

FRANCISCO ALBIR LIMA JÚNIOR

**PREDIÇÃO DA ÁREA DO MÚSCULO *Longissimus dorsi* A PARTIR DE IMAGENS
ULTRASSONOGRÁFICAS EM OVINOS UTILIZANDO VISÃO
COMPUTACIONAL**

TERESINA, PI

2021

FRANCISCO ALBIR LIMA JÚNIOR

**PREDIÇÃO DA ÁREA DO MÚSCULO *Longissimus dorsi* A PARTIR DE IMAGENS
ULTRASSONOGRÁFICAS EM OVINOS UTILIZANDO VISÃO
COMPUTACIONAL**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência Animal da Universidade Federal do Piauí, como parte dos requisitos para obtenção do título de Mestre em Ciência Animal, Área de Concentração: Produção Animal.

Orientador: Prof. Dr. José Lindenberg Rocha Sarmiento

TERESINA, PI

2021

FICHA CATALOGRÁFICA
Universidade Federal do Piauí
Biblioteca Setorial do Centro de Ciências Agrárias
Serviço de Processos Técnicos

L732p Lima Júnior, Francisco Albir
Predição de área do músculo Longissimus dorsi a partir de imagens ultrasonográficas em ovinos utilizando visão computacional. / Francisco Albir Lima Júnior. -- 2021.
57 f.: il.

Dissertação (Mestrado) – Universidade Federal do Piauí, Centro de Ciência Agrárias, Programa de Pós-Graduação em Ciência Animal, Teresina, 2021.
“Orientador: Prof. Dr. José Lindenberg Rocha Sarmiento”

1. Ovinos de corte 2. AOL 3. Fenotipagem de precisão 4. Inteligência Artificial 5. Ultrassonografia I. Sarmiento, José Lindenberg Rocha II. Título.

CDD 636.313

**PREDIÇÃO DA ÁREA DO MÚSCULO *Longissimus dorsi* A PARTIR DE
IMAGENS ULTRASSONOGRÁFICAS EM OVINOS UTILIZANDO VISÃO
COMPUTACIONAL**

FRANCISCO ALBIR LIMA JUNIOR

Dissertação aprovada em: 01/04/2021

Banca Examinadora:



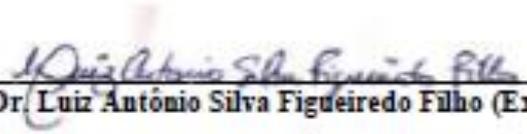
Prof. Dr. José Lindenberg Rocha Sarmiento (Presidente) / DZO/CCA/UFPI



Prof. Dr. Antônio de Sousa Junior (Interno) / CTT/UFPI



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



Pesquisador Dr. Luiz Antônio Silva Figueiredo Filho (Externo) / IFMA

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 namorado, **Francisco Iago Fonseca Farias**, por sempre ter estado ao meu lado me apoiando*

(Dedico e ofereço)

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 um período tão turbulento de pandemia.

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

Ao Prof. Dr. José Lindenberg Rocha Sarmiento pela confiança, ensinamentos, paciência e orientações e suporte durante todo o mestrado.

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.

Ao Prof. Dr. Amilton Paulo Raposo Costa por ter cedido o ultrassom para a execução da coleta.

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

Aos Professores do Programa de Pós-graduação em Ciência Animal, em especial o Prof. Dr. Arnauld Azevedo Alves, 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), pelo apoio fundamental dado durante o desenvolvimento da minha pesquisa.

A fazenda São José 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.....	10
2. REFERÊNCIAS BIBLIOGRÁFICAS.....	11
CAPÍTULO I.....	13
1. Introdução.....	16
2. Ovinocultura de corte.....	17
2.1. <i>Histórico da ovinocultura.....</i>	17
2.2. <i>Carcaça ovina e seus componentes.....</i>	18
2.3. <i>Área do músculo Longissimus dorsi.....</i>	20
3. Ultrassonografia de carcaça.....	21
3.1. <i>História da ultrassonografia.....</i>	21
3.2. <i>Instituições que realizam avaliação de carcaça.....</i>	21
3.3. <i>Importância e vantagens da ultrassonografia.....</i>	22
3.4. <i>Técnica da ultrassonografia e aplicações.....</i>	23
3.5. <i>Ultrassonografia de carcaça.....</i>	24
4. Visão computacional.....	25
4.1. <i>História.....</i>	25
4.2. <i>Importância da visão computacional.....</i>	26
4.3. <i>Algoritmos de segmentação de imagens.....</i>	27
4.4. <i>Aplicações da visão computacional.....</i>	29
5. Conclusões.....	30
Referências bibliográficas.....	31
CAPÍTULO II.....	37
1. Introdução.....	40
2. Metodologia.....	41
2.1. <i>Coleta de dados.....</i>	42
2.1.1. <i>Coleta do banco de dados.....</i>	42
2.1.2. <i>Características mensuradas.....</i>	42
2.1.3. <i>Pré-processamento de imagens.....</i>	43
2.2. <i>Segmentação da região de interesse.....</i>	44
2.2.1. <i>Métricas de segmentação.....</i>	44
2.3. <i>Extração de atributos.....</i>	45

