreamento de animais e predição de peso.

Sendo assim, de posse dos resultados da segmentação de imagens, torna-se possível extrair características corporais de ovinos com precisão, trazendo robustez e otimização para as coletas de dados em campo. Entretanto, a ovinocultura de corte aliada a pecuária de precisão ainda possui vários desafios.

2.6. Desafios e perspectivas futuras

A importância da Pecuária de Precisão cresceu globalmente, sendo um sistema de monitoramento e gerenciamento da produção animal com o intuito de melhorar o bem-estar animal e otimizar a produção pecuária, aplicando visão computacional na análise de dados, melhorando a eficiência de produção e reduzindo custos. Entretanto o setor enfrenta algumas limitações (GARCÍA et al., 2020).

Um dos principais desafios relatados por ZHAO et al. (2023) é atingir um bom desempenho de segmentação utilizando uma pequena quantidade de dados, além de que os dados ainda são registrados manualmente, portanto busca-se a automatização da tarefa de segmentação obtendo maior desempenho do modelo com menos custo de mão de obra.

Além disso, STEFANOVA et al. (2019) afirmam que a maioria dos dados coletados nas propriedades estão em *notebooks* ou em um sistema de informação zootécnica e que se torna necessária a digitalização automática de todos os dados de uma propriedade no contexto da pecuária de precisão, com menos gasto de energia, mesclando dados de diversas fontes, reduzindo dimensões em imagens, além de compactando dados.

Desta maneira, o uso de algoritmos inteligentes otimizados que trabalham com dados comprimidos diminui o consumo de energia, dentro do contexto da pecuária de precisão, assim como diminuir a quantidade de dados para análise, melhorando assim a vida útil da bateria da máquina (DEBAUCHE et al. 2019).

VAN HERTEM et al. (2017) também relatam que é fundamental a visualização adequada dos dados, pelos pecuaristas, ou seja, de fácil visualização e compreensão. Desta maneira, conclui-se que uma interface otimizada, para a apresentação correta e clara dos dados, é fundamental nas coletas.

CAFFARINI et al. (2022) e LIMA JÚNIOR et al. (2024) ainda afirmam que é necessária a coleta de novos fenótipos da perspectiva de gerenciamento e melhoramento genético aliados a fenotipagem de precisão, que podem ser implementados nos dados em campo. Sendo assim, a coleta terá um resultado mais preciso com a maior quantidade de informações contribuindo assim para uma melhor escrituração zootécnica na cadeia de produção.

3. Conclusões

Os algoritmos de visão computacional são ferramentas importantes para automatizar a predição de características de carcaça em ovinos a partir de imagens ultrassonográficas com uma maior precisão e robustez, contribuindo para otimização do processo de coleta de dados de carcaça, facilitando o trabalho do técnico de campo e agilizando o retorno de informações ao produtor.

Para isso, torna-se necessário que a pesquisa invista na formação de pessoal qualificado para o desenvolvimento de ferramentas de fácil uso para uso na coleta de mais dados da carcaça ovina, melhorando assim a produção e fortalecendo a fenotipagem de precisão. Além disso é fundamental, a criação de uma ferramenta computacional que permita fácil visualização pelo produtor das informações geradas, facilitará o manejo e a seleção na propriedade.

Referências Bibliográficas

- ABDULATEEF, SK. et al. A Comprehensive Review of Image Segmentation Techniques. **Iraqi Journal for Electrical & Electronic Engineering**, v.17, p.166-175. 2021. Available from: <<https://doi.org/10.37917/ijeee.17.2.18>>. Accessed: Apr. 14, 2025. doi: 10.37917/ijeee.17.2.18.
- ALBATINEH, AN.; NIEWIADOMSKA-BUGAJ, M. Correcting Jaccard and other similarity indices for chance agreement in cluster analysis. **Advances in Data Analysis and Classification**, v.5, p.179–200, 2011. Available from: <<https://doi.org/10.1007/s11634-011-0090-y>>. Accessed: Nov. 19, 2024. doi: 10.1007/s11634-011-0090-y.
- ANTTALAINEN, A. et al. Predicting lecithin concentration from differential mobility spectrometry measurements with linear regression models and neural networks. **Talanta**, v.225, p.121926, 2021. Available from: <<https://doi.org/10.1016/j.talanta.2020.121926>>. Accessed: Apr. 14, 2025. doi: 10.1016/j.talanta.2020.121926.
- ARNAB, A. et al. Conditional Random Fields Meet Deep Neural Networks for Semantic Segmentation: Combining Probabilistic Graphical Models with Deep Learning for Structured Prediction. **IEEE Signal Processing Magazine**, v.35, p.37-52, 2018. Available from: <https://doi.org/10.1109/MSP.2017.2762355>. Accessed: Nov. 19, 2024. doi: 10.1109/MSP.2017.2762355.
- AZEREDO, DM. et al. Crescimento e desenvolvimento de ovinos Corriedale não castrados, castrados e criptorquidas abatidos com diferentes pesos. **Revista Brasileira de Agrociências**, 11, 339- 345. 2005. Available from: <<https://doi.org/10.18539/CAST.V11I3.1244>>. Accessed: Jan. 27, 2025. doi: 10.18539/CAST.V11I3.1244
- BACKES, AR.; SÁ JUNIOR, JJM. **Introdução à visão computacional usando Matlab**. Rio de Janeiro: Alta Books Editora, 2019. 288p.
- BERCKMANS D. Precision livestock farming technologies for welfare management in intensive livestock systems. **Revue Scientifique et Technique**, v.33, p.189–196. 2014. Available from: <<https://doi.org/10.20506/rst.33.1.2273>>. Accessed: Jan. 27, 2025. doi: 10.20506/rst.33.1.2273.
- BERIAIN, MJ. et al. Effectiveness of using ultrasound readings to predict carcass traits and sensory quality in young bulls. **Computers and Electronics in Agriculture**, v.183, p.106060. 2021. Available from: <<https://doi.org/10.1016/j.compag.2021.106060>>. Accessed: Jan. 27, 2025. doi: 10.1016/j.compag.2021.106060.

- BERSET, CM. et al. Federation of European Laboratory Animal Science Associations recommendations of best practices for the health management of ruminants and pigs used for scientific and educational purposes. **Laboratory Animals**, v.55, p.117-128. 2021. Available from: <<https://doi.org/10.1177/0023677220944461>>. Accessed: Feb. 27, 2025. doi: 10.1177/0023677220944461.
- BOERNER, V. et al. Accuracy of Igenity genomically estimated breeding values for predicting Australian Angus BREEDPLAN traits. **Journal Animal Science**, 93, 13-21. 2015. Available from: <<https://doi.org/10.2527/jas.2014-8357>>. Accessed: Jan. 25, 2025. doi: 10.2527/jas.2014-8357.
- BOO, J. et al. Reduction Strategies in Animal Research: A Review of Scientific Approaches at the Intra-experimental, Supra-experimental and Extra-experimental Levels. **Alternatives to Laboratory Animals**, v.33, p.369-377, 2005. Available from: <<https://doi.org/10.1177/026119290503300404>>. Accessed: Jan. 08, 2025. doi: 10.1177/026119290503300404.
- CEZAR, MF.; SOUSA, WH. **Carcças ovinas e caprinas - Obtenção, avaliação e classificação**. Uberaba: Editora Agropecuária Tropical. 2007. 231p.
- CHANDRA, MA. et al. Survey on SVM and their application in image classification. **International Journal of Information Technology**, v.13, p.1–11, 2021. Available from: <<https://doi.org/10.1007/s41870-017-0080-1>>. Accessed: Jan. 06, 2025. doi: 10.1007/s41870-017-0080-1.
- CHEN, C. et al. Behaviour recognition of pigs and cattle: Journey from computer vision to deep learning. **Computers and Electronics in Agriculture**, v.187, p.106255. 2021. Available from: <<https://doi.org/10.1016/j.compag.2021.106255>>. Accessed: Jan. 27, 2025. doi: 10.1016/j.compag.2021.106255.
- CHICCO, D. et al. The coefficient of determination rsquared is more informative than smape, mae, mape, mse and rmse in regression analysis evaluation. **PeerJ Computer Science**, v.7, p.e623, 2021. Available from: <<https://doi.org/10.7717/peerj-cs.623>>. Accessed: Apr. 16, 2025. doi: 10.7717/peerj-cs.623.
- CLELLAND, N. Prediction of intramuscular fat levels in Texel lamb loins using X-ray computed tomography scanning. **Meat Science**, v.98, p.263-271, 2014. Available from: <<https://doi.org/10.1016/j.meatsci.2014.06.004>>. Accessed: Jan. 27, 2025. doi: 10.1016/j.meatsci.2014.06.004.
- DAMY, SB. et al. Aspectos fundamentais da experimentação animal - aplicações em cirurgia experimental. **Revista da Associação Médica Brasileira**, v.56, p.103-111.

2010. Available from: <<https://doi.org/10.1590/S0104-42302010000100024>>. Accessed: Nov. 20, 2024. doi: 10.1590/S0104-42302010000100024.

DEBAUCHE, O. et al. Cloud services integration for farm animals' behavior studies based on smartphones as activity sensors. **Journal of Ambient Intelligence and Humanized Computing**, v.10, p.4651-4662. 2019. Available from: <<https://doi.org/10.1007/s12652-018-0845-9>>. Accessed: Jan. 28, 2025. Doi: 10.1007/s12652-018-0845-9.

DICE, LR., 1945. Measures of the Amount of Ecologic Association Between Species. **Ecology**, v.26, p.297-302. Available from: <<https://doi.org/10.2307/1932409>>. Accessed: Nov. 20, 2024. doi: 10.2307/1932409.

DU, M. et al Meat science and muscle biology symposium: Manipulating mesenchymal progenitor cell differentiation to optimize performance and carcass value of beef cattle. **Journal of Animal Science**, v.91, p.1419–1427, 2013. Available from: <<https://doi.org/10.2527/jas.2012-5670>>. Accessed: Nov. 25, 2024. doi: 10.2527/jas.2012-5670.

FONT-I-FURNOLS, M. et al. Intramuscular fat content in different muscles, locations, weights and genotype-sexes and its prediction in live pigs with computed tomography. **Animal**, v.13, p.666-674. 2019. Available from: <<https://doi.org/10.1017/S1751731118002021>>. Accessed: Jan. 25, 2025. doi: 10.1017/S1751731118002021.

GARCÍA, R. et al. A systematic literature review on the use of machine learning in precision livestock farming. **Computers and Electronics in Agriculture**, v.179, p.105826. 2020. Available from: <<https://doi.org/10.1016/j.compag.2020.105826>>. Accessed: Jan. 25, 2025. doi: 10.1016/j.compag.2020.105826.

GOMES, MB. et al. Prediction of carcass composition through measurements in vivo and measurements of the carcass of growing Santa Inês sheep. **Plos One**, v.16, p.e0247950. 2021. Available from: <<https://doi.org/10.1371/journal.pone.0247950>>. Accessed: Jan. 27, 2025. doi: 10.1371/journal.pone.0247950.

GONZALEZ, RC. **Digital image processing**. India: Pearson education, 2009. 4v.

HASHIMOTO, JH. et al. Carcass quality, parts and tissue development of lambs finished in three systems. **Revista Brasileira De Zootecnia**, v.41, p.438–448. 2012. Available from: <<https://doi.org/10.1590/S1516-35982012000200029>>. Accessed: Nov. 20, 2024. doi: 10.1590/S1516-35982012000200029.

- HE, K. et al. Deep residual learning for image recognition. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**, p. 770–778, 2016. Available from: <<https://doi.org/10.48550/arXiv.1512.03385>>. Accessed: Jan. 08, 2025. doi: 10.48550/arXiv.1512.03385
- HESAMIAN M. H. et al. Deep Learning Techniques for Medical Image Segmentation: Achievements and Challenges. **Journal of Digital Imaging**, v.32, p.582–596. 2019. Available from: <<https://doi.org/10.1007/s10278-019-00227-x>>. Accessed: Jan. 27, 2025. doi: 10.1007/s10278-019-00227-x.
- JIMENEZ-SANZ, A. et al. Relação entre fatores associados às parasitoses gastrointestinais, desempenho e estado fisiológico de ovelhas Santa Inês. **Agropecuária Técnica**, v.37, p.88–95, 2016. Available from: <<https://doi.org/10.25066/agrotec.v37i1.25170>>. Accessed: Jan. 08, 2025. doi: 10.25066/agrotec.v37i1.25170.
- LI ST. et al. Aprendizado profundo para classificação de imagens hiperespectrais: uma visão geral. **Ieee Transactions on Geoscience and Remote Sensing**, v.57, p.6690–6709. 2019. Available from: <<https://doi.org/10.1109/TGRS.2019.2907932>>. Accessed, Jan. 27, 2025. doi: 10.1109/TGRS.2019.2907932.
- LI, X. et al. Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection. **Advances in Neural Information Processing Systems**, v.33, p.21002–21012, 2020. Available from: <<https://doi.org/10.48550/arXiv.2006.04388>>. Accessed: Nov. 21, 2024. doi: 10.48550/arXiv.2006.04388.
- LIMA JÚNIOR, FA. et al. Prediction of carcass rib eye area by ultrasound images in sheep using computer vision. **Ciência Rural**, v.54, p. e20230576, 2024. Available from: <<https://doi.org/10.1590/0103-8478cr20230576>>. Accessed: Nov. 21, 2024. Epub 10-Jun-2024. doi: 10.1590/0103-8478cr20230576.
- LIRA, AB. et al. Desempenho e características de carcaça de dois biótipos de ovinos da raça Santa Inês terminados a pasto suplementados com blocos multinutricionais. **Revista Brasileira De Saúde E Produção Animal**, v.18, p.313–326, 2017. Available from: <<https://doi.org/10.1590/S1519-99402017000200010>>. Accessed: Nov. 21, 2024. doi: 10.1590/S1519-99402017000200010.
- LONG, J. et al. Fully Convolutional Networks for semantic segmentation. **IEEE Conference of Vision and Pattern Recognition (CVPR)**, Boston, p.3431–3440, 2015. Available from: <<https://doi.org/10.48550/arXiv.1411.4038>>. Accessed: Nov. 21, 2024. doi: 10.48550/arXiv.1411.4038.

- LÓPEZ, GL. et al. Comparative analysis of shape descriptors for 3D objects. **Multimedia Tools and Applications**, v.76, p.6993–7040. 2017. Available from: <<https://doi.org/10.1007/s11042-016-3330-5>>. Accessed: Apr. 14, 2025. doi: 10.1007/s11042-016-3330-5.
- MAGGIORI, E. et al. Convolutional Neural Networks for Large-Scale Remote-Sensing Image Classification. **IEEE Transactions on Geoscience and Remote Sensing**, v.55, p.645-657, 2017. Available from: <<https://doi.org/10.1109/TGRS.2016.2612821>>. Accessed: Jan. 09, 2025. doi: 10.1109/TGRS.2016.2612821.
- MARENGONI, M.; STRINGHINI, S. Tutorial: Introdução a visão computacional usando OpenCV. **Revista de Informática Teórica e Aplicada**, v.16, p.125-160, 2010. Available from: <<https://doi.org/10.22456/2175-2745.11477>>. Accessed: Nov. 21, 2024. doi: 10.22456/2175-2745.11477.
- MASOOD, S. et al. A survey on medical image segmentation. **Current Medical Imaging**, v.11, p.3–14, 2015. Available from: <<https://doi.org/10.2174/157340561101150423103441>>. Accessed: Nov. 21, 2024. doi: 10.2174/157340561101150423103441.
- MCMANUS, C. et al. Avaliação ultrasonográfica da qualidade de carcaça de ovinos Santa Inês. **Ciência Animal Brasileira**, v.14, p.8–16. 2013. Available from: <https://doi.org/10.5216/cab.v14i1.12336>. Accessed: Nov. 25, 2024. doi: 10.5216/cab.v14i1.12336.
- MINAEE, S. et al. Image segmentation using deep learning: A survey. **IEEE transactions on pattern analysis and machine intelligence**, v.44, p.3523-3542, 2021. Available from: <<https://doi.org/10.48550/arXiv.2001.05566>>. Accessed: Apr. 14, 2025. doi: 10.48550/arXiv.2001.05566.
- MOREIRA, AD. et al. Castration methods in crossbred cattle raised on tropical pasture. **Animal Production Science**, v.58, p.1307-1315. 2018. Available from: <<https://doi.org/10.1071/AN16580>>. Accessed: Nov. 21, 2024. doi: 10.1071/AN16580.
- MUMFORD, D.; SHAH, J. Optimal Approximations by Piecewise Smooth Functions and Associated Variational Problems. **Communications on Pure and Applied Mathematics**, v.42, p.577-685. 1989. Available from: <<https://doi.org/10.1002/cpa.3160420503>>. Accessed: Nov. 21, 2024. doi: 10.1002/cpa.3160420503.
- OSÓRIO, JCS. et al. Características sensoriais da carne ovina. **Revista Brasileira De Zootecnia**, v.38, p.292–300. 2009. Available from: <<https://doi.org/10.1590/S1516->

35982009001300029>. Accessed: Jan. 08, 2025. doi: 10.1590/S1516-35982009001300029.

PAULING, RC. et al. Parâmetros genéticos para pressão arterial pulmonar, desempenho de um ano e características de ultrassom de carcaça em gado Angus. **Journal of Animal Science**, v.101, p.skad288. 2023. Available from: <<https://doi.org/10.1093/jas/skad288>>. Accessed: Jan. 25, 2025. doi: 10.1093/jas/skad288.