<i>2.4. Análise estatística</i>	45
<i>2.4.1. Análise de regressão</i>	45
<i>2.4.2. Métricas de regressão</i>	46
<i>2.4.3. Estatística descritiva e comparação de médias</i>	46
3 Resultados e discussão	47
4 Conclusões	53
Referências bibliográficas	53
Considerações finais	57

LIMA JÚNIOR, Francisco Albir. **PREDIÇÃO DA ÁREA DO MÚSCULO *Longissimus dorsi* A PARTIR DE IMAGENS ULTRASSONOGRÁFICAS EM OVINOS UTILIZANDO VISÃO COMPUTACIONAL**. 2021. 57f. Dissertação (Mestrado em Ciência Animal), Universidade Federal do Piauí, Teresina, 2021.

RESUMO

A ovinocultura de corte é um setor que se encontra em constante expansão. Este setor também está ganhando espaço no agronegócio brasileiro e na região Nordeste. Entretanto, a produtividade é baixa. Portanto, este setor exige alternativas tecnológicas dentro do melhoramento genético dos rebanhos, como fenotipagem de precisão, através das coletas de informações fenotípicas com precisão para permitir melhorar o rendimento de carcaça dos animais, a fim de atender às demandas e a avaliação de carcaça com resultados mais precisos, a qual tem sido realizada a partir da análise de imagens ultrassonográficas por profissionais especializados. Sendo assim, o objetivo com pesquisa foi o desenvolvimento de uma abordagem com o uso de inteligência artificial para avaliação de carcaça ovina de forma acurada por meio do reconhecimento de imagens ultrassonográficas do músculo *Longissimus dorsi*. A metodologia proposta para este trabalho foi dividida em 4 etapas. Na etapa de coleta de dados, 121 imagens ultrassonográficas de fêmeas ovinas foram coletadas com auxílio de aparelho de ultrassom, Durante a segmentação das regiões de interesse, utilizou-se apenas um método de segmentação automatizado com base em algoritmo de redes neurais (U-Net). Para a avaliação de segmentações automáticas, utilizou-se as métricas de coeficiente de dados *Dice* e a métrica de intersecção sobre união (IoU). Na extração de recursos, objetivou-se encontrar características importantes para a previsão de AOL (Área de Olho de Lombo). Na última etapa, foi realizada uma análise de regressão, sendo a variável independente os valores dos atributos obtidos com os descritores utilizados e a variável dependente a AOL previsto para a imagem de ultrassom do animal, aonde utilizou-se as métricas de quadrado médio do resíduo (QMR) e erro médio absoluto (EMA). Dois algoritmos de regressão foram utilizados, *AdaBoost Regressor*(ABR) e *Random Forest Regressor* (RFR). Realizou-se uma análise de variância e o teste “t” de student para comparar as médias de AOL observada e predita. Os valores obtidos pela métrica *Dice* foi de 0,94 e a da IoU foi de 0,89 o que demonstra alta similaridade entre o real e o previsto. Os valores de QMR, EMA e R^2 para o ABR é de, respectivamente, 2,61, 1,22 e 0,51 e para o RFR é de 2,15, 1,12 e 0,61, o que demonstra uma correlação positiva entre os valores preditos e os valores reais. Observou que não houve diferenças significativas entre as médias de AOL observada e predita. Portanto, a medição automatizada da AOL a partir de imagens ultrassonográficas é promissora e possibilitará maior eficiência na realização desta medida em grandes quantidades de imagens com alta precisão, pois dispensa a intervenção humana na delimitação da área do músculo *Longissimus dorsi* em ovinos de corte de carcaça.

Palavras-chave: AOL, fenotipagem de precisão, Inteligência Artificial, Ovinos de corte, Ultrassonografia

LIMA JÚNIOR, Francisco Albir. **PREDICTION OF THE MUSCLE AREA Longissimus dorsi FROM ULTRASONOGRAPHIC IMAGES IN SHEEP USING COMPUTATIONAL VIEW.** 2021. 57f. Dissertation (MSc. in Animal Science), Federal University of Piauí, Teresina, 2021.