POIRIER, GM. et al. ESLAV/ECLAM/LAVA/EVERI recommendations for the roles, responsibilities and training of the laboratory animal veterinarian and the designated veterinarian under Directive 2010/63/EU. **Laboratory Animal**, v.49, p.89-99. 2015. Available from: <<https://doi.org/10.1177/0023677214557717>>. Accessed: Feb. 27, 2025. doi: 10.1177/0023677214557717.

QIAO, Y. et al. Segmentação de gado e extração de contorno com base em máscara R-CNN para pecuária de precisão. **Computers and Electronics in Agriculture**, v.165, p.104958. 2019. Available from: <<https://doi.org/10.1016/j.compag.2019.104958>>. Accessed: Jan. 27, 2025. doi: 10.1016/j.compag.2019.104958.

RIPOLL, G. et al. Estimation of carcass composition by ultrasound measurements in 4 anatomical locations of 3 commercial categories of lamb. **Journal of Animal Science**, v.88, p.3409-3418. 2010. Available from: <<https://doi.org/10.2527/jas.2009-2632>>. Accessed: Jan. 27, 2025. doi: 10.2527/jas.2009-2632.

RONNEBERGER, O. et al. U-Net: Convolutional Networks for Biomedical Image Segmentation. **Medical Image Computing and Computer-Assisted Intervention (MICCAI)**, v.9351, p.234-241, 2015. Available from: <<https://doi.org/10.48550/arXiv.1505.04597>>. Accessed: Nov. 22, 2024. doi: 10.48550/arXiv.1505.04597.

SAMPATH, V. et al. A survey on generative adversarial networks for imbalance problems in computer vision tasks. **Journal of big Data**, v.8, p.1-59, 2021. Available from: <<https://doi.org/10.1186/s40537-021-00414-0>>. Accessed: Apr. 14, 2025. doi: 10.1186/s40537-021-00414-0.

SANTOS, ACP. et al. Métodos de avaliação de carcaça e de carne dos animais através de predições in vivo e post mortem – revisão de literatura. **Revista Científica de Medicina Veterinária**, v..30, p.1-21, 2018. Available from: <<https://pesquisa.bvsalud.org/portal/resource/pt/biblio-1494289>>. Accessed: Nov. 22, 2024.

- SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. **Information Processing and Management**, v.45, p.427–437, 2009. Available from: <<https://doi.org/10.1016/j.ipm.2009.03.002>>. Accessed: Nov. 22, 2024. doi: 10.1016/j.ipm.2009.03.002.
- SORENSEN, T., 1948. A method of establishing groups of equal amplitude in plant sociology based on similarity of species and its application to analyses of the vegetation on Danish commons. In... **Biologiske skrifter**, 3 ed., Munksgaard in Komm, 1948. v.5, p.1-34, 34p.
- SOUZA, SF. et al. Aplicação da ultrassonografia para avaliação de condição corporal e acabamento de carcaça em pequenos ruminantes. **Ciência Veterinária nos Trópicos**, v.19, p.34–42, 2016. 143p.
- STEFANOVA, M. Precision poultry farming: software architecture framework and online zootechnical diary for monitoring and collaborating on hens' health. **Springer International Publishing**, v.953, p.191-205. 2019. Available from: <https://doi.org/10.1007/978-3-030-12998-9_14>. Accessed: Jan. 28, 2025. doi: 10.1007/978-3-030-12998-9_14.
- SUGUISAWA, L. et al. Ultra-sonografia para predição da composição da carcaça de bovinos jovens. **Revista Brasileira de Zootecnia**, v.35, p.177-185. 2006. Available from: <<https://doi.org/10.1590/S1516-35982006000100023>>. Accessed: Nov. 22, 2024. doi: 10.1590/S1516-35982006000100023.
- SUGUISAWA, L. et al. Uso da ultrassonografia na avaliação de características de carcaça e de qualidade da carne. **Melhoramento genético aplicado em gado de corte**. Brasília, DF: Embrapa; 2013. p.97-107.
- TAROUCO, JU., et al. 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**, v.34, p.2074-2084. 2005. Available from: <<https://doi.org/10.1590/S1516-35982005000600033>>. Accessed: Jan. 25, 2025. doi: 10.1590/S1516-35982005000600033.
- TEIXEIRA, IAM. et al.. Inovações tecnológicas na caprinocultura. **Revista Brasileira de Saúde e Produção Animal**, v.14, p.104–120, 2013. Available from: <<https://www.scielo.br/j/rbspa/a/MNyt9zZhztWxmmCbMTkr5KM>>. Accessed Nov. 20, 2024.
- VAN HERTEM, T. et al. Appropriate data visualisation is key to Precision Livestock Farming acceptance. **Computers and electronics in agriculture**, v.138, p.1-10. 2017.

Available from: <<https://doi.org/10.1016/j.compag.2017.04.003>>. Accessed: Jan. 28, 2025. doi: 10.1016/j.compag.2017.04.003.

VOIPIO, HM. et al. Guidelines for the veterinary care of laboratory animals: report of the FELASA/ECLAM/ESLAV Joint Working Group on Veterinary Care. **Laboratory Animal**, v.42, p.1-11. 2008. Available from: <<https://doi.org/10.1258/la.2007.007027>>. Accessed: Feb. 27, 2025. doi: 10.1258/la.2007.007027.

XU, B. et al. Intelligent weight prediction of cows based on semantic segmentation and back propagation neural network. **Frontiers Artificial Intelligence**, v.7: p.1-18. 2024. Available from: <<https://doi.org/10.3389/frai.2024.1299169>>. Accessed: Jan. 27, 2025. doi: 10.3389/frai.2024.1299169.

YU, L. et al. A Lightweight Neural Network-Based Method for Detecting Estrus Behavior in Ewes. **Agriculture**, v.12, p.1207. 2022. Available from: <<https://doi.org/10.3390/agriculture12081207>>. Accessed: Jan. 27, 2025. doi: 10.3390/agriculture12081207.

ZHAO, H. et al. SheepInst: A High-Performance Instance Segmentation of Sheep Images Based on Deep Learning. **Animals**, v.13, p.1338. 2023. Available from: <<https://doi.org/10.3390/ani13081338>>. Accessed: Jan. 27, 2025. doi: 10.3390/ani13081338.

CAPÍTULO II

Predição da Espessura de Gordura Subcutânea por meio do reconhecimento de imagens ultrassonográficas utilizando algoritmos de visão computacional

Predição da Espessura de Gordura Subcutânea em ovinos de corte por meio do reconhecimento de imagens ultrassonográficas utilizando algoritmos de visão computacional

Francisco Albir Lima Júnior^{a,*}, José Weyner Rodrigues Farias^b, Natanael Pereira da Silva Santos^c, Daniel Biagiotti^d, Débora Araújo de Carvalho^e, Gleyson Vieira dos Santos^e, João Vitor Moreira Passos^f, Romuere Rodrigues Veloso e Silva^f José Lindenberg Rocha Sarmiento^c

^a Programa de Pós-Graduação em Zootecnia, Centro de Ciências Agrárias, Universidade Federal do Piauí, Campus Universitário Ministro Petrônio Portella, Bairro Ininga, 64049-550, Teresina, PI, Brasil.

^b Zootecnista

^c Departamento de Zootecnia, Centro de Ciências Agrárias, Universidade Federal do Piauí, Campus Universitário Ministro Petrônio Portella, Bairro Ininga, 64049-550, Teresina, PI, Brasil.

^d Docente Colégio Técnico de Teresina – UFPI

^e Universidade Estadual do Piauí (UESPI), Teresina, PI, Brasil

^f Universidade Federal do Piauí (UFPI), Picos, PI, Brasil.

*Autor correspondente.

Endereços de e-mail: albirjunior@hotmail.com (F.A. Lima Júnior)

Resumo: A ovinocultura é uma atividade pecuária presente em todos os continentes, em que, o mercado consumidor exige carne de boa qualidade. Sendo assim, a espessura de gordura subcutânea do músculo *Longissimus dorsi* (EGS) é importante, pois é positivamente correlacionada com a qualidade da carne. A determinação em animais vivos pode ser realizada por profissional com o auxílio de ultrassom para obter medidas, o que torna o processo de mensuração laborioso, o que dificulta o retorno desta medida para o produtor. Portanto, o objetivo com esta pesquisa foi predizer a espessura de gordura subcutânea por meio do reconhecimento de imagens de ultrassom utilizando ferramentas de visão computacional. Foram coletadas 263 imagens ultrassonográficas do músculo supracitado em ovinos de corte. A medida EGS foi registrada em mm utilizando ultrassom por profissional treinado. As imagens coletadas foram levadas para anotação e, em seguida, compiladas para processamento e extração da medida EGS com o *software ImageJ*. O conjunto de imagens foi dividido em imagens originais e imagens com a medida de EGS (máscaras de segmentação) para encontrar a região de interesse nas imagens com dimensão padronizada (224-224-3 pixels). Durante a segmentação, a rede YOLOv8 foi usada para processar e ajustar as imagens, enquanto os algoritmos, VGG e ResNet foram usados para validar e apresentar os resultados. O conjunto de imagens foi dividido entre treinamento do algoritmo (80%), validação (10%) e teste (10%). As métricas de precisão, mAP50 e *recall* foram usadas para verificar a similaridade entre os dois conjuntos de imagens. Para estimar as medidas de EGS a partir dos descritores da rede neural, ou seja, as características que a rede extrai de uma imagem ou vetor de características das imagens segmentadas, três regressores foram usados: Adabooster (ABR), Random Forest (RFR) e GradientBoosting (GBR). Para avaliar a qualidade de ajuste da regressão, foram calculados o quadrado médio dos resíduos (QMR), erro médio absoluto (EMA) e coeficiente de determinação de regressão (R^2). Para comparar as

médias reais e previstas de EGS, foi realizada análise de variância e teste t de Student a 5% de probabilidade. Dentre os regressores utilizados, o RFR foi o que apresentou melhor desempenho utilizando os algoritmos citados, demonstrando a robustez deste regressor. A similaridade entre o conjunto de imagens do especialista e do algoritmo foi avaliada, obtendo uma precisão de 0,74, um mAP50 de 0,78, e um *recall* de 0,75, verificando similaridade entre as imagens do especialista e do algoritmo. As médias previstas pela ferramenta e as encontradas pelo especialista não apresentaram diferenças significativas ($p > 0,05$). Os valores preditos apresentaram menor variância que os valores medidos, o que confirma maior precisão na medida predita com a ferramenta utilizada. Portanto, a mensuração automática desta medida pela ferramenta proposta a partir de imagens ultrassonográficas é promissora. Além disso, o método possibilita a análise de uma grande quantidade de imagens em curto espaço de tempo, o que garante retorno mais rápido da informação para o produtor de ovinos. Entretanto, devido ao baixo ajustamento da equação aos dados, torna-se necessário a coleta de mais imagens em campo, afim de fortalecer a fenotipagem de ovinos.

Palavras-chave: Carcaça, Inteligência Artificial, Produção de Carne, Random Forest, Yolov8.

Abstract: Sheep farming is a livestock activity present on all continents, in which the consumer market demands good quality meat. Therefore, the subcutaneous fat thickness of the Longissimus dorsi muscle (SFT) is important, as it is positively correlated with meat quality. The determination in live animals can be performed by a professional with the aid of ultrasound to obtain measurements, which makes the measurement process laborious, which makes it difficult to return this measurement to the producer. Therefore, the objective of this research was to predict the subcutaneous fat thickness through the recognition of ultrasound images using computer vision tools. A total of 358 ultrasound images of the aforementioned muscle were collected in meat sheep. The SFT measurement was recorded in mm using ultrasound by a trained professional. The collected images were taken for annotation and then compiled for processing and extraction of the SFT measurement with the ImageJ software. The image set was divided into original images and images with the SFT measure (segmentation masks) to find the region of interest in the images with standardized dimension (224-224-3 pixels). During segmentation, the Yolov8 network was used to process and adjust the images, while the VGG and ResNet algorithms were used to validate and present the results. The image set was divided between algorithm training (80%), validation (10%) and testing (10%). The precision metrics, mAP50 and recall were used to verify the similarity between the two image sets. To estimate the SFT measures from the neural network descriptors, that is, the features that the network extracts from an image or feature vector of the segmented images, three regressors were used: Adabooster (ABR), Random Forest (RFR) and GradientBoosting (GBR). To assess the regression fit quality, the mean square error (MSE), mean absolute error (MAE) and regression coefficient of determination (R^2) were calculated. To compare the real and predicted SFT means, analysis of variance and Student's t-test at 5% probability were performed. Among the regressors used, RFR was the one that presented the best performance using the aforementioned algorithms, demonstrating the robustness of this regressor. The similarity between the set of images from the expert and the algorithm was evaluated, obtaining a precision of 0.74, a mAP50 of 0.78, and a recall of 0.75, verifying similarity between the images from the expert and the algorithm. The means predicted by the tool and those found by the expert showed no significant differences ($p > 0.05$). The predicted values presented lower variance than the measured values, which confirms greater precision in the measurement predicted with the

tool used. Therefore, the automatic measurement of this measurement by the proposed tool from ultrasound images is promising. Furthermore, the method enables the analysis of a large number of images in a short space of time, which ensures faster return of information to the sheep producer. However, due to the low adjustment of the equation to the data, it is necessary to collect more images in the field in order to strengthen sheep phenotyping.

Keywords: Artificial Intelligence, Carcass, Meat Production, Random Forest, YOLOv8.

1. Introdução

A ovinocultura tem se destacado de maneira positiva devido a qualidade de seus produtos e a capacidade dos ovinos se adaptarem aos mais diversos tipos de climas devido a rusticidade da espécie e a ampla difusão desses animais ocorre devido à rusticidade e a adaptabilidade da espécie aos diferentes ecossistemas (SANTOS e BORGES, 2019). Esta atividade está em constante expansão e, com isso, aumenta-se também a necessidade de informações sobre seus produtos, dado o perfil mais exigente dos consumidores por produtos de maior qualidade (JIMENEZ-SANZ et al., 2016).

No Brasil, encontram-se presente em torno de 21 milhões de ovinos, sendo o Nordeste a região com maior número de animais. Entretanto, a produção de carne ovina, no decorrer dos anos ainda é baixa, principalmente pela ausência de informações para tomadas de decisão, aliado a deficiência dos diferentes manejos, além da falta de avaliações rotineiras de características de carcaça para fins de seleção genética (LIRA et al., 2017).

A alimentação, a genética e o ambiente de criação também influenciam na qualidade das carcaças dos animais. A falta de uniformização das carcaças, oriunda da variação genética e irregularidade da oferta devido ao sistema de alimentação a que os animais são submetidos, caracterizam-se como os principais fatores que dificultam o atendimento da demanda crescente por carne ovina de qualidade. Sendo assim, a avaliação de carcaça é essencial para buscar a padronização, por meio de seleção e manejo alimentar. Na avaliação de carcaça, uma medida mensurada é a Espessura da Gordura Subcutânea (EGS), a qual evita o enrijecimento e escurecimento da carne e protege o produto contra os efeitos prejudiciais do processo de resfriamento (SOUZA et al., 2016).

Assim, o conhecimento desta medida é essencial na rotina das fazendas para orientar a seleção e manejo nutricional. Todavia, a sua determinação em animais vivos deve ser realizada por especialista com o auxílio de ultrassom e softwares auxiliares na avaliação de imagens, o que torna o processo de mensuração laborioso, o que dificulta a sua determinação de rotineira. Com intuito de contribuir com avanços na mensuração da

medida de EGS, o uso de tecnologias de precisão que possam automatizar a medição a partir de imagens ultrassonográficas pode ser um fator determinante para a rotina das fazendas. Dentre estas tecnologias, destacamos a visão computacional, cujo objetivo é obter características a partir de imagens e interpretá-las. O intuito é processar e analisar de forma efetiva as imagens obtidas de forma a extrair, quantificar e analisar essas informações para obter compreensão e percepção sobre a imagem em estudo (SILVA et al., 2019).

A visão computacional também pode ser utilizada para avaliar características da carcaça de animais, como a espessura de gordura, por meio do reconhecimento de imagens ultrassonográficas do músculo *Longissimus dorsi*, entre as 12^a e 13^a vértebras do animal. A visão computacional, nesse contexto, fornece estimativas precisas de medidas da carcaça, otimizando a medição em campo e aumentando a eficiência do processo de seleção. Através das medidas extraídas pelo especialista utilizando o ultrassom pode-se desenvolver uma ferramenta para prever as medidas de interesse a partir do reconhecimento dessas imagens por algoritmos (LIMA JÚNIOR et al., 2024).

Neste sentido, VAN HERTEM et al. (2017) afirmam que se faz necessário a construção de uma ferramenta de fácil manuseio e visualização pelos produtores de ovinos, além de uma demonstração clara e objetiva dos resultados pelas ferramentas. STEFANOVA et al. (2019) e DEBAUCHE et al. (2019) ainda enfatizaram que é importante minimizar o gasto de energia, durante a análise e processamento de dados, no contexto da pecuária de precisão.

O objetivo com esta pesquisa é analisar a capacidade da rede YOLOv8, do algoritmo VGG e da arquitetura ResNet para predição de EGS por meio do reconhecimento de imagens ultrassonográficas da carcaça de ovinos em tempo real.

2. Materiais e Métodos

2.1. Coleta de Dados

Os dados utilizados no estudo pertencem ao projeto Estudo genômico aplicado ao melhoramento genético de ovinos Santa Inês para características de carcaça e aprovado pela Comissão de Ética no Uso de Animais (CEUA/UFPI), nº 340/17, da Universidade Federal do Piauí, que integra o Instituto Nacional de Ciência e Tecnologia Cadeia Produtiva da Carne (INCT-CARNE) do CNPq, coordenado pela Universidade Federal da Bahia.

Na primeira etapa foram coletadas 263 imagens ultrassonográficas de resolução 393 x 497 pixels de ovinos. As imagens foram coletadas com o aparelho de ultrassom da marca *Sonoscape* modelo A5V equipado com um transdutor multifrequencial com frequência entre 7,5 a 8,5 MHz (Figura 1).



Figura 1: Aparelho de ultrassom utilizado nas coletas de imagens da carcaça.

Foram registrados o número do animal, sexo e a espessura de gordura subcutânea (EGS) em mm. As mensurações de EGS foram obtidas através da imagem ultrassonográfica do músculo *Longissimus dorsi* conforme observa-se na Figura 3, tendo-se como referência anatômica o espaço intercostal entre a 12^a e 13^a costelas. Durante o registro das imagens, o animal em estudo era contido de maneira confortável para melhor qualidade da imagem ultrassonográfica. Em seguida, foi realizada a limpeza da pele do indivíduo e com auxílio de pente foi feita a separação do pelo na região anatômica indicada para mensuração. Logo após, foi aplicado gel incolor específico para ultrassonografia (Figura 2).



Figura 2: Transdutor posicionado entre a 12^a e 13^a costelas para captura da imagem ultrassonográfica do músculo.

As imagens ultrassonográficas coletadas, sem as mensurações, foram levadas para anotação, em seguida, compiladas em uma versão para processamento e delimitação da medida de área e espessura do músculo através de *software ImageJ* (Figura 3) (BRITO et al., 2022).




Figura 3: *Software ImageJ* com marcação (linha amarela) da medida de espessura de gordura olho de lombo do músculo *Longissimus dorsi*.

2.2. Pré-processamento das imagens

A base de dados foi dividida em dois grupos, ou seja, imagens originais e imagens com as delimitações da espessura de gordura subcutânea originando as máscaras de segmentação para EGS (Região de Interesse). As originais foram coloridas em um sistema de cores RGB – *Red-Green-Blue* (Vermelho-Verde-Azul) e as máscaras de segmentação geradas são imagens binárias, que são utilizadas para predição da EGS.

Após realizar a segmentação utilizando máscaras de algoritmos de segmentação e a base de imagens do especialista, operações foram realizadas para obter somente a ROI – *Region of Interest* (Região de Interesse). Optou-se por redimensionar as imagens para o formato mais usual de rede neural (224x224pixels) para obter a ROI. Para ajustar as imagens para o padrão usual usou-se a rede Yolov8 (TERVEN et al., 2023), validar e apresentar os resultados utilizaram-se os algoritmos VGG (TAMMINA, 2019) e o ResNet (HE et al., 2016).

2.3. Segmentação da EGS

Utilizou-se dois algoritmos de segmentação automatizado *VGG* e *ResNet* e uma função de forma denominada *shape*, para encontrar as características geométricas da imagem. O *VGG* e a *ResNet* são responsáveis por extrair as características da imagem, utilizando descritores e filtros convolucionais, já a função de forma *shape* extrai características geométricas do objeto, extraindo informações da imagem, tal como a espessura de gordura subcutânea.

O objetivo foi realizar marcações próximas ou iguais as feita pelo especialista que coletou as imagens no ultrassom e tratou as mesmas na ferramenta *ImageJ* (Brito et al., 2022). Os algoritmos foram escolhidos com base em sua relevância para a segmentação em imagens de ultrassom (HE et al., 2016; TAMMINA, 2019; TARG et al., 2016).

Durante a segmentação, do total das imagens, 80% foram utilizadas para treinamento do algoritmo, 10% para validação da ferramenta e 10% para testes (HE et al., 2016; TARG et al., 2016).

2.4. Métricas de segmentação

Para a avaliação de segmentações automatizadas, três métricas foram utilizadas para medir a qualidade das segmentações. Cada uma dessas métricas são abordadas abaixo.

A precisão (Equação 1) dos objetos detectados, indica quantas detecções estavam corretas. Já a *recall* (Equação 2) calcula a proporção de mensurações corretas, medindo a capacidade do modelo de identificar todas as partes da imagem. A métrica mAP50 (Equação 3) refere-se à precisão média calculada com um limiar de intersecção sobre união (IoU) de 0,50 (a IoU indicando a similaridade entre dois conjuntos de imagens). A mAP50 é uma medida que avalia a precisão do modelo (ZHAO et al., 2023).

$$\text{Equação (1)} \quad \text{Precisão} = \frac{|VP|}{|VP| + |FP|}$$

$$\text{Equação (2)} \quad \text{Recall} = \frac{|VP|}{|VP| + |FN|}$$

$$\text{Equação (3)} \quad mAP50 = \frac{1}{m} \sum_{t=1}^m AP_t$$

Onde VP significa verdadeiros positivos, quando o algoritmo categoriza a imagem, por exemplo, indicando a medida de EGS como EGS na imagem; já o FP categoriza uma imagem, por exemplo, indicando EGS como outra medida na imagem; enquanto FN não

categorizar a imagem, não categorizando a medida de EGS como EGS na imagem. A precisão mede a porcentagem de imagens classificadas corretamente, o quanto o modelo é preciso. Já a *recall* o quão bem o modelo retorna as mensurações corretas. A mAP50 é a precisão média, ou seja, a média dos valores de precisão máxima, sendo AP o valor da precisão (ZHAO et al., 2023).

2.5. Extração de características

Com o intuito de encontrar características importantes para a previsão de EGS (Espessura de Gordura Subcutânea), tais como o vetor de características, a extração destas características foi trabalhada usando uma função de forma (*shape*) para analisar as imagens e determinar as características geométricas e uma rede neural artificial pré-treinada (*Yolov8*) usando uma ferramenta online *Roboflow*, que se trata de uma ferramenta de anotação online para construir bancos de dados de imagens para pesquisa de visão computacional (ALEXANDROVA et al., 2015). Para validar e apresentar os resultados, utilizou-se os algoritmos *VGG* e *ResNet* que obteve a EGS a partir de cada imagem (MAGGIORI et al., 2017).

2.6. Estimação da EGS

A análise de regressão foi dada pela relação entre uma variável dependente e uma ou mais variáveis independentes, sendo a variável dependente a EGS prevista para a imagem de ultrassom do animal e as independentes os valores das características extraídas com os descritores da rede neural, ou seja, as características que a rede extrai de uma imagem ou vetor de características (*VGG* ou *ResNet*).

Três algoritmos de regressão foram utilizados, *AdaBoost Regressor* (CAO et al., 2013), *Random Forest Regressor* (BREIMAN, 1996) e *GradientBoosting Regressor* (KEPRATE et al., 2017). O conjunto de características foi dividido, com os valores já normalizados entre 0 e 1, em treinamento (80%), validação (10%) e teste (10%), respectivamente (Cheng et al., 2022).

2.7. Métricas de Regressão

As métricas mais utilizadas para avaliar o desempenho de modelos de regressão são abordadas e estão disponíveis na Biblioteca *Scikit-Learn*: QMR (Quadrado Médio do Resíduo), EMA (Erro Médio Absoluto) e quanto mede o valor da medida de ajuste do modelo de regressão (R^2) (KRAMER, 2016).

A Equação 4, o valor do Quadrado Médio dos Resíduos (QMR), calcula a média dos erros do modelo ao quadrado, ou seja, diferenças menores são menos importantes, enquanto as diferenças maiores recebem mais peso, aonde y_i é o valor real e $\hat{y}_i$ é o valor predito de EGS.

$$\text{Equação (4)} \quad QMR(y, \hat{y}) = \frac{1}{n_{amostras}} \sum_{i=0}^{n_{amostras}-1} (y_i - \hat{y}_i)^2$$

Já a Equação 5, o valor do Erro Médio Absoluto (EMA), é uma métrica de risco, sendo y_i o valor real e $\hat{y}_i$ é o valor predito da EGS.

$$\text{Equação (5)} \quad EMA(y, \hat{y}) = \frac{1}{n_{amostras}} \sum_{i=0}^{n_{amostras}-1} |y_i - \hat{y}_i|$$

Enquanto a Equação 6 representa o coeficiente de determinação de regressão (R^2), sendo y_i o valor real e $\hat{y}_i$ é o valor predito da EGS.

$$\text{Equação (6)} \quad R^2(y, \hat{y}) = 1 - \frac{\sum_{i=0}^{n_{amostras}-1} (y_i - \hat{y}_i)^2}{\sum_{i=0}^{n_{amostras}-1} (y_i - \bar{y})^2}$$

Todas as análises descritas anteriormente foram realizadas por meio da linguagem de programação em *Python* (PYTHON, 2025).

2.8. Estatística descritiva e comparação de médias

As médias de espessura de gordura subcutânea determinadas por especialista com ultrassom (EGS real) e as preditas pela ferramenta computacional (EGS predita) a partir das imagens de ultrassom foram submetidas a análises descritivas, a partir do coeficiente de variação, o erro padrão e o intervalo de confiança para a média construído a 95% de probabilidade, e foram comparadas pelo teste “t” de *student* pareado para comparação das médias a 5% de probabilidade.

3. Resultados

3.1. Resultados da Segmentação

As métricas de precisão, *recall* e mAP50 foram utilizadas para a análise quantitativa de comparação entre a máscara realizada pelo especialista e a obtida através dos algoritmos e o grau de exatidão das detecções feitas pela ferramenta YOLOv8.

A representação dos resultados obtidos com a segmentação automatizada a partir das imagens ultrassonográficas dos ovinos por meio da utilização do algoritmo por meio do algoritmo YOLOv8. As métricas de precisão, *recall* e mAP50 foram utilizadas para a

análise quantitativa de comparação entre a máscara realizada pelo especialista e a obtida através dos algoritmos. Os resultados da segmentação das 358 imagens de ultrassom foram apresentados na Tabela 1.

Os resultados obtidos para as métricas foram próximos a 1 (Precisão = 0,74/ mAP50 = 0,78/ Recall = 0,75) em uma escala de 0 a 1. As métricas utilizadas são métricas de similaridade, que realiza a comparação entre dois resultados, ou seja, os três índices mostram semelhança entre duas amostras de dados, visto que quanto mais próximo de 1 for o valor melhor será o resultado e maior será a semelhança entre o mensurado e o predito. Desta maneira, este algoritmo se mostrou eficiente na segmentação das imagens.

Na Figura 4 pode-se observar um comparativo entre a segmentação das imagens de ultrassom feitas pelo algoritmo YOLOv8 e as feitas pelo especialista.




Figura 4: Segmentação das medidas de EGS e AOL nas imagens ultrassonográficas feitas pelo especialista no imageJ e pelo algoritmo YOLOv8

Observa-se uma similaridade entre as marcações nas imagens pelo especialista e pelo algoritmo YOLOv8 (Figura 4), o que torna a metodologia eficiente e capaz de prever a espessura de gordura subcutânea dos animais em estudo. Sendo assim, a ferramenta em questão mostra robustez em programas de segmentação de imagens ultrassonográficas.

3.2. Resultados para estimação da EGS

A seguir são apresentados os resultados obtidos com os regressores *AdaBoost Regressor*, *Random Forest Regressor* e *Gradient Boosting Regressor*. Os resultados foram divididos em experimentos com as EGS extraídas das segmentações feitas, manualmente, utilizando *VGG* e *ResNet* (Tabela 3).

Tabela 3: Resultados obtidos com a regressão usando os regressores *AdaBoost*, *Regressor*, *Random Forest* e *GradientBoosting* nas imagens obtidas por segmentação usando *Yolov8*, para os algoritmos *VGG* e *ResNet*, para a estimação da EGS.

	<i>Adabooster</i>			<i>RandomForest</i>			<i>GradientBoosting</i>		
	EMA	QMR	R ²	EMA	QMR	R ²	EMA	QMR	R ²
<i>VGG</i>	0,33	0,24	0,06	0,32	0,23	0,08	0,34	0,24	0,05
<i>ResNet</i>	0,33	0,24	0,04	0,32	0,22	0,12	0,33	0,23	0,08

EMA: Erro Médio Absoluto; QMR: Quadrado Médio do Resíduo; R²: Coeficiente de determinação.

Observou-se de acordo com a Tabela 3 que ao utilizar-se o *VGG* como algoritmo de segmentação, o *Random Forest* apresentou resultados mais promissores que os demais algoritmos, na regressão, demonstrando maior qualidade de ajuste da equação aos dados na regressão, dentre os regressores. Além disso, o RF por apresentar menor EMA, ou seja, menor erro na predição da EGS. Entretanto, ao se utilizar o *ResNet* na segmentação, o algoritmo *Adabooster* obteve resultados mais promissores e robustos que o *VGG*.

Entretanto, vale ressaltar que os resultados para a EGS foram ruins, o que indica baixa qualidade de ajuste da equação aos dados, demonstrando baixa precisão da ferramenta ao mensurar a EGS nos ovinos.

Na Figura 5 estão representados os gráficos das análises de regressão realizada a partir dos resultados obtidos com os três regressores mencionados anteriormente, para os 3 algoritmos mencionados.




Figura 5: Dispersão dos valores de EGS reais e preditos para o algoritmo VGG e Adabooster (5a), VGG e Random Forest (5b), VGG e GradientBoosting (5c), ResNet e shape (5d), ResNet e Random Forest (5e), ResNet e GradientBoosting (5f).

Observa que os valores de R^2 para o *Random Forest* foram maiores em comparação aos outros regressores, de acordo com os gráficos 5b e 5e, ao se utilizar o VGG na segmentação, o que demonstra maior qualidade na regressão e melhor ajuste da equação aos dados, em relação aos outros regressores, sendo que o gráfico 5e (*Random Forest* e *ResNet*) demonstra menor dispersão dos dados e maior qualidade de ajuste na regressão, comparando-se com os outros algoritmos.

Nas Tabelas 4 e 5 estão representadas as estatísticas descritivas das médias de Espessura de Gordura Subcutânea predita (EGS predita) e a mensurado (EGS real) mensuradas em ovinos, que foram submetidas a comparação de médias pelo teste “t” de *student*, para cada um dos métodos e regressores.

Tabela 4: Estatística descritiva das médias de Espessura de Gordura Subcutânea (EGS) reais e preditas em Ovinos para o algoritmo VGG.

Método Regressor	+	Característica estudada	μ	CV	A	σ^2	Intervalo de confiança para a média a 95% de probabilidade	
							Limite inferior	Limite superior
VGG + <i>Adabooster</i>		EGS observada	1,91a	26,00	3,40	0,25	1,10	4,50
		EGS predita	1,87a	8,00	1,18	0,02	1,62	2,80
VGG <i>RandomForest</i>	+	EGS observada	1,91a	26,00	3,40	0,25	1,10	4,50
		EGS predita	1,89a	12,00	1,36	0,05	1,43	2,79
VGG <i>GradientBoosting</i>	+	EGS observada	1,91a	26,00	3,40	0,25	1,10	4,50
		EGS predita	1,89a	13,00	2,02	0,06	1,44	3,45

μ : média; CV: coeficiente de variação (%); A: amplitude; σ^2 : variância; a: médias seguidas de mesma letra não diferem estatisticamente pelo teste t ao nível de 5% de probabilidade.

Tabela 5: Estatística descritiva das médias de Espessura de Gordura Subcutânea (EGS) reais e preditas em Ovinos para o algoritmo *ResNet*.

Método Regressor	+	Característica estudada	μ	CV	A	σ^2	Intervalo de confiança para a média a 95% de probabilidade	
							Limite inferior	Limite superior
<i>ResNet</i> <i>Adabooster</i>	+	EGS observada	1,91a	26,00	3,40	0,25	1,10	4,50
		EGS predita	1,86a	9,00	0,84	0,03	1,56	2,39
<i>ResNet</i> <i>RandomForest</i>	+	EGS observada	1,91a	26,00	3,40	0,25	1,10	4,50
		EGS predita	1,88a	11,00	1,31	0,05	1,40	2,71
<i>ResNet</i> <i>GradientBoosting</i>	+	EGS observada	1,91a	26,00	3,40	0,25	1,10	4,50
		EGS predita	1,88a	12,00	1,32	0,05	1,43	2,74

μ : média; CV: coeficiente de variação (%); A: amplitude; σ^2 : variância; a: médias seguidas de mesma letra não diferem estatisticamente pelo teste t ao nível de 5% de probabilidade.

As médias de EGS observada e EGS predita não apresentaram diferenças significativas pelo teste t de *student*, o que destaca a eficiência e robustez da ferramenta. Fica evidente a contribuição que essa ferramenta pode trazer para a fenotipagem em larga escala da avaliação de carcaça em ovinos de corte, por assim trazer mais informações sobre os animais em estudo, de maneira automatizada.

Observou-se que o CV para a EGS predita foi menor do que obtido para a EGS observada, o que indica menor dispersão nos dados nos resultados encontrados pela ferramenta proposta, ou seja, houve menor variabilidade dos dados, demonstrando maior

precisão no valor predito que no observado, demonstrando dados mais homogêneos na EGS predita.

Verificou-se ainda que a amplitude (A) e o intervalo de confiança (IC) foram menores para a EGS predita, o que se deve a padronização (atribuição fixa de funções) que a metodologia proposta impõe aos dados coletados, ficando evidente assim o sucesso, a robustez e a confiabilidade da ferramenta. Sendo assim, a confiabilidade na EGS predita foi maior do que na observada, destacando a importância da utilização da ferramenta tecnológica, por ter resultados mais promissores.

Observou-se ainda que a variância para a EGS predita foi menor do que a observada, destacando que as médias preditas apresentaram menor dispersão do que a observadas, demonstrando a eficiência e precisão do método. Verificou-se também que a partir do intervalo de confiança construído para a EGS predito fica evidente, mais uma vez, a maior confiabilidade para EGS predita pelo algoritmo, o que mais uma vez destaca que os algoritmos desenvolvidos foram eficientes para prever a EGS.