ABSTRACT

Beef sheep is an expanding sector. This sector is also gaining space in Brazilian agribusiness and in the Northeast region. However, productivity is low. Therefore, this sector requires technological alternatives within the genetic improvement of herds, such as precision phenotyping, through the collection of phenotypic information needed to improve the carcass yield of the animals, to meet the demands and the carcass evaluation with more accurate results. , one that has been carried out from the analysis of ultrasound images by specialized professionals. Therefore, the objective with research was the development of an approach with the use of artificial intelligence to evaluate sheep carcass accurately through the recognition of ultrasound images of the Longissimus dorsi muscle. The methodology proposed for this work was divided into 4 stages. In the data collection stage, 121 ultrasound images of sheep from collections were collected with the aid of an ultrasound device. During the selection of the regions of interest, using only an automated supply method based on a neural network algorithm (U-Net) For the evaluation of automatic segmentations, the Dice data coefficient metrics and the intersection over union (IoU) metrics were used. In the extraction of resources, the objective was to find important characteristics for a forecast of REA (Rib Eye Area). In the last step, a regression analysis was performed, with the independent variable being the values of the resources provided with the descriptors used and the REA-dependent variable predicted for the animal's ultrasound image, where it was used as mean square error (MSE) and mean absolute error (MAE). Two regression algorithms were used, AdaBoost Regressor (ABR) and Random Forest Regressor (RFR). An analysis of variance and the student's "t" test were performed to compare how REA averages were compared and predicted. The values obtained by the metric Dice was 0.94 and that of the IoU was 0.89, which demonstrates a high similarity between the real and the predicted. The values of MSE, MAE and R² for ABR are 2.61, 1.22 and 0.51, respectively, and for RFR it is 2.15, 1.12 and 0.61, which demonstrates a correlation between predicted and actual values. He observed that there were no significant differences between the observed and predicted REA averages. Therefore, an automated measurement of REA from ultrasound images is promising and will enable greater efficiency in carrying out this measurement in large quantities of images with high precision, since it does not require human intervention in the delimitation of the Longissimus dorsi muscle area in carcass sheep. .

Keyword: Artificial Intelligence, Beef sheep, precision phenotyping, REA, Ultrasonography

1 INTRODUÇÃO GERAL

A produção de ovinos é uma atividade executada em todos os continentes. O Brasil vem, ao longo dos anos, se consolidando no cenário agropecuário global, e a ovinocultura não se torna exceção nesse mercado (JIMENEZ-SANS et al., 2016). Entre as regiões brasileiras, o Nordeste ocupa uma posição de destaque possui mais da metade de todo o rebanho nacional. O Piauí destaca-se no cenário regional com efetivo de, aproximadamente, dois milhões de cabeças (IBGE, 2019).

Entretanto, a produtividade da carne ovina, com o decorrer dos anos não tem mudado, não atendendo as demandas do mercado, por fatores internos como a deficiência nos manejos sanitário, nutricional e reprodutivo, além da falta de informações zootécnicas do rebanho (LIRA; GONZAGA NETO; SOUSA et al., 2017).

É importante destacar que a preferência pela carne amplia esta atividade e aumenta a demanda que o mercado exige, o que se torna fundamental aumentar a produção de forma eficiente dentro da propriedade. Sendo assim, uma dessas prioridades é buscar alternativas tecnológicas que permita maior eficiência na escrituração zootécnica nos rebanhos para permitir mensurar fenótipos de características de carcaça com maior rapidez e acurácia, com o intuito de promover seleção para características de carcaça em rebanhos ovinos e desta forma, avançar na melhoria da carcaça para atender as demandas do mercado consumidor (LIRA; GONZAGA NETO; SOUSA et al., 2017).

Um das medidas mais utilizadas e avaliadas pela ultrassonografia de carcaça é a área de olho de lombo (AOL) que se trata de uma medida tomada do músculo *Longissimus dorsi*, 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. Relata-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 (LUCHIARI FILHO, 2000).

Sendo assim, para o reconhecimento das medidas de AOL a partir de imagem tomada do músculo do animal, utiliza-se de softwares para auxiliar na mensuração, o que pode ser melhorado com a utilização de visão computacional. Este campo da tecnologia possibilita que imagens capturadas por dispositivos sejam processadas e tratadas, de maneira que, após passarem por diversas etapas do sistema de análise computacional, elas forneçam informações de forma precisa e rápida (PISTORI, 2017).

O processamento digital dessas imagens e a visão computacional têm demonstrado a crescente efetividade da aplicação de algoritmos bioinspirados para segmentação de imagens (LOPES et al., 2018). Em contrapartida, métodos em aprendizagem profunda, baseados em redes neurais convolucionais (*Convolutional Neural Network - CNN*) são também utilizados para a segmentação de imagens, obtendo resultados muito promissores. É importante destacar que a área de aprendizagem profunda vem ganhando espaço no reconhecimento de padrões (RONNENBERG et al., 2015).