Embora, ocorra diferença na variabilidade das EGS observadas e preditas, as médias calculadas não apresentando diferença significativa ($P > 0,05$) entre elas, o que evidencia a precisão, robustez e eficiência na predição da EGS pela ferramenta proposta, visto que se aproxima bastante da mensuração feita pelo especialista, com menor variação na EGS predita.

4. Discussão

A rede YOLOv8 demonstrou precisão e *recall* semelhantes aos descrito por CHENG et al. (2022), BARWICK et al. (2018), PENG et al. (2024) e ZHAO et al. (2023) no estudo de características de ovinos, que afirmaram que quanto mais imagens, melhor serão os resultados, visto que quanto mais próximo de 1, maior a presença de características corretamente reconhecidas pela ferramenta, em comparações às medições feita pelo especialista.

A arquitetura da YOLOv8 segmentou as imagens com precisão e robustez. Esses resultados mostram a capacidade do modelo de solucionar o desafio de mensurar a gordura na carcaça com precisão. Desta maneira a YOLOv8 mostrou-se eficiente ao prever a EGS em ovinos.

YU et al. (2024), no estudo de detecção de características de ovelhas utilizando a YOLOv8, observou que os resultados experimentais indicam que o método proposto utilizando a rede demonstra alta precisão e robustez. PEI et al. (2024) no estudo de

detecção de ovinos utilizando a Yolov8, observou que a rede foi superior às outras, por apresentar maior precisão, estabilidade e robustez com resultados semelhantes aos do presente trabalho, sendo, portanto, uma ferramenta mais otimizada e de maior desempenho. YADAV et al. (2024), na detecção de características de caprinos e ovinos utilizando a mesma rede, observaram precisão e recall semelhantes ao do presente trabalho, demonstrando robustez e eficiência na presente ferramenta.

Resultados semelhantes de mAP50, *recall* e precisão foram encontrados por PENG et al. (2024), PEI et al. (2024), na tarefa de segmentação de imagens de ovinos. Além disso, NG (2018) ainda afirma que é importante incluir na análise outras métricas além da precisão, pois avalia a velocidade de detecção das características, e assim para todos os resultados abaixo do aceitável, será otimizada a acurácia dos modelos.

De acordo com a tabela 3, o *Random Forest* se comportou melhor, ao se utilizar o *ResNet*, visto que, em média, obteve menor EMA e QMR e maior R^2 , comparando-se com o *Adabooster* e *RandomForest* demonstrando maior robustez, performance e eficiência para avaliar a qualidade da análise de regressão, corroborando os resultados de TIRINK (2023), MANSBRIDGE et al. (2018) e MCMANUS et al. (2013), no estudo de características da carcaça de ovelhas, confirmaram em seus trabalhos que o *Random Forest* é capaz de melhorar, significativamente, a estabilidade e precisão do modelo, sendo superior aos outros regressores. BREIMAN (1996) afirma que o *Random Forest* apresenta múltiplas tarefas como segmentação de imagens observando robustez e eficiência nos resultados encontrados. Entretanto ao se utilizar o *ResNet* na segmentação, o *Adabooster* terá resultados mais promissores.

De acordo com PINHEIRO et al. (2010) e LIMA JÚNIOR et al. (2024), no estudo da carcaça de ovinos, observaram um bom ajustamento da equação aos dados, ao estudarem AOL em ovinos, mesmo trabalhando com um número reduzido de imagens, demonstrando um resultado promissor.

Dentre os algoritmos apresentados no trabalho, o VGG foi o que teve melhor desempenho e robustez ao utilizar-se o *Adabooster* na regressão por apresentar, menores valores de EMA e QMR e maior R^2 , em média.

SUN et al. (2018), na detecção de características de ovinos utilizando algoritmos de visão computacional, afirmam que o VGG tem maior precisão, robustez e desempenho e é capaz de capturar características na imagem, sendo muito útil para solucionar tarefas de

reconhecimento e classificação de imagens, dentre os algoritmos estudados. GU et al. (2023), ao estudarem o comportamento de ovelhas, observaram que o VGG pode ser utilizada no estudo de ovelhas, sendo adequada na tarefa de segmentação de imagens e apresentando resultados satisfatórios.

Sendo assim, o algoritmo *ResNet* e o regressor *Random Forest*, quando ambos foram utilizados na ferramenta proposta, obtiveram resultados mais promissores demonstrando maior acurácia e precisão, em relação aos outros algoritmos, pois o R^2 foi maior e o CV, a amplitude e a variância foram os menores dos que foram propostos e as médias preditas e reais não apresentaram diferenças significativas. Entretanto, vale ressaltar que é necessária a coleta de mais imagens em campo, para ampliar o banco de dados, fortalecendo a fenotipagem e assim resultados mais promissores e robustos, na mensuração de EGS em ovinos.

Embora a diferença na variabilidade da EGS tomada, as médias calculadas foram muito próximas, não se observando diferença significativa ($P>0,05$) entre elas, o que fica evidente a acurácia na predição para a medida determinado pelos algoritmos propostos, visto que se aproxima bastante da mensuração feita pelo especialista, com menor variação, enfatizando a eficiência da ferramenta e mostra que a tecnologia é capaz de prever com precisão a EGS, otimizando assim a coleta em campo, assim como o observado por SENNA et al. (2020), LIMA JÚNIOR et al. (2024) e CARTAXO et al. (2008), ao estudarem características de carcaça em ovinos da raça Santa Inês.

Observou-se que o CV para EGS predita, em todos os casos, foi menor do que obtido para a EGS observada, indicando menor dispersão de dados nos resultados encontrados pela ferramenta computacional, que é corroborado por TAVEIRA et al. (2016) e SENA et al. (2016) e SENA et al. (2020) ao avaliarem a carcaça de ovinos.

Constatou-se ainda que a amplitude (A) e o intervalo de confiança (IC) e a variância foram menores para a EGS predita, em todos os casos, indicando menor dispersão dos dados, e fica evidente, também, a maior confiabilidade da estimativa para EGS predita pelos métodos computacionais, devido à padronização utilizada imposta aos dados coletados, confirmando assim, o sucesso da ferramenta, corroborado por SENA et al. (2016) e PAULA et al. (2013), no estudo de ovinos Santa Inês. Além disso a menor variância no predito deixa estabelecido que houve menor variação nos dados preditos

pelos métodos computacionais, o que deixa evidenciado maior precisão e eficiência na automação.

Neste contexto, vale ressaltar ainda que a ausência de gordura ocasiona a maior perda de líquidos na carcaça durante o resfriamento e eleva o grau de escurecimento da carne, reduzindo assim o seu valor comercial, e ainda afeta negativamente na coloração, suculência e maciez, além de influenciar negativamente nas características sensoriais (LUCHIARI FILHO, 2000).

Entretanto, GOES et al. (2005) destacam que para evitar carnes com aparência negativa e/ou estragada, os frigoríficos brasileiros requerem que as carcaças apresentem a espessura mínima de 2,5 a 3 mm de gordura subcutânea, para proteção durante o resfriamento. Isto pode ser corroborado nos trabalhos de KAZAMA et al. (2008) que verificaram que a gordura atua como isolante térmico protegendo o músculo dos efeitos negativos da exposição ao resfriamento e ainda possibilita que ela resfrie lentamente, dentro dos limites aceitáveis, evitando o encurtamento das fibras musculares (*cold shortening*), melhorando ainda a maciez da carne.

DA SILVA et al. (2019), ao estudar bovinos, afirma que gordura subcutânea acima de 3 mm acaba sendo prejudicial, já que possui correlação negativa com a quantidade de carne magra na carcaça. O que é corroborado por COSTA et al. (2002) ao afirmarem que o excesso de gordura diminui o peso da carcaça e aumenta o custo operacional do sistema produtivo, sendo assim negativamente correlacionado com a porção comestível da carcaça, ocasionando prejuízos ao produtor e ao frigorífico e diminuindo a eficiência de produção.

Além disso, o uso de tecnologias no sistema de produção é fundamental, pois otimiza o processo de produção, como o uso da ultrassonografia e de algoritmo, trazendo melhorias significativas nas análises de imagens e, conseqüentemente, na produção, aonde dentro da rotina de coleta de dados é capaz de solucionar problemas como por exemplo, imagens com pouca resolução e um reduzido banco de imagens (LOBO, 2017; LIMA JÚNIOR et al. 2024).

Por fim, a padronização utilizada, o qual houve atribuições fixas de funções, possibilitou trabalhar-se com poucas imagens e obter precisão e resultados promissores. Vale ressaltar que além de comprovar a precisão oriunda da padronização durante a coleta, esta pesquisa também contribuiu para a fenotipagem de ovinos em larga escala,

sendo fundamental para os programas de melhoramento genético e para outras áreas da produção animal de ovinos de corte que permite fazer uso dessa informação para a tomada de decisões, já que permite um monitoramento maior dos indivíduos facilitando na seleção dos animais.

5. Conclusões

Através de algoritmos da visão computacional é possível predizer a espessura de gordura subcutânea do músculo *Longissimus dorsi*, o que pode gerar um avanço importante na rotina de medição dessa característica, sendo necessário coletar mais imagens a fim de aprimorar o treinamento dos modelos e melhorar ainda mais os resultados obtidos.

O algoritmo VGG, dentre os que foram avaliados, obteve resultados mais promissores em conjunto com o *Adabooster*, entretanto ao se utilizar o *ResNet* para a segmentação em conjunto com o *Random Forest* para a regressão, os resultados foram melhores e mais robustos.

O regressor *Random Forest* teve melhor robustez ao utilizar-se o VGG, entretanto no caso do VGG na segmentação, os resultados para o *Adabooster* serão mais promissores.

As ferramentas de visão computacional demonstraram-se como importantes aliadas na rotina de obtenção de informações sobre a carcaça de ovinos, trazendo otimização, robustez e eficiência na segmentação de imagens de ovinos Santa Inês.

Referências Bibliográficas

- ANDRADE, A.C.S. et al. Características físico-químicas e sensoriais da carne de cordeiros Santa Inês abatidos com diferentes espessuras de gordura subcutânea. **Revista Brasileira de Zootecnia**, v.44, p.290-295. 2015. Available from: <<https://doi.org/10.1590/S1519-99402015000300021>>. Accessed: Mai. 27, 2025. doi: 10.1590/S1519-99402015000300021.
- BARWICK, J. et al. Predicting Lameness in Sheep Activity Using Tri-Axial Acceleration Signals. **Animals**, v.8, p.12. 2018. Available from: <<https://doi.org/10.3390/ani8010012>>. Accessed: Mai. 24, 2025. doi:10.3390/ani8010012.
- BAUTISTA-DÍAZ, E. et al. Prediction of Carcass Traits of Hair Sheep Lambs Using Body Measurements. **Animals**, v.10, p.1276. 2020. Available from: <<https://doi.org/10.3390/ani10081276>>. Accessed: Mai. 27, 2025. doi: 10.3390/ani10081276

BREIMAN, L. Bagging predictors. **Machine Learning**, v.24, p.123–140. 1996. Available from: <<https://doi.org/10.1007/BF00058655>>. Accessed: Mai. 24, 2025. doi: 10.1007/BF00058655.

BRITO, L.S. et al. Evaluation of ImageJ software in ultrasonic image analysis: Follicular and luteal morphological characteristics of cattle. **Animal Reproduction Science**, v.236, p.106907. 2022. Available from: <<https://doi.org/10.1016/j.anireprosci.2021.106907>>. Accessed: Mai. 24, 2025. doi: 10.1016/j.anireprosci.2021.106907.

CAO, Y. et al. Advance and Prospects of AdaBoost Algorithm. **Acta Automatic Sinica**, v.39, p.745-758. 2013. Available from: <[https://doi.org/10.1016/S1874-1029\(13\)60052-X](https://doi.org/10.1016/S1874-1029(13)60052-X)>. Accessed: Mai. 24, 2025. doi: 10.1016/S1874-1029(13)60052-X.

CARTAXO, F.Q.; SOUSA, W.H. Correlações entre as características obtidas in vivo por ultra-som e as obtidas na carcaça de cordeiros terminados em confinamento. **Revista Brasileira de Zootecnia**, v. 37, p. 1490-1495. 2008. Available from: <<https://doi.org/10.1590/S1516-35982008000800022>>. Accessed: Mai. 24, 2025. doi: 10.1590/S1516-35982008000800022.

CHENG, M. et al. Application of deep learning in sheep behaviors recognition and influence analysis of training data characteristics on the recognition effect. **Computers and electronics in agriculture**, v.198, p.107010. 2022. Available from: <<https://doi.org/10.1016/j.compag.2022.107010>>. Accessed: Mai. 24, 2025. doi: 10.1016/j.compag.2022.107010.

CORDÃO, M.A. et al. Acabamento de carcaça de ovinos e caprinos – Revisão Bibliográfica. **Agropecuária Científica no Semiárido**, v.8, p.16-23. 2012. Available from: <<https://doi.org/10.30969/acsa.v8i2.196>>. Accessed: Mai. 24, 2025. doi: 10.30969/acsa.v8i2.196.

COSTA, E.C.D. et al. 2002. Desempenho de novilhos Red Angus superprecoces, confinados e abatidos com diferentes pesos. **Revista Brasileira de Zootecnia**, v.31, p.129-138. Available from: <<https://doi.org/10.1590/S1516-35982002000100015>>. Accessed: Mai. 24, 2025. doi: 10.1590/S1516-35982002000100015.

DA SILVA, A.M.M. et al. Processamento e Análise de Imagens Médicas. **Revista Brasileira de Física Médica**, v.13, p.34-48. 2019. Available from:

<<https://doi.org/10.29384/rbfm.2019.v13.n1.p34-48>>. Accessed: Mai. 24, 2025. doi: 10.29384/rbfm.2019.v13.n1.p34-48.

DEBAUCHE, O. et al. Cloud services integration for farm animals behavior studies based on smartphones as activity sensors. **Journal of Ambient Intelligence and Humanized Computing**, v.10, p.4651-4662. 2019. Available from: <<https://doi.org/10.1007/s12652-018-0845-9>>. Accessed: Mai. 24, 2025. doi: 10.1007/s12652-018-0845-9.

DOS SANTOS S.K. et al. Intake and performance of growing lambs supplemented with quebracho tannins. **Tropical Animal Health Production**, v.54, p.71. 2022. Available from: <<https://doi.org/10.1007/s11250-022-03043-8>>. Accessed: Mai. 24, 2025. doi: 10.1007/s11250-022-03043-8.

HE, K. et al. Deep Residual Learning for Image Recognition. **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**. p.770-778. 2016. Available from: <<https://doi.org/10.48550/arXiv.1512.03385>>. Accessed: Mai. 24, 2025. doi: 10.48550/arXiv.1512.03385.

JIMENEZ-SANZ, A., et al. Relação entre fatores associados às parasitoses gastrointestinais, desempenho e estado fisiológico de ovelhas Santa Inês. **Agropecuária Técnica**. v.37, p.88–95. 2016. Available from: <<https://doi.org/10.25066/agrotec.v37i1.25170>>. Accessed: Mai. 24, 2025. doi: 10.25066/agrotec.v37i1.25170.

KAZAMA, R. et al. Quantitative and qualitative carcass characteristics of heifers fed different energy sources on a cottonseed hulls and soybean hulls based diet. **Revista Brasileira de Zootecnia**. v.37, p.350-357. 2008. Available from: <<https://doi.org/10.1590/S1516-35982008000200023>>. Accessed: Mai. 24, 2025. doi: 10.1590/S1516-35982008000200023

KEPRATE, A.; RATNAYAKE, R.M.C. Using gradient boosting regressor to predict stress intensity factor of a crack propagating in small bore piping, **IEEE International Conference on Industrial Engineering and Engineering Management**, v.1331-1336. 2017. Available from: <<https://doi.org/10.1109/IEEM.2017.8290109>>. Accessed: Mai. 24, 2025. doi: 10.1109/IEEM.2017.8290109.

KRAMER, O. Scikit-Learn. In: Machine Learning for Evolution Strategies. **Studies in Big Data**, v.20. 2016. Available from: <https://doi.org/10.1007/978-3-319-33383-0_5>. Accessed: Mai. 24, 2025. doi: 10.1007/978-3-319-33383-0_5.

LIMA JÚNIOR, F.A. et al. Prediction of carcass rib eye area by ultrasound images in sheep using computer vision. **Ciência Rural**, v.54, p.e20230576. 2024. Available from: <<https://doi.org/10.1590/0103-8478cr20230576>>. Accessed: Mai. 24, 2025. doi: 10.1590/0103-8478cr20230576.

LIRA, A. B. et al. Performance and carcass characteristics of two biotypes of pasture-finished Santa Inês sheep supplemented with multinutritional blocks. *Revista Brasileira de Saúde e Produção Animal*, v.18, p.313-326, 2017. Available from: <<http://dx.doi.org/10.1590/s1519-99402017000200010>>. Accessed: Mai. 24, 2025. doi: 10.1590/s1519-99402017000200010.

LOBO, L.C. Inteligência Artificial e Medicina. **Revista Brasileira de Educação Médica**, v.41, p.185-193. 2017. Available from: <<https://doi.org/10.1590/1981-52712015v41n2esp>>. Accessed: Mai. 24, 2025. doi: 10.1590/1981-52712015v41n2esp.

LUCHIARI FILHO, A. **Pecuária da carne bovina**. São Paulo: PUC-PR. 2000. 1v.

MORA, N.H.A.P. et al. Características de carcaça de cordeiras Pantaneiras abatidas com diferentes espessuras de gordura subcutânea. **Arquivo Brasileiro De Medicina Veterinária E Zootecnia**, v.67, p.290–298. 2015. Available from: <<https://doi.org/10.1590/1678-7319>>. Accessed: Mai. 24, 2025. doi: 10.1590/1678-7319.

MAGGIORI, E. et al. Convolutional Neural Networks for Large-Scale Remote-Sensing Image Classification. **IEEE Transactions on Geoscience and Remote Sensing**, v.55, p.645-657. 2017. Available from: <<https://doi.org/10.1109/TGRS.2016.2612821>>. Accessed: Mai. 24, 2025. doi: 10.1109/TGRS.2016.2612821.

MANSBRIDGE, N., et al. 2018. Feature Selection and Comparison of Machine Learning Algorithms in Classification of Grazing and Rumination Behaviour in Sheep. **Sensors**. v.18, p.3532. Available from: <<https://doi.org/10.3390/s18103532>>. Accessed: Mai. 24, 2025. doi: 10.3390/s18103532.

MCMANUS, C., et al. Avaliação ultrasonográfica da qualidade de carcaça de ovinos Santa Inês. **Ciência Animal Brasileira**, v.14, p.8–16. 2013. Available from: <<https://doi.org/10.5216/cab.v14i1.12336>>. Accessed: Mai. 24, 2025. doi: 10.5216/cab.v14i1.12336

MUÑOZ-OSÓRIO G.A. et al. Using fat thickness and longissimus thoracis traits real-time ultrasound measurements in Black Belly ewe lambs to predict carcass tissue composition

through multiresponse multivariate adaptive regression splines algorithm. **Meat Science**, v.207, p.109369. 2024. Available from: <<https://doi.org/10.1016/j.meatsci.2023.109369>>. Accessed: Mai. 24, 2025. doi: 10.1016/j.meatsci.2023.109369.

NASCIMENTO, U.F.S. et al. Performance and carcass characteristics of lambs ½ Dorper + ½ Santa Inês, slaughtered with different thicknesses of subcutaneous fat. **Revista Brasileira de Saúde e Produção Animal**, v.19, p.125-135. 2018. Available from: <<https://doi.org/10.1590/S1519-99402018000100012>>. Accessed: Mai. 24, 2025. doi: 10.1590/S1519-99402018000100012.

NG, A. **Machine learning yearning: Technical strategy for AI engineers, in the era of deep learning**. 2018.118p.

PANNIER, L. et al. Associations of sire estimated breeding values and objective meat quality measurements with sensory scores in Australian lamb. **Meat Science**, v.96, p.1076-1087. 2014. Available from: <<https://doi.org/10.1016/j.meatsci.2013.07.037>>. Accessed: Mai. 24, 2025. doi: 10.1016/j.meatsci.2013.07.037.

PAULA, E.F.E. et al. Consumo alimentar residual e sua relação com medidas de desempenho e eficiência e características in vivo da carcaça de cordeiros. **Arquivo Brasileiro De Medicina Veterinária E Zootecnia**, v.65, p.566–572. 2013. Available from: <<https://doi.org/10.1590/S0102-09352013000200037>>. Accessed: Mai. 24, 2025. doi: 10.1590/S0102-09352013000200037

PEI, S. et al. Realizing Cattle and Sheep Target Detection in Ecological Livestock Farming Based on Improved YOLOv8 Model. **6th Asia Symposium on Image Processing**, v.21-28. 2024. Available from: <<https://doi.org/10.1109/ASIP63198.2024.00012>>. Accessed: Mai. 24, 2025. doi: 10.1109/ASIP63198.2024.00012.

PENG, Y. et al. A dynamic individual yak heifer live body weight estimation method using the YOLOv8 network and body parameter detection algorithm. **Journal of Dairy Science**, v.107, p.6178-6191. 2024. Available from: <<https://doi.org/10.3168/jds.2023-24065>>. Accessed: Mai. 24, 2025. doi: 10.3168/jds.2023-24065.

PINHEIRO, R.S.B. et al. Correlações entre medidas determinadas in vivo por ultrassom e na carcaça de ovelhas de descarte. **Revista Brasileira De Zootecnia**, v.39, p.1161–1167. 2010. Available from: <<https://doi.org/10.1590/S1516-35982010000500030>>. Accessed: Mai. 24, 2025. doi: 10.1590/S1516-35982010000500030.

QUEIROZ, L.O. et al. Características quantitativas da carcaça de cordeiros Santa Inês, abatidos com diferentes espessuras de gordura subcutânea. **Revista Brasileira De Saúde E Produção Animal**, v.16, p.712–722. 2015. Available from: <<https://doi.org/10.1590/S1519-99402015000300021>>. Accessed: Mai. 24, 2025. doi: 10.1590/S1519-99402015000300021.

RONNEBERGER, O. et al. U-Net: Convolutional Networks For Biomedical Image Segmentation. **Medical Image Computing and Computer-Assisted Intervention**, v.9351, p.234–241. 2015. Available from: <https://doi.org/10.1007/978-3-319-24574-4_28>. Accessed: Mai. 24, 2025. doi: 10.1007/978-3-319-24574-4_28.

SENA, L.S. et al. Genetic evaluation of Tropical climate-adapted sheep for carcass traits including genomic information. **Small Ruminant Research**, v.3, p.106120. 2020. Available from: <<https://doi.org/10.1016/j.smallrumres.2020.106120>>. Accessed: Mai. 24, 2025. doi: 10.1016/j.smallrumres.2020.106120

SENA, L.S. et al. Associação entre características de carcaça e tamanho corporal em ovinos Santa Inês. **Revista Científica de Produção Animal**, v.18, p.84-92. 2016. Available from: <<http://doi.org/10.5935/2176-4158/rcpa.v18n2p84-92>>. Accessed: Mai. 24, 2025. doi: 10.5935/2176-4158/rcpa.v18n2p84-92.

SILVA, F.A.S. Predição do peso de carcaça, espessura de gordura subcutânea e perda de peso corporal durante o transporte de bovinos de corte. **Exigências Nutricionais de Zebuínos Puros e Cruzados**, v.4, p.139–164. 2023. Available from: <<http://doi.org/10.26626/978-85-8179-192-0.2023.C006.p.139-164>>. Accessed: Mai. 24, 2025. doi: 10.26626/978-85-8179-192-0.2023.C006.p.139-164.

SILVA, L.H.P. et al. Carcass and meat quality traits of Nellore young bulls and steers throughout fattening. **Livestock Science**, v.229, p.28-36. 2019. Available from: <<https://doi.org/10.1016/j.livsci.2019.09.012>>. Accessed: Mai. 24, 2025. doi: 10.1016/j.livsci.2019.09.012.

SOUZA, S.F. et al. Aplicação da ultrassonografia para avaliação de condição corporal e acabamento de carcaça em pequenos ruminantes. **Ciência Veterinária nos Trópicos**, v.19, p.34–42. 2016. Available from: <https://rcvt.org.br/?page_id=3637#volume-19-numero-3/4>. Accessed: Mai. 24, 2025.

STEFANOVA, M. Precision poultry farming: software architecture framework and online zootechnical diary for monitoring and collaborating on hens health. **Springer International**

Publishing, v.953, p.191-205. 2019. Available from: <https://doi.org/10.1007/978-3-030-12998-9_14>. Accessed: Mai. 24, 2025. doi: 10.1007/978-3-030-12998-9_14.

TAMMINA, S. Transfer learning using vgg-16 with deep convolutional neural network for classifying images. **International Journal of Scientific and Research Publications**, v.9, p.143-150. 2019. Available from: <<http://doi.org/10.29322/IJSRP.9.10.2019.p9420>>. Accessed: Mai. 24, 2025. doi: 10.29322/IJSRP.9.10.2019.p9420.

TARG, S. et al. Resnet in resnet: Generalizing residual architectures. **Workshop track - ICLR**, 2016. Available from: <<https://doi.org/10.48550/arXiv.1603.08029>>. Accessed: Mai. 24, 2025. doi: 10.48550/arXiv.1603.08029.

TAVEIRA, R.Z. et al. Avaliação de carcaça de bovinos da raça Tabapuã com ultrassonografia. **Pubvet**, v.10, p.100-104. 2016. Available from: <<https://doi.org/10.22256/pubvet.v10n1.100-104>>. Accessed: Mai. 24, 2025. doi: 10.22256/pubvet.v10n1.100-104

TERVEN, J. et al. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. **Machine Learning and Knowledge Extraction**, v.5, p.1680-1716. 2023. Available from: <<https://doi.org/10.3390/make5040083>>. Accessed: Mai. 24, 2025. doi: 10.3390/make5040083.

TIRINK. C. Comparison of Bayesian Regularized Neural Network, Random Forest Regression, Support Vector Regression and Multivariate Adaptive Regression Splines Algorithms to Predict Body Weight from Biometrical Measurements in Thalli Sheep. **Kafkas Universitesi Veteriner Fakultesi Dergisi**, v.28, p.411-419. 2023. Available from: <<https://doi.org/10.9775/kvfd.2022.27164>>. Accessed: Mai. 24, 2025. doi: 10.9775/kvfd.2022.27164.

VAN HERTEM, T. et al. Appropriate data visualisation is key to Precision Livestock Farming acceptance. **Computers and Electronics in Agriculture**, v.138, p.1-10. 2017. Available from: <<https://doi.org/10.1016/j.compag.2017.04.00>>. Accessed: Mai. 24, 2025. doi: 10.1016/j.compag.2017.04.00.

YAN, K. et al. Face Recognition Based On Convolution Neural Network. **36th Chinese Control Conference (CCC) – IEEE**. p.4077 -4081. 2017. Available from:

<<https://doi.org/10.23919/ChiCC.2017.8027997>>. Accessed: Mai. 24, 2025. doi: 10.23919/ChiCC.2017.8027997.

YU, W. et al. YoloSortC3D: A YOLOv8, DeepSort, and C3D-Based Method for Sheep Rumination Behavior Recognition. **Applied Science**, v.14, p.10801. 2024. Available from: <<https://doi.org/10.3390/app142310801>>. Accessed: Mai. 24, 2025. doi: 10.3390/app142310801.

ZHAO, H. et al. SheepInst: a high-performance instance segmentation of sheep images based on deep learning. **Animals**, 13, 1338. 2023. Available from: <<https://doi.org/10.3390/ani13081338>>. Accessed: Mai. 24, 2025. doi: 10.3390/ani13081338.

CAPÍTULO III

Visão Computacional e Ultrassonografia na ovinocultura: Segmentação Automatizada de imagens do músculo *Longissimus dorsi* para Predição de Características de Carcaça

Visão Computacional e Ultrassonografia na ovinocultura: Segmentação Automatizada de imagens do músculo *Longissimus dorsi* para Predição de Características de Carcaça

Francisco Albir Lima Júnior^{a,*}, José Weyner Rodrigues Farias^b, Natanael Pereira da Silva Santos^c, Daniel Biagiotti^d, Débora Araújo de Carvalho^e, Gleyson Vieira dos Santos^e, João Vitor Moreira Passos^f, Romuere Rodrigues Veloso e Silva^f José Lindenberg Rocha Sarmiento^c

^a Programa de Pós-Graduação em Zootecnia, Centro de Ciências Agrárias, Universidade Federal do Piauí, Campus Universitário Ministro Petrônio Portella, Bairro Ininga, 64049-550, Teresina, PI, Brasil.

^b Zootecnista

^c Departamento de Zootecnia, Centro de Ciências Agrárias, Universidade Federal do Piauí, Campus Universitário Ministro Petrônio Portella, Bairro Ininga, 64049-550, Teresina, PI, Brasil.

^d Docente Colégio Técnico de Teresina – UFPI

^e Universidade Estadual do Piauí (UESPI), Teresina, PI, Brasil

^f Universidade Federal do Piauí (UFPI), Picos, PI, Brasil.

*Autor correspondente.

Endereços de e-mail: albirjunior@hotmail.com (F.A. Lima Júnior)

Resumo: A ultrassonografia de carcaça é uma técnica eficaz que fornece informações fundamentais para o produtor de carne ovina. por permitir auxiliar na identificação de animais com maior potencial de deposição de músculos nobres e maior rendimento de carcaça. Neste sentido, medidas do comprimento (COL) e a profundidade de olho de lombo (POL) permite medir a razão entre POL e COL, denominada de *Ratio* que permite comparar a morfometria muscular entre diferentes animais e auxiliar na seleção genética para melhor rendimento de carne Sendo assim, o objetivo com esta pesquisa foi analisar a capacidade de predizer características de carcaça, COL, POL e AOL, com auxílio da rede Yolov8, do algoritmo VGG e da arquitetura ResNet por meio do reconhecimento automatizado de imagens ultrassonográficas de carcaça de ovinos e calcular, medidas relacionadas, tais como, AOL ajustada para 30 kg de peso corporal (AOL30) e *Ratio*. Foram coletadas 263 imagens de ultrassom do músculo em questão de ovinos de corte para determinar as medidas AOL, COL e POL por profissional treinado utilizando a ferramenta online Roboflow. O conjunto de imagens foi dividido em imagens originais e imagens com limites AOL, POL e COL (máscaras de segmentação) para encontrar a região de interesse nas imagens com dimensão padronizada (224-224-3 pixels). Durante a segmentação, a rede Yolov8 foi utilizada para processar e ajustar as imagens, enquanto os algoritmos VGG e ResNet foram usados para validar e apresentar os resultados. O conjunto de imagens foi dividido entre treinamento do algoritmo (80%), validação (10%) e teste (10%). As métricas de precisão, mAP50 e *recall* foram usadas para verificar a similaridade entre os dois conjuntos de imagens. Para estimar as medidas de AOL, AOL30, COL, POL e *Ratio* a partir dos descritores da rede neural para as características das imagens segmentadas, três regressores foram usados: Adabooster (ABR), Random Forest (RFR) e GradientBoosting (GBR). Para avaliar a qualidade da regressão, foram calculados o quadrático médio dos resíduos (QMR), erro absoluto médio (MAE) e coeficiente de determinação (R^2). Para comparar as médias reais e previstas do AOL,

AOL30, POL, COL e *Ratio*, foi realizada análise de variância e teste t de Student a 95% de probabilidade. Dentre os regressores utilizados, o RFR foi o que apresentou melhor desempenho utilizando os algoritmos citados, demonstrando a robustez deste regressor. A similaridade entre o conjunto de imagens do especialista e do algoritmo foi avaliada, obtendo os valores de precisão, *recall* e mAP50 iguais a 1, verificando uma alta similaridade entre as imagens do especialista e do algoritmo. As médias previstas pela ferramenta e as encontradas pelo especialista não apresentaram diferenças significativas ($p > 0,05$), com os valores preditos apresentando menor variância, o que confirma maior precisão com a ferramenta utilizada. Portanto, a mensuração automática das medidas AOL, POL e COL pelo método computacional proposto a partir de imagens de ultrassom é promissora, pela maior precisão, garantindo retorno mais rápido da informação para o produtor de ovinos.

Palavras-chave: AOL, Ovinocultura, Pecuária de precisão, *Random Forest*, VGG

Abstract: Carcass ultrasonography is an effective technique that provides essential information for a producer who works with sheep suitable for slaughter, in addition to determining the ideal point for slaughter in an animal, in order to avoid loss of carcass quality. The length and depth of the rib eye (LRE and DRE) in cm, which has a positive correlation with the loin eye area and carcass yield, The relationship between LRE and DRE is called Ratio and is important to avoid the appearance of late muscularity. REA30 is used to reduce the environmental effect and to assess the animal's potential for meat cut yield. Computer vision tools can be used to evaluate animal carcass characteristics by recognizing ultrasound images of the animal's body by image segmentation algorithms. Therefore, the objective of this study is to analyze the ability of the Yolov8 network, the VGG algorithm, and the ResNet architecture to predict carcass characteristics, such as REA, DRE, and LRE, by recognizing ultrasound images of sheep carcasses and calculating related measures, such as REA30 and Ratio, to provide a better basis for carcass evaluation, bringing more information to the sheep producer. A total of 263 ultrasound images of the muscle of beef sheep were collected. The measurement of the rib eye area (REA) was recorded in mm, and through this measurement the other measurements could be extracted. The determination of the REA, DRE, and LRE measurements was performed with ultrasound by a trained professional. The collected images were taken for annotation using the Roboflow online tool. The set of images was divided into original images and images with REA limits (segmentation masks) to find the region of interest in the images with standardized dimensions (224-224-3 pixels). During segmentation, the Yolov8 network was used to process and adjust the images, while the VGG and ResNet algorithms were used to validate and present the results. The image set was divided between algorithm training (80%), validation (10%) and testing (10%). The precision, mAP50 and recall metrics were used to verify the similarity between the two image sets. To estimate the REA, REA30, DRE, LRE and Ratio measures from the neural network descriptors, i.e., feature vector of the segmented images, three regressors were used: Adabooster (ABR), Random Forest (RFR) and GradientBoosting (GBR). To assess the quality of the regression, the mean squared residuals (MSR), mean absolute error (MAE) and coefficient of determination (R^2) were calculated. To compare the real and predicted means of REA, REA30 and Ratio, analysis of variance and Student's t-test at 95% probability were performed. Among the regressors used, RFR was the one that presented the best performance using the aforementioned algorithms, demonstrating the robustness of this regressor. The similarity between the set of images from the expert and the algorithm was evaluated, obtaining precision, recall and mAP50 values equal to 1, verifying a high similarity between the images from the

expert and the algorithm. The means predicted by the tool and those found by the expert did not present significant differences ($p>0.05$), with the predicted values presenting lower variance, which confirms greater precision with the tool used. Therefore, the automatic measurement of this measurement by the proposed computational method from ultrasound images is promising, due to the greater precision than measurements performed by trained personnel, ensuring faster return of information to the sheep producer.