Dentre os diversos algoritmos que realizam a segmentação das imagens temos U-Net (Redes Neurais Convolucionais) que se destaca por apresentar resultados mais promissores, por se adaptar facilmente aos mais diversos tipos de dados, oferecendo soluções mais claras e precisas, sendo um dos algoritmos mais eficientes para a segmentação de imagens médicas. Desta maneira através deste algoritmo, é possível extrair-se de uma imagem, uma determinada região de interesse, de maneira automatizada (ISENSEE ET AL., 2018).

Sendo assim, o objetivo com esta pesquisa é propor um sistema para mensurar a Área de Olho de Lombo (AOL) do músculo *Longissimus dorsi* em ovinos com o intuito de auxiliar na avaliação da carcaça utilizando algoritmos de visão computacional.

A Dissertação é apresentada em Capítulos, de acordo com as Normas do Programa de Pós-Graduação em Ciência Animal da UFPI. A estrutura é apresentada da seguinte forma:

- **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 área de olho de lombo do músculo *Longissimus dorsi*, a técnica da ultrassonografia em todas suas aplicações, 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 área do músculo *Longissimus dorsi* a partir de imagens ultrassonográficas em ovinos utilizando visão computacional (Este capítulo foi elaborado com base nas normas da revista *Small Ruminant Research*– ISSN 0921-4488).

2. REFERÊNCIAS BIBLIOGRÁFICAS

IBGE – Instituto Brasileiro de Geografia e Estatística. Censo Agropecuário. 2019.

- ISENSEE, F., PETERSEN, J., KLEIN, A., ZIMMERER, D., JAEGER, P. F., et al., 2018. nnU-Net: Self-adapting Framework for U-Net-Based Medical Image Segmentation. **arXiv preprint**. arXiv:1809.10486.
- JIMENEZ-SANZ, A. L., QUIRINO, C. R., PACHECO, A., COSTA, R. L. D., BELTRAME, R. T., RUA, M. A. S., SILVA, R. M. C. e FÁTIMA, M. O. A. 2016. Relação entre fatores associados às parasitoses gastrointestinais, desempenho e estado fisiológico de ovelhas Santa Inês. **Agropecuária Técnica**, 37, 88-95. <http://www.iz.sp.gov.br/pdfs/1472562005.pdf>
- LIRA, A. B., GONZAGA NETO, S., SOUSA, W. H., RAMOS, J. P. F., CARTAXO, F. Q., SANTOS, E. M., CÉZAR, M. F., FREITAS, F. F., 2017. 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**, 18, 313-326. <http://dx.doi.org/10.1590/s1519-99402017000200010>
- LOPES, G. A. W., BELTRAME, F. S., SANTOS R. M., RODRIGUES, P. S., 2018. Comparison of bio-inspired algorithms from the point of view of medical image segmentation. In 2018 IEEE International Work Conference on Bioinspired Intelligence (IWOBI), 1–7, 2018. <https://ieeexplore.ieee.org/document/8464218>
- LUCHIARI FILHO, A. Pecuária da carne bovina. São Paulo: LinBife, 2000. 134p.
- PISTORI, E. Pecuária de precisão como fator de desenvolvimento local da região do alto taquari. Edital Chamada Fundect - Universal. 2017.
- RONNEBERGER, O., FISHER, P., BROX, T., 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. **Medical Image Computing and Computer-Assisted Intervention (MICCAI)**, 9351, 234-241. arXiv:1505.04597

CAPÍTULO I

Avaliação de carcaça por meio do reconhecimento de imagens ultrassonográficas de ovinos utilizando ferramentas de visão computacional: Uma revisão

Avaliação de carcaça por meio do reconhecimento de imagens ultrassonográficas de ovinos utilizando ferramentas de visão computacional: Uma revisão

Francisco Albir Lima Júnior^{a,*}, José Lindenberg Rocha Sarmento^b

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

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

*Autor correspondente.

Endereços de e-mail: albirjunior@hotmail.com (F.A. Lima Júnior), sarmento@ufpi.edu.br (J.L.R. Sarmento).

RESUMO:

Objetivou-se com esta revisão, descrever todos os aspectos da avaliação de carcaça por meio do reconhecimento de imagens ultrassonográficas de ovinos utilizando ferramentas de visão computacional. A ovinocultura desenvolveu-se de forma gradativa e pontual no território brasileiro, aonde os ovinos, assim como os caprinos, foram os primeiros a serem introduzidos no Brasil, assim como outras espécies. A criação de ovinos é uma atividade econômica bastante promissora que apresenta alto custo benefício além do animal ser bem adaptado aos mais diversos tipos de ecossistemas. Os principais caracteres quantitativos e qualitativos da carcaça que podem ser identificados, além do peso e rendimento, são: conformação e cobertura de gordura, de maneira subjetiva (avaliação visual), medidas morfológicas e sua determinação de índices, a composição tecidual e regional, além dos componentes não-carcaça. Uma das principais medidas indicadoras da qualidade da carcaça é a Área de Olho de Lombo (AOL) do