Keywords: Precision livestock farming, Random Forest, sheep farming, VGG

1. Introdução

A fim de ampliar e consolidar a produção e a comercialização da carne de ovinos, são utilizadas metodologias práticas e claras para caracterizar as medidas diretamente relacionadas com a qualidade da carcaça. A avaliação de características da carcaça, desta forma, fornece informações necessárias para caracterizar e determinar a tendência do animal. O conhecimento de medidas da carcaça permite estimar características quantitativas e qualitativas dos diferentes tecidos da carcaça, evitando-se assim uma carne de má qualidade (GOIS et al., 2019).

Vale ressaltar que, para ampliar a importância da carne ovina no mercado, é fundamental adaptar a produção ao mercado consumidor, cada vez mais exigente com a qualidade do produto. Na busca por maior rendimento de corte nobres, uma metodologia prática e eficaz para avaliar a carcaça de ovinos *in vivo* consiste na pesagem do indivíduo e na avaliação da carcaça por ultrassonografia. Essas tecnologias possibilitam prever algumas características produtivas como peso, rendimento e conformação da carcaça, tal como o rendimento dos cortes, avaliando, assim, o desempenho dos animais e auxiliando na decisão sobre o momento ideal para o abate e seleção dos melhores indivíduos para reprodução (SENA et al., 2016).

Uma dessas medidas importantes é o comprimento de olho de lombo (COL), que é extraído através da imagem ultrassonográfica do músculo *Longissimus dorsi* entre a 12^a e 13^a vértebras do ovino, possui correlação positiva com a área de olho de lombo e o rendimento da carcaça (PINHEIRO et al., 2010; SENA et al., 2016).

Outra medida importante para inferir informações sobre a carcaça é a profundidade de olho de lombo (POL). Esta característica está associada a quantidade de músculo da carcaça e possui alta correlação com a área de olho de lombo, além de ser positivamente correlacionada com a espessura de gordura subcutânea, peso da carcaça, marmoreio e com o COL. A relação entre essas duas medidas é denominada de *ratio*, que se trata da razão entre POL e COL, que é um índice utilizado para avaliar a conformação e a qualidade da carcaça em animais de produção (PHILIPPE et al., 2020).

A avaliação precisa do músculo *Longissimus dorsi* é crucial, pois sua conformação está diretamente relacionada ao rendimento e à qualidade dos cortes comerciais. Assim, um índice *Ratio* próximo de 0,5 a 0,7 indica uma forma mais equilibrada do músculo, sugerindo uma boa conformação e potencial para cortes de qualidade; quando maior que 0,7, sugere que o músculo é mais alto do que largo, o que pode indicar uma menor área de superfície e, possivelmente, menor rendimento de cortes comerciais; já quando menor que 0,4, pode indicar que o músculo é mais largo do que alto, o que pode ser desejável para determinados cortes e pode refletir em um melhor rendimento. (SUGUISAWA et al., 2013).

As características mensuradas no músculo *Longissimus dorsi* como o COL e a POL, tem sido utilizada para estudar a musculosidade da carcaça, com o uso de imagens ultrassonográficas durante a avaliação do animal *in vivo*. Além disso, a utilização da ultrassonografia é fundamental para identificar ovinos com potencial de musculosidade e acabamento de carcaça, nos programas de melhoramento genético, as medidas ultrassonográficas do músculo devem ser consideradas importantes. Além disso, torna-se fundamental a inclusão de mais medidas na avaliação de carcaça, para trazer mais informações ao produtor sobre a qualidade e a musculosidade (FIGUEIREDO FILHO et al. 2017).

Todavia, como qualquer medida depende de ultrassonografia, a determinação de COL e POL requerem o processamento da imagem por usuário treinado, o que demanda tempo e esforço repetitivo para gerar informações de muitos animais que adotem a avaliação de carcaça como rotina nas fazendas. Uma alternativa para ajudar nesse processo é a combinação de ultrassonografia com ferramentas de visão computacional, o que pode automatizar o reconhecimento de imagens ultrassonográficas das regiões de interesse do animal por algoritmos que segmentação de imagem (LIMA JÚNIOR et al., 2024).

Para a qualidade de ajuste aos dados, um dos algoritmos que extrai medidas de uma imagem, validando a ferramenta e apresentando os resultados, é o VGG que demonstra precisão no reconhecimento de imagem em larga escala. Já a ResNet (do inglês *Residual Network*) também apresenta resultados promissores e pode ser utilizada para a segmentação de imagens com eficácia e rapidez (HE et al., 2016; MAGGIORI et al., 2017).

Vale destacar, que é fundamental a obtenção de uma precisão elevada com um banco de imagens limitado. Além disso, é primordial a construção de uma ferramenta de fácil

manuseio e visualização pelos produtores de ovinos, além de uma demonstração clara dos resultados pela tecnologia. É importante, também, diminuir o gasto de energia, durante a coleta e análise de dados, no contexto da pecuária de precisão. (ZHAO et al., 2023; VAN HERTEM et al., 2017; STEFANOVA et al., 2019; DEBAUCHE et al., 2019)

Sendo assim, o objetivo com esta pesquisa é analisar a capacidade de prever as características de carcaça COL, POL, a partir da rede YOLOv8, do algoritmo VGG e da arquitetura ResNet por meio do reconhecimento de imagens ultrassonográficas de carcaça de ovinos e calcular *Ratio* em tempo real, com menor erro e maior agilidade.

2. Materiais e Métodos

2.1. Coleta de Dados

As características utilizadas no presente trabalho fazem parte do projeto “Estudo genômico aplicado ao melhoramento genético de ovinos Santa Inês para características de carcaça” e aprovado pela Comissão de Ética no Uso de Animais (CEUA/UFPI), nº 340/17, da Universidade Federal do Piauí, que integra o Instituto Nacional de Ciência e Tecnologia em Ciência Animal (INCT-CA) do CNPq, coordenado pela Universidade Federal de Viçosa.

Foram coletadas 263 imagens ultrassonográficas de resolução 393 x 497 pixels de ovinos da raça Santa Inês. As imagens foram obtidas de um ultrassom da marca *sonoscape* modelo A5V equipado com um transdutor multifrequencial com frequência variando entre 7,5 a 8,5 MHz (Figura 1).



Figura 1: Ultrassom utilizado durante as coletas de imagens da carcaça

A determinação da medida de COL e POL foi realizada através da ferramenta de medida do próprio aparelho de ultrassom por profissional treinado. As imagens coletadas

foram levadas para anotação, em seguida, compiladas em uma versão para processamento e extração da medida de COL e POL através do *software ImageJ* (BRITO et al., 2022).

Já o *Ratio* é calculado através da relação entre POL e COL, conforme descrito na equação 1, expressa em valores absolutos.

$$(1) \quad Ratio = \frac{POL}{COL}$$

2.2. Pré-processamento das imagens

A base de dados foi dividida em imagens originais e imagens com as delimitações de AOL e que originaram as médias para AOL (máscaras de segmentações). As originais foram coloridas em RGB – *Red-Green-Blue* (Vermelho-Verde-Azul) e as máscaras de segmentação são imagens binárias. A delimitação de AOL foi necessária para a determinação das medidas de COL e POL que já estão incluídas na AOL.

Observou-se que ambos os conjuntos, original e máscara, estavam em escala de cinza, sendo formado por um único canal de cor. Sendo assim, evita-se a utilização de informações repetidas e processamento desnecessário.

Em seguida, operações foram realizadas para obter somente a ROI – *Region of Interest* (Região de Interesse). Este último passo foi necessário para evitar dados desnecessários ao longo do experimento, evitando um custo computacional adicional e indução de erros. Para não se ter problemas com as dimensões, optou-se por redimensionar as imagens para o formato mais usual de rede neural (224x224pixels) para obter a ROI. Para ajustar as imagens para o padrão usual utilizou-se a rede Yolov8 (Terven et al., 2023), para validação e apresentação dos resultados utilizaram-se os algoritmos VGG e o ResNet (HE et al., 2016; TAMMINA, 2019).

2.3. Segmentação das regiões de interesse

Para a segmentação, utilizou-se dois algoritmos de segmentação automatizado VGG e ResNet. O VGG e a ResNet extraem as características da imagem, utilizando descritores e filtros convolucionais, utilizando o método *regionprops* da biblioteca *skimage*.

O objetivo foi realizar marcações próximas ou iguais as feita pelo especialista que coletou as imagens no ultrassom e ajustou as mesmas no *software ImageJ* (BRITO et al., 2022). Os algoritmos foram escolhidos com base em sua relevância para a segmentação em imagens de ultrassom (HE et al., 2016; TAMMINA, 2019; TARG et al., 2016).

Durante a segmentação, do total das imagens, 80% foram utilizadas para treinar o algoritmo, 10% para validar a ferramenta e 10% para testar o método (HE et al., 2016; TARG et al., 2016).

2.4. Métricas de segmentação

Para avaliação das segmentações automatizadas, três métricas foram utilizadas que indicam a qualidade das segmentações. Cada uma dessas métricas são abordadas abaixo.

A precisão (Equação 1) dos objetos detectados, indica quantas detecções estavam corretas. Já a *recall* (Equação 2) calcula a proporção de mensurações corretas, medindo a capacidade do modelo de identificar todas as partes da imagem. Enquanto a mAP50 (Equação 3) refere-se à precisão média calculada com um limiar de intersecção sobre união (IoU) de 0,50 (outra métrica que indica a similaridade entre dois conjuntos de imagens). A mAP50 é uma medida que avalia a precisão do modelo (ZHAO et al., 2023).

$$\text{Equação (4)} \quad \text{Precisão} = \frac{|VP|}{|VP| + |FP|}$$

$$\text{Equação (5)} \quad \text{Recall} = \frac{|VP|}{|VP| + |FN|}$$

$$\text{Equação (6)} \quad mAP50 = \frac{1}{m} \sum_{t=1}^m AP_t$$

Onde VP significa verdadeiros positivos, quando o algoritmo categoriza a imagem, por exemplo, indicando a medida de AOL como AOL na imagem; já o FP categoriza uma imagem, por exemplo, indicando AOL como outra medida na imagem; enquanto FN não categorizar a imagem, não categorizando a medida de AOL como AOL na imagem. Ou seja, a precisão mede a porcentagem de imagens classificadas corretamente, o quanto o modelo é preciso. Já a *recall* o quão bem o modelo gera as mensurações corretas. A mAP50 é a precisão média, ou seja, a média dos valores de precisão máxima, sendo AP o valor da precisão (ZHAO et al., 2023).

2.5. Extração de características

Com o intuito de encontrar características importantes, tais como o COL e POL para a previsão de AOL, a extração de características foi investigada usando um algoritmo de forma (*shape*) para analisar as imagens e uma rede neural artificial pré-treinada (*Yolov8*) utilizando o *software ImageJ*, para anotação online para construir bancos de dados de imagens para pesquisa de visão computacional (BRITO et al., 2022). Para validar e

apresentar os resultados, utilizou-se os algoritmos *VGG* e *ResNet* que obteve a AOL a partir de cada imagem (MAGGIORI et al., 2017).

2.6. Análise de Regressão

A análise de regressão foi dada pela relação entre uma variável dependente e uma ou mais variáveis independentes, sendo a variável dependente “Y” a medida prevista para a imagem de ultrassom do animal e as independentes “X”, os valores das características obtidas com os descritores da rede neural, ou seja, as características que a rede obtém de uma imagem ou vetor de características (*VGG* ou *ResNet*).

Utilizou-se três algoritmos de regressão, *AdaBoost Regressor*, *Random Forest Regressor* e *GradientBoosting Regressor*. (CAO et al., 2013; BREIMAN, 1996; KEPRATE, 2017). O conjunto de características foi dividido, com os valores já normalizados entre 0 e 1, em treinamento (80%), validação (10%) e teste (10%), respectivamente. Os três algoritmos foram treinados e validados no conjunto de treinamento e validação e o modelo foi testado no conjunto de teste (CHENG et al., 2022).

2.7. Métricas de Regressão

As métricas usadas para avaliar o desempenho de modelos de regressão são abordadas e estão disponíveis na Biblioteca *Scikit-Learn*: QMR (Quadrado Médio do Resíduo), EMA (Erro Médio Absoluto) e o valor da medida de ajuste do modelo de regressão (R^2) (KRAMER, 2016).

A equação 7 indica o valor do Quadrado Médio dos Resíduos (QMR) e calcula a média dos erros do modelo ao quadrado, ou seja, diferenças menores são menos importantes, enquanto as diferenças maiores recebem mais peso, aonde y_i é o valor real e $\hat{y}_i$ é o valor predito.

$$(7) \quad QMR(y, \hat{y}) = \frac{1}{n_{amostras}} \sum_{i=0}^{n_{amostras}-1} (y_i - \hat{y}_i)^2$$

A equação 8 representa o valor do Erro Quadrático Médio Absoluto (EMA) e é uma métrica de risco, sendo y_i o valor real e $\hat{y}_i$ é o valor predito.

$$(8) \quad EMA(y, \hat{y}) = \frac{1}{n_{amostras}} \sum_{i=0}^{n_{amostras}-1} |y_i - \hat{y}_i|^2$$

A equação 9 representa o coeficiente de determinação de regressão (R^2), sendo y_i o valor real e $\hat{y}_i$ é o valor predito.

$$(9) \quad R^2(y, \hat{y}) = 1 - \frac{\sum_{i=0}^{n_{amostras}-1} (y_i - \hat{y}_i)^2}{\sum_{i=0}^{n_{amostras}-1} (y_i - \bar{y})^2}$$

A análise de regressão foi realizada por meio da linguagem de programação em *Python* (Python, 2024).

2.8. Estatística descritiva e comparação de médias

As médias de COL, POL e *Ratio* e determinadas por especialista com ultrassom (medidas reais) e as previstas pela ferramenta computacional (medidas previstas) a partir das imagens de ultrassom foram submetidas a análises descritivas, a partir do coeficiente de variação, o erro padrão e o intervalo de confiança para a média construído a 95% de probabilidade, e foram comparadas pelo teste “t” de *student* pareado para comparação das médias a 5% de probabilidade. Estes procedimentos foram realizados com o auxílio da linguagem de programação *Python* (PYTHON, 2024).

3. Resultados

3.1. Resultados da segmentação

As métricas de precisão, *recall* e mAP50 foram utilizadas para comparação entre a máscara realizada pelo especialista e a obtida através dos algoritmos e o grau de exatidão das detecções feitas pela ferramenta, conforme observa-se na Tabela 1.

Tabela 1: Resultados da segmentação realizada com a rede YOLOv8

Métricas de Segmentação	Precisão	mAP50	<i>Recall</i>
AOL	0,98	0,99	1,00

De acordo com a Tabela 1, estão representados os resultados obtidos com a segmentação automatizada a partir das imagens ultrassonográficas dos ovinos por meio da utilização do algoritmo YOLOv8. Os resultados da segmentação das 263 imagens de ultrassom foram apresentados na Tabela 1.

As métricas utilizadas são métricas de similaridade, que compara dois resultados, ou seja, os três índices mostram semelhança entre duas amostras de dados, visto que quanto mais próximo de 1 for o valor, melhor será o resultado e maior será a semelhança entre o mensurado e o predito. Os valores das métricas foram próximas ou iguais a 1, o que demonstra que entre todos os objetos que estavam na imagem, o modelo conseguiu encontrar 100% da característica de AOL (*recall* = 1) em todas as imagens, usadas para

teste da ferramenta. Desta forma, o modelo conseguiu identificar a característica da AOL corretamente, ou seja, ele conseguiu deduzir que tinha uma AOL na imagem e assim este algoritmo se mostrou eficiente e robusto na tarefa de segmentação das imagens.

3.2. Resultados da Análise de Regressão

Os resultados obtidos com os regressores *AdaBoost Regressor*, *Random Forest Regressor* e *Gradient Boosting Regressor* são apresentados nas tabelas 2, 3, 4 e 5 para as medidas de COL, POL e *Ratio*, respectivamente. Os resultados foram separados em experimentos com as medidas extraídas das segmentações feitas, manualmente, utilizando *VGG* e *ResNet*.

Tabela 2: Resultados obtidos com a regressão, para a medida COL usando os regressores *AdaBoost*, *Regressor*, *Random Forest* e *GradientBoosting* nas imagens obtidas por segmentação usando *Yolov8*, para os algoritmos *VGG* e *ResNet*.

	<i>Adabooster</i>			<i>RandomForest</i>			<i>GradientBoosting</i>		
	EMA	QMR	R ²	EMA	QMR	R ²	EMA	QMR	R ²
<i>VGG</i>	0,47	0,33	0,33	0,48	0,33	0,33	0,48	0,37	0,32
<i>ResNet</i>	0,48	0,36	0,27	0,47	0,34	0,31	0,47	0,34	0,32

QMR: Quadrado Médio do Resíduo; EMA: Erro Médio Absoluto; R²: Coeficiente de determinação da variância.

Tabela 3: Resultados obtidos com a regressão, para a medida POL usando os regressores *AdaBoost*, *Regressor*, *Random Forest* e *GradientBoosting* nas imagens obtidas por segmentação usando *Yolov8*, para os algoritmos *VGG* e *ResNet*.

	<i>Adabooster</i>			<i>RandomForest</i>			<i>GradientBoosting</i>		
	EMA	QMR	R ²	EMA	QMR	R ²	EMA	QMR	R ²
<i>VGG</i>	0,19	0,05	0,32	0,18	0,05	0,38	0,20	0,06	0,29
<i>ResNet</i>	0,19	0,05	0,37	0,20	0,06	0,31	0,20	0,06	0,29

QMR: Quadrado Médio do Resíduo; EMA: Erro Médio Absoluto; R²: Coeficiente de determinação da variância.

Tabela 4: Resultados obtidos com a regressão, para a medida *Ratio* usando os regressores *AdaBoost*, *Regressor*, *Random Forest* e *GradientBoosting* nas imagens obtidas por segmentação usando *Yolov8*, para os algoritmos *VGG* e *ResNet*.

	<i>Adabooster</i>			<i>RandomForest</i>			<i>GradientBoosting</i>		
	EMA	QMR	R ²	EMA	QMR	R ²	EMA	QMR	R ²
<i>VGG</i>	0,12	0,03	0,00	0,12	0,03	0,01	0,14	0,03	0,00
<i>ResNet</i>	0,13	0,04	0,00	0,15	0,04	0,00	0,14	0,04	0,00

QMR: Quadrado Médio do Resíduo; EMA: Erro Médio Absoluto; R²: Coeficiente de determinação da variância.

Tabela 5: Resultados obtidos com a regressão, para a medida AOL usando os regressores *AdaBoost*, *Regressor*, *Random Forest* e *GradientBoosting* nas imagens obtidas por segmentação usando *Yolov8*, para os algoritmos *VGG* e *ResNet*.

	<i>Adabooster</i>			<i>RandomForest</i>			<i>GradientBoosting</i>		
	EMA	QMR	R ²	EMA	QMR	R ²	EMA	QMR	R ²
<i>VGG</i>	1,22	2,37	0,71	1,13	2,08	0,74	1,14	2,11	0,74
<i>ResNet</i>	1,30	2,70	0,67	1,16	2,20	0,73	1,20	2,26	0,72

QMR: Quadrado Médio do Resíduo; EMA: Erro Médio Absoluto; R²: Coeficiente de determinação da variância.

De acordo com as tabelas 2, 3 e 4, o regressor *Random Forest* (RF) quando algoritmo *VGG* é utilizado, apresentou resultados mais promissores que os demais algoritmos indicando maior qualidade de ajuste aos dados na regressão, maior desempenho no modelo e maior capacidade de prever resultados com maior precisão, ou seja, o RF e o *VGG* tiveram melhor ajuste do modelo aos dados observados.

Além disso, o *VGG* em conjunto com o RF, por apresentar menor EMA que os demais, demonstraram uma maior acurácia no modelo, indicando maior eficiência. Portanto, ao se utilizar o regressor *Random Forest* para avaliar a qualidade da regressão e o *VGG* para validar e apresentar os resultados, os resultados serão mais robustos e promissores.

Nas Figuras 2, 3 e 4 estão representados os gráficos das análises de regressão realizada a partir dos resultados obtidos com os três regressores mencionados anteriormente, para os 2 algoritmos mencionados, para a característica AOL, COL e POL, respectivamente. Observa-se que os valores preditos pela metodologia proposta se aproximam dos valores reais, representando no gráfico uma correlação positiva entre os valores preditos e reais.




Figura 2: Dispersão dos valores reais e preditos para o algoritmo VGG e Adabooster (2a), VGG e Random Forest (2b), VGG e GradientBoosting (2c), ResNet e Adabooster (2d), ResNet e Random Forest (2e), ResNet e GradientBoosting (2f) para a característica AOL.




Figura 3: Dispersão dos valores reais e preditos para o algoritmo VGG e Adabooster (3a), VGG e Random Forest (3b), VGG e GradientBoosting (3c), ResNet e Adabooster (3d), ResNet e Random Forest (3e), ResNet e GradientBoosting (3f) para a característica COL.




Figura 4: Dispersão dos valores reais e preditos para o algoritmo VGG e Adabooster (4a), VGG e Random Forest (4b), VGG e GradientBoosting (4c), ResNet e shape (4d), ResNet e Random Forest (4e), ResNet e GradientBoosting (4f) para a característica POL.

Notou-se que os valores de R^2 para o *Random Forest* foram maiores em comparação aos outros regressores e os dados para este algoritmo mostraram-se menos dispersos nos gráficos 2b, 2e, 3b, 3e, 4b e 4e o que demonstra maior qualidade na regressão e melhor ajuste da equação aos dados, sendo que os gráficos 2b, 3b e 4b (*Random Forest* e *VGG*) demonstra menor dispersão dos dados e maior qualidade de ajuste na regressão, ou seja, maior precisão encontrada para a AOL, COL e POL, respectivamente.

Nas Tabelas 6, 7, 8 e 9 estão representadas as estatísticas descritivas das médias de características preditas e a mensuradas em ovinos, que foram submetidas a comparação de médias pelo teste “t” de *student*, para cada um dos métodos e regressores, utilizando o algoritmo *VGG* e *ResNet*.

Tabela 6: Estatística descritiva das médias das relações *Ratio* reais e preditas em Ovinos para o algoritmo *VGG*.

Método Regressor	+	Característica estudada	μ	CV	A	Intervalo de confiança para a média a 95% de probabilidade	
						Limite inferior	Limite superior
<i>VGG + Adabooster</i>		<i>Ratio</i> observada	0,76a	22,00	0,68	0,55	1,23
		<i>Ratio</i> predita	0,71a	5,00	0,16	0,64	0,79
<i>VGG + RandomForest</i>		<i>Ratio</i> observada	0,76a	22,00	0,68	0,55	1,23
		<i>Ratio</i> predita	0,70a	5,00	0,15	0,64	0,79
<i>VGG + GradientBoosting</i>		<i>Ratio</i> observada	0,76a	22,00	0,68	0,55	1,23
		<i>Ratio</i> predita	0,69a	9,00	0,25	0,56	0,81

$\hat{\mu}$: média; CV: coeficiente de variação (%); A: amplitude; a: médias seguidas de mesma letra não diferem estatisticamente pelo teste t ao nível de 5% de probabilidade.

Tabela 7: Estatística descritiva das médias das relações *Ratio* reais e preditas em Ovinos para o algoritmo *ResNet*.

Método Regressor	+	Característica estudada	μ	CV	A	Intervalo de confiança para a média a 95% de probabilidade	
						Limite inferior	Limite superior
<i>VGG + Adabooster</i>		<i>Ratio</i> observada	0,76a	22,00	0,68	0,55	1,23
		<i>Ratio</i> predita	0,70a	6,00	0,16	0,62	0,78
<i>VGG + RandomForest</i>		<i>Ratio</i> observada	0,76a	22,00	0,68	0,55	1,23
		<i>Ratio</i> predita	0,72a	7,00	0,19	0,64	0,83
<i>VGG + GradientBoosting</i>		<i>Ratio</i> observada	0,76a	22,00	0,68	0,55	1,23
		<i>Ratio</i> predita	0,72a	8,00	0,22	0,64	0,86

$\hat{\mu}$: média; CV: coeficiente de variação (%); A: amplitude; a: médias seguidas de mesma letra não diferem estatisticamente pelo teste t ao nível de 5% de probabilidade.

Tabela 8: Estatística descritiva das médias das relações AOL reais e preditas em Ovinos para o algoritmo *VGG*.

Método Regressor	+	Característica estudada	μ	CV	A	Intervalo de confiança para a média a 95% de probabilidade	
						Limite inferior	Limite superior
<i>VGG + Adabooster</i>		AOL observada	6,90a	41,00	14,16	1,74	15,90
		AOL predita	7,10a	30,00	8,73	4,45	13,19
<i>VGG RandomForest</i>	+	AOL observada	6,90a	41,00	14,16	1,74	15,90
		AOL predita	6,97a	31,00	9,47	3,65	13,12
<i>VGG GradientBoosting</i>	+	AOL observada	6,90a	41,00	14,16	1,74	15,90
		AOL predita	7,00a	33,00	10,83	3,42	14,25

$\hat{\mu}$: média; CV: coeficiente de variação (%); A: amplitude; a: médias seguidas de mesma letra não diferem estatisticamente pelo teste t ao nível de 5% de probabilidade.

Tabela 9: Estatística descritiva das médias das relações AOL reais e preditas em Ovinos para o algoritmo *ResNet*.

Método Regressor	+	Característica estudada	μ	CV	A	Intervalo de confiança para a média a 95% de probabilidade	
						Limite inferior	Limite superior
<i>VGG + Adabooster</i>		AOL observada	6,90a	41,00	14,16	1,74	15,90
		AOL predita	7,07a	30,00	8,65	4,63	13,28
<i>VGG RandomForest</i>	+	AOL observada	6,90a	41,00	14,16	1,74	15,90
		AOL predita	7,06a	30,00	9,98	3,69	13,67
<i>VGG GradientBoosting</i>	+	AOL observada	6,90a	41,00	14,16	1,74	15,90
		AOL predita	7,08a	31,00	10,44	3,56	14,00

$\hat{\mu}$: média; CV: coeficiente de variação (%); EPM: erro padrão da média; A: amplitude; a: médias seguidas de mesma letra não diferem estatisticamente pelo teste t ao nível de 5% de probabilidade.

Tabela 12: Estatística descritiva das médias das relações COL reais e preditas em Ovinos para o algoritmo *VGG*

Método Regressor	+	Característica estudada	μ	CV	A	Intervalo de confiança para a média a 95% de probabilidade	
						Limite inferior	Limite superior
<i>VGG + Adabooster</i>		COL observada	3,08a	23,00	3,21	1,70	4,91
		COL predita	2,99a	10,00	1,33	2,52	3,85
<i>VGG</i> <i>RandomForest</i>	+	COL observada	3,08a	23,00	3,21	1,70	4,91
		COL predita	3,03a	10,00	1,51	2,48	3,98
<i>VGG</i> <i>GradientBoosting</i>	+	COL observada	3,08a	23,00	3,21	1,70	4,91
		COL predita	3,00a	12,00	1,72	2,36	4,08

$\hat{\mu}$: média; CV: coeficiente de variação (%); EPM: erro padrão da média; A: amplitude; a: médias seguidas de mesma letra não diferem estatisticamente pelo teste t ao nível de 5% de probabilidade.

Tabela 13: Estatística descritiva das médias das relações COL reais e preditas em Ovinos para o algoritmo *ResNet*

Método Regressor	+	Característica estudada	μ	CV	A	Intervalo de confiança para a média a 95% de probabilidade	
						Limite inferior	Limite superior
<i>ResNet</i> <i>Adabooster</i>	+	COL observada	3,08a	23,00	3,21	1,70	4,91
		COL predita	2,97a	9,00	1,21	2,50	3,72
<i>ResNet</i> <i>RandomForest</i>	+	COL observada	3,08a	23,00	3,21	1,70	4,91
		COL predita	2,98a	8,00	1,20	2,39	3,59
<i>ResNet</i> <i>GradientBoosting</i>	+	COL observada	3,08a	23,00	3,21	1,70	4,91
		COL predita	2,98a	11,00	1,58	2,36	3,94

$\hat{\mu}$: média; CV: coeficiente de variação (%); EPM: erro padrão da média; A: amplitude; a: médias seguidas de mesma letra não diferem estatisticamente pelo teste t ao nível de 5% de probabilidade.

Tabela 14: Estatística descritiva das médias das relações POL reais e preditas em Ovinos para o algoritmo *VGG*

Método Regressor	+	Característica estudada	μ	CV	A	Intervalo de confiança para a média a 95% de probabilidade	
						Limite inferior	Limite superior
<i>VGG + Adabooster</i>		POL observada	2,46a	11,00	1,36	1,86	3,22
		POL predita	2,49a	7,00	0,77	2,14	2,91
<i>VGG + RandomForest</i>		POL observada	2,46a	11,00	1,36	1,86	3,22
		POL predita	2,46a	8,00	0,93	2,05	2,98
<i>VGG + GradientBoosting</i>		POL observada	2,46a	11,00	1,36	1,86	3,22
		POL predita	2,45a	9,00	1,10	1,88	2,99

$\hat{\mu}$: média; CV: coeficiente de variação (%); EPM: erro padrão da média; A: amplitude; a: médias seguidas de mesma letra não diferem estatisticamente pelo teste t ao nível de 5% de probabilidade.

Tabela 15: Estatística descritiva das médias das relações POL reais e preditas em Ovinos para o algoritmo *ResNet*

Método Regressor	+	Característica estudada	μ	CV	A	Intervalo de confiança para a média a 95% de probabilidade	
						Limite inferior	Limite superior
<i>ResNet + Adabooster</i>		POL observada	2,46a	11,00	1,36	1,86	3,22
		POL predita	2,46a	9,00	0,89	2,04	2,93
<i>ResNet + RandomForest</i>		POL observada	2,46a	11,00	1,36	1,86	3,22
		POL predita	2,45a	9,00	0,85	1,98	2,83
<i>ResNet + GradientBoosting</i>		POL observada	2,46a	11,00	1,36	1,86	3,22
		POL predita	2,48a	10,00	1,03	1,91	2,94

$\hat{\mu}$: média; CV: coeficiente de variação (%); EPM: erro padrão da média; A: amplitude; a: médias seguidas de mesma letra não diferem estatisticamente pelo teste t ao nível de 5% de probabilidade.

As médias de *ratio* observada e predita, assim como de AOL, COL e POL observada e predita foram muito próximas e não tiveram diferenças significativas pelo teste t de *student*, em todos os casos, o que evidencia a eficiência e robustez da utilização de algoritmos de visão computacional, para estudo de características na carcaça. Fica evidente a contribuição que esta ferramenta computacional pode trazer para a fenotipagem em larga escala da avaliação de carcaça em ovinos de corte, por disponibilizar mais informações sobre os animais em estudo, de maneira automatizada, contribuindo para a escrituração zootécnica nos programas de melhoramento genético de ovinos.

Observou-se que o CV para a característica predita foi menor do que obtido para a característica mensurada, significando menor dispersão nos dados nos resultados encontrados na utilização de algoritmos para a estatística descritiva, ou seja, houve menor variabilidade dos dados, indicando maior acurácia nas características reais e nas preditas que no observado, demonstrando dados mais homogêneos na AOL e no *ratio* preditos.

Verificou-se ainda que a amplitude (A) e o intervalo de confiança (IC) foram menores para a AOL, COL, POL e *ratio* preditas, o que se deve a padronização imposta aos dados coletados (atribuição fixa de funções), a qual apenas o profissional com experiência em coleta de ultrassom realiza o registro das imagens, ficando assim evidente assim o sucesso, a robustez e a confiabilidade da ferramenta computacional.

A confiabilidade nas medidas preditas foi maior do que na observada, evidenciando a importância da utilização da ferramenta tecnológica, por ter resultados mais promissores. Verificou-se também que a partir do intervalo de confiança construído fica evidente, mais uma vez, a maior confiabilidade para as medidas preditas pelo algoritmo, destacando que a utilização de algoritmos para prever esta característica em ovinos demonstrou-se eficiente

Embora, ocorra diferença na variabilidade das características observadas e preditas, as médias calculadas foram muito próximas, não apresentando diferença significativa entre elas, o que evidencia, precisão, robustez e eficiência na predição para a medida determinado pelos algoritmos propostos, visto que se aproxima bastante da mensuração feita pelo especialista, com menor variação nas medidas preditas.

4. Discussão

Na avaliação da segmentação das imagens, observou-se precisão, *recall* e mAP50 máximos, ou seja, os algoritmos de visão computacional do presente trabalho podem ser utilizados para prever características de carcaça de ovelhas com precisão e confiabilidade, sendo ferramentas úteis e práticas para prever medidas de carcaça, reafirmando que o modelo foi eficiente e cumpriu o objetivo de segmentar as imagens de ovelhas com precisão e desempenho desejável, corroborado por BAUTISTA-DÍAZ et al. (2020) e PENG et al. (2024)

A rede Yolov8 demonstrou precisão, *recall* e mAP50 semelhantes aos descrito por YU et al. (2024) e GUARNIDO-LOPEZ et al. (2024), ao estudar características de ovelhas, constatando que quanto maior for o banco de dados, melhor serão os resultados das métricas, visto que quanto mais próximo de 1, maior a presença de características

corretamente reconhecidas pela ferramenta, em comparações às medições feita pelo especialista, demonstrando também que se as condições, durante a coleta, foram mantidas as mesmas, os resultados serão satisfatórios mesmo com a quantidade reduzida de imagens.

Além disso, torna-se fundamental na análise a inclusão de outras métricas além da precisão, pois calcula a velocidade de detecção das características, e será otimizada a acurácia dos modelos, para situações de métricas com baixo desempenho, conforme observado por NG (2018).

Portanto, o modelo apresentado demonstrou precisão e estabilidade, com robustez e desempenho na tarefa de segmentação de imagens de ovelhas para obtenção de características de carcaça, tendo o processamento independente melhorado a execução do método, assim como o observado por PENG et al. (2024) e PEI et al. (2024).

Observou-se, no presente trabalho que o Random Forest teve desempenho superior aos outros regressores, corroborando os trabalhos de TIRINK (2023), MANSBRIDGE et al. (2018), LIMA JÚNIOR et al. (2024), e BERIAN et al. (2021) por apresentar menor EMA e QMR e maior R^2 indicando que o modelo proposto no presente trabalho se ajustou melhor aos dados e apresentou menor dispersão nos dados, para ambos os algoritmos apresentados, em todas as características estudadas.

O Random Forest apresenta resultados robustos e precisos, permitindo trabalhar-se com dados com alta dimensionalidade e evitando que o modelo não consiga fazer previsões precisas para dados que não sejam os de treinamento do algoritmo, conforme descrito por CAMACHO-PÉREZ et al. (2023). O modelo é um bom preditor, com a inclusão do Random Forest para características de carcaça de ovelhas, melhorando os resultados.

Dentre os algoritmos, O VGG foi o que apresentou os melhores resultados, utilizando diferentes regressores, tendo melhor desempenho e robustez nos resultados por apresentar, menores valores de EMA e QMR e maior R^2 , confirmando o sucesso do algoritmo. BIMANTORO et al. (2021), ao trabalharem com as arquiteturas de rede para o estudo de ovelhas, observaram que o VGG teve resultados superiores ao *ResNet*, por poder auxiliar os criadores de ovelhas a ter uma estimativa precisa e de baixo custo do rendimento de carne e gerenciamento de custos. ZHAO et al. (2021), ao estudarem características de ovelhas, afirmaram que o modelo pode identificar com precisão,

utilizando o VGG, as diferentes medidas das ovelhas, atendendo aos requisitos da linha de produção de ovinos.

Desta forma, o algoritmo VGG e o regressor *Random Forest*, apresentaram resultados mais promissores demonstrando maior acurácia, robustez e precisão, pois o R^2 foi maior e o QMR e o EMA foram menores, dentre as características estudadas. Os valores de R^2 encontrados para as características de COL e POL foram semelhantes aos apresentados por PINHEIRO et al. (2010), no estudo de características de carcaça de ovelhas, comprovando bom ajustamento da equação aos dados. Já o valor de *Ratio* foi negativo indicando baixa precisão da equação.

Observou-se que a AOL e *Ratio* preditas na estatística descritiva teve resultados melhores que a AOL e *Ratio* mensurada, indicando melhor qualidade de ajuste aos dados e menor erro de predição, corroborando o trabalho de TAVEIRA et al. (2016), PHILIPPE et al. (2020) para bovinos e PINHEIRO et al. (2010) para ovinos,

Embora a diferença na variabilidade da AOL e *Ratio* tomadas, as médias obtidas foram muito semelhantes, sem diferenças significativas, entre elas, destacando a acurácia na predição para a medida determinada pelos algoritmos propostos, pois é muito próxima da medida feita pelo profissional, com menor variação, mostrando que a que a ferramenta é capaz de prever com precisão medidas na carcaça, facilitando assim a coleta em campo, assim como o observado por SENNA et al. (2020), LIMA JÚNIOR et al. (2024) ao avaliarem características de carcaça em ovinos da raça Santa Inês.

SUGUISAWA et al. (2013) observaram que uma alternativa à utilização das medidas de AOL em valores brutos, é a utilização da medida *Ratio*, que é uma medida relacionada a conformação do músculo, estando relacionada à produção de carcaças mais volumosas. A medida AOL ajustada ao peso reduz o efeito ambiental e calcula o potencial do animal para rendimento de cortes cárneos.

Observou-se que o CV para as medidas preditas, em todos os casos, foi menor do que obtido para as medidas observadas, observando menor dispersão de dados nos resultados encontrados pela ferramenta computacional (Tabelas 5 e 6), conforme o observado por TAVEIRA et al. (2016), LIMA JÚNIOR et al (2024) e SENA et al. (2016) e ao avaliarem a carcaça de ovinos.

Constatou-se ainda que a amplitude (A) e o intervalo de confiança (IC) e a variância foram menores para as medidas predita, em todos os casos, indicando dados menos

dispersos, e fica evidente, também, a maior confiabilidade da estimativa para AOL e *Ratio* predita pelos algoritmos, por conta da padronização adotada nos dados coletados, confirmando assim, o sucesso e a robustez da ferramenta computacional, corroborado por SENA et al. (2016) e LIMA JÚNIOR et al. (2024) no estudo de ovinos Santa Inês. A menor variância no predito deixa estabelecido que houve menor variação nos dados preditos pelos algoritmos utilizada, o que deixa evidenciado maior precisão e robustez na ferramenta.

Os resultados do presente trabalho foram semelhantes aos descritos por HASHIMOTO et al. (2007), PHILIPPE et al. (2020), SANTOS et al. (2019) e PINHEIRO et al. (2010) que observaram que as medidas de profundidade máxima do músculo (POL) e comprimento de olho de lombo (COL), apresentam alta correlação com a área de olho-de-lombo e, conseqüentemente, a musculosidade e o rendimento da carcaça. SANTOS et al. (2019) afirmam que a medida de profundidade do músculo tem mais relação com a AOL do que medida de comprimento. Sendo assim, essas medidas podem servir para avaliar as características da carcaça ovina por ser facilmente determinadas e pela precisão obtida.

Ressaltando a questão da padronização (apenas 1 especialista coletando a imagem ultrassonográfica), SANTOS et al. (2019) e LIMA JÚNIOR et al. (2024) afirmam que quando a avaliação de carcaça é realizada por mais de um especialista, pode-se aumentar o erro experimental, diminuindo a precisão na análise. Sendo ressaltada a importância da padronização para ter resultados com precisão razoável mesmo trabalhando com um banco de imagens limitado.

Vale ressaltar também, a importância da fenotipagem na rotina de coleta de imagens contribuindo, significativamente, para uma escrituração zootécnica mais efetiva, melhorando, assim, os resultados obtidos nas análises. Quanto mais imagens forem coletadas, maior será a quantidade de informações obtidas e, conseqüentemente, mais precisos serão os resultados, corroborando os resultados obtidos por LIMA JÚNIOR et al. (2024). Este processo é fundamental para os programas de melhoramento genético e para outras áreas da produção animal de ovinos de corte que podem utilizar dessas informações para a tomada de decisões, pois permite um monitoramento maior dos indivíduos facilitando, assim, na seleção dos animais.

5. Conclusão

Os algoritmos de visão computacional podem prever com precisão e robustez, as características de área, comprimento, profundidade e *Ratio* do músculo *Longissimus dorsi*, otimizando, assim, a coleta em campo, trazendo dinamicidade e rapidez.

As ferramentas de visão computacional combinadas com a ultrassonografia, auxiliam, consideravelmente a coleta e análise de imagens no campo, trazendo dinamismo, precisão, robustez e eficiência para a fenotipagem de precisão para características de carcaça em ovinos, diminuindo o tempo e o custo na obtenção de dados nas propriedades de ovinos.

6. Referências bibliográficas

- BAUTISTA-DÍAZ, E. et al. Prediction of Carcass Traits of Hair Sheep Lambs Using Body Measurements. **Animals**, v.10, p.1276. 2020. Available from: <<https://doi.org/10.3390/ani10081276>>. Accessed: Mai. 27, 2025. doi: 10.3390/ani10081276.
- BIMANTORO, M.Z. et al. Sheep Face Classification using Convolutional Neural Network. **IEEE**, p.111-115. 2021. Available from: <<https://doi.org/10.1109/EIConCIT50028.2021.9431933>>. Accessed: Mai. 27, 2025. doi: 10.1109/EIConCIT50028.2021.9431933.
- BREIMAN, L. Bagging predictors. **Machine Learning**, v.24, p.123–140. 1996. Available from: <<https://doi.org/10.1007/BF00058655>>. Accessed: Mai. 24, 2025. doi: 10.1007/BF00058655.
- BRITO, L.S. et al. Evaluation of ImageJ software in ultrasonic image analysis: Follicular and luteal morphological characteristics of cattle. **Animal Reproduction Science**, v.236, p.106907. 2022. Available from: <<https://doi.org/10.1016/j.anireprosci.2021.106907>>. Accessed: Mai. 24, 2025. doi: 10.1016/j.anireprosci.2021.106907.
- CAO, Y. Advance and Prospects of AdaBoost Algorithm. **Acta Automatic Sinica**, v.39, p.745-758. 2013. Available from: <[https://doi.org/10.1016/S1874-1029\(13\)60052-X](https://doi.org/10.1016/S1874-1029(13)60052-X)>. Accessed: Mai. 24, 2025. doi: 10.1016/S1874-1029(13)60052-X.
- CAMACHO-PÉREZ, E. et al. Predição da composição do tecido da carcaça em ovelhas Blackbelly usando medidas de ultrassom e métodos de aprendizado de máquina. **Tropical Animal Health and Production**, v.55, p.300. 2023. Available from:

<<https://doi.org/10.1007/s11250-023-03759-1>>. Accessed: Mai. 24, 2025. doi: 10.1007/s11250-023-03759-1.

CHENG, M. et al. Application of deep learning in sheep behaviors recognition and influence analysis of training data characteristics on the recognition effect. **Computers and electronics in agriculture**, v.198, p.107010. 2022. Available from: <<https://doi.org/10.1016/j.compag.2022.107010>>. Accessed: Mai. 24, 2025. doi: 10.1016/j.compag.2022.107010.

FIGUEIREDO FILHO, L.A.S. et al. Estimate of genetic parameters for carcass traits and visual scores in meat sheep using Bayesian inference via threshold and linear models. **Ciência Rural**, v.47, p.e20160174. 2017. Available from: <<http://dx.doi.org/10.1590/0103-8478cr20160174>>. Accessed: Mai. 24, 2025. doi: 10.1590/0103-8478cr20160174.

GOIS, G.C. et al. 2019. Características de carcaça e componentes não-carcaça de ovinos: uma revisão. **Arquivos de Ciências Veterinárias e Zoologia da UNIPAR**, v.22, p.4. Available from: <<https://doi.org/10.25110/arqvet.v22i4.7101>>. Accessed: Mai. 24, 2025. doi: 10.25110/arqvet.v22i4.7101.

GUARNIDO-LOPEZ, P. et al. Programming and Setting Up the Object Detection Algorithm YOLO to Determine Feeding Activities of Beef Cattle: A Comparison between YOLOv8m and YOLOv10m. **Animals**, v.14, p.2821. 2024. Available from: <<https://doi.org/10.3390/ani14192821>>. Accessed: Mai. 24, 2025. doi: 10.3390/ani14192821.

HASHIMOTO, J.H. et al. Características de carcaça e da carne de caprinos Boer x Saanen confinados recebendo rações com casca do grão de soja em substituição ao milho. **Revista Brasileira De Zootecnia**, v.36, p.165–173. 2007. Available from: <<https://doi.org/10.1590/S1516-35982007000100020>>. Accessed: Mai. 24, 2025. doi: 10.1590/S1516-35982007000100020.

HE, K. et al. Deep Residual Learning for Image Recognition. **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**. p.770-778. 2016. Available from: <<https://doi.org/10.48550/arXiv.1512.03385>>. Accessed: Mai. 24, 2025. doi: 10.48550/arXiv.1512.03385.

KRAMER, O. Scikit-Learn. In: Machine Learning for Evolution Strategies. **Studies in Big Data**, v.20. 2016. Available from: <https://doi.org/10.1007/978-3-319-33383-0_5>. Accessed: Mai. 24, 2025. doi: 10.1007/978-3-319-33383-0_5.

KEPRATE, A.; RATNAYAKE, R.M.C. Using gradient boosting regressor to predict stress intensity factor of a crack propagating in small bore piping, **IEEE International Conference on Industrial Engineering and Engineering Management**, v.1331-1336. 2017. Available from: <<https://doi.org/10.1109/IEEM.2017.8290109>>. Accessed: Mai. 24, 2025. doi: 10.1109/IEEM.2017.8290109.

LIMA JÚNIOR, F.A. et al. Prediction of carcass rib eye area by ultrasound images in sheep using computer vision. **Ciência Rural**, v.54, p.e20230576. 2024. Available from: <<https://doi.org/10.1590/0103-8478cr20230576>>. Accessed: Mai. 24, 2025. doi: 10.1590/0103-8478cr20230576.

MAGGIORI, E. et al. Convolutional Neural Networks for Large-Scale Remote-Sensing Image Classification. **IEEE Transactions on Geoscience and Remote Sensing**, v.55, p.645-657. 2017. Available from: <<https://doi.org/10.1109/TGRS.2016.2612821>>. Accessed: Mai. 24, 2025. doi: 10.1109/TGRS.2016.2612821.

MANSBRIDGE, N., et al. 2018. Feature Selection and Comparison of Machine Learning Algorithms in Classification of Grazing and Rumination Behaviour in Sheep. **Sensors**, v.18, p.3532. Available from: <<https://doi.org/10.3390/s18103532>>. Accessed: Mai. 24, 2025. doi: 10.3390/s18103532.

PEI, S. et al. Realizing Cattle and Sheep Target Detection in Ecological Livestock Farming Based on Improved YOLOv8 Model. **6th Asia Symposium on Image Processing**, v.21-28. 2024. Available from: <<https://doi.org/10.1109/ASIP63198.2024.00012>>. Accessed: Mai. 24, 2025. doi: 10.1109/ASIP63198.2024.00012.

PENG, Y. et al. A dynamic individual yak heifer live body weight estimation method using the YOLOv8 network and body parameter detection algorithm. **Journal of Dairy Science**, v.107, p.6178-6191. 2024. Available from: <<https://doi.org/10.3168/jds.2023-24065>>. Accessed: Mai. 24, 2025. doi: 10.3168/jds.2023-24065.

PHILIPPE, M.G. et al. 2020. Carcass and meat traits of certified beef cattle. **Brazilian Journal of Development**, v.6, p.52942–52951. Available from: <<https://doi.org/10.34117/bjdv6n7-805>>. Accessed: Mai. 24, 2025. doi: 10.34117/bjdv6n7-805.

PINHEIRO, R.S.B. et al. Correlações entre medidas determinadas in vivo por ultrassom e na carcaça de ovelhas de descarte. **Revista Brasileira De Zootecnia**, v.39, p.1161–1167.

2010. Available from: <<https://doi.org/10.1590/S1516-35982010000500030>>. Accessed: Mai. 24, 2025. doi: 10.1590/S1516-35982010000500030.

SANTOS, N.P.S. et al. Correção de medida ultrassonográfica de carcaça em coelhos usando modelo linear misto com covariáveis. **Arquivo Brasileiro De Medicina Veterinária E Zootecnia**, v.71, p.473–480. 2019. Available from: <<https://doi.org/10.1590/1678-4162-10416>>. Accessed: Mai. 24, 2025. doi: 10.1590/1678-4162-10416.

SENA, L.S. et al. Associação entre características de carcaça e tamanho corporal em ovinos Santa Inês. **Revista Científica de Produção Animal**, v.18, p.84-92. 2016. Available from: <<http://doi.org/10.5935/2176-4158/rcpa.v18n2p84-92>>. Accessed: Mai. 24, 2025. doi: 10.5935/2176-4158/rcpa.v18n2p84-92.

SENA, L.S. et al. Genetic evaluation of Tropical climate-adapted sheep for carcass traits including genomic information. **Small Ruminant Research**, v.3, p.106120. 2020. Available from: <<https://doi.org/10.1016/j.smallrumres.2020.106120>>. Accessed: Mai. 24, 2025. doi: 10.1016/j.smallrumres.2020.106120

SUGUISAWA, L. et al. **Uso da ultrassonografia na avaliação de características de carcaça e de qualidade da carne. Melhoramento genético aplicado em gado de corte.** Brasília, DF: Embrapa. p.97-107. 2013.

TAMMINA, S. Transfer learning using vgg-16 with deep convolutional neural network for classifying images. **International Journal of Scientific and Research Publications**, v.9, p.143-150. 2019. Available from: <<http://doi.org/10.29322/IJSRP.9.10.2019.p9420>>. Accessed: Mai. 24, 2025. doi: 10.29322/IJSRP.9.10.2019.p9420.

TARG, S. et al. Resnet in resnet: Generalizing residual architectures. **Workshop track – ICLR**, 2016. Available from: <<https://doi.org/10.48550/arXiv.1603.08029>>. Accessed: Mai. 24, 2025. doi: 10.48550/arXiv.1603.08029.

TAVEIRA, R.Z. et al. Avaliação de carcaça de bovinos da raça Tabapuã com ultrassonografia. **Pubvet**, v.10, p.100-104. 2016. Available from: <<https://doi.org/10.22256/pubvet.v10n1.100-104>>. Accessed: Mai. 24, 2025. doi: 10.22256/pubvet.v10n1.100-104

TERVEN, J. et al. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. **Machine Learning and Knowledge Extraction**, v.5, p.1680-1716. 2023. Available from:

<<https://doi.org/10.3390/make5040083>>. Accessed: Mai. 24, 2025. doi: 10.3390/make5040083.

TIRINK. C. Comparison of Bayesian Regularized Neural Network, Random Forest Regression, Support Vector Regression and Multivariate Adaptive Regression Splines Algorithms to Predict Body Weight from Biometrical Measurements in Thalli Sheep. **Kafkas Universitesi Veteriner Fakultesi Dergisi**, v.28, p.411-419. 2023. Available from: <<https://doi.org/10.9775/kvfd.2022.27164>>. Accessed: Mai. 24, 2025. doi: 10.9775/kvfd.2022.27164.

YU, W. et al. YoloSortC3D: A YOLOv8, DeepSort, and C3D-Based Method for Sheep Rumination Behavior Recognition. **Applied Science**, v.14, p.10801. 2024. Available from: <<https://doi.org/10.3390/app142310801>>. Accessed: Mai. 24, 2025. doi: 10.3390/app142310801.

ZHAO, H. et al. SheepInst: a high-performance instance segmentation of sheep images based on deep learning. **Animals**, 13, 1338. 2023. Available from: <<https://doi.org/10.3390/ani13081338>>. Accessed: Mai. 24, 2025. doi: 10.3390/ani13081338.

7. Considerações Finais

Para trabalhos futuros, recomenda a coleta de mais imagens de ovinos para uma melhoria nos resultados, contribuindo para a fenotipagem de precisão. Desta forma, objetiva-se a criação de uma ferramenta computacional, que possibilite a segmentação automatizada de uma imagem ultrassonográfica para obter as medidas de carcaça, tendo mais informações para prever o rendimento da carcaça, dando subsídios para a seleção de animais nos programas de melhoramento genético de ovinos.

Torna-se necessário, a criação de uma ferramenta interativa e mais didática para mensurar os ovinos em campo, facilitando a vida do produtor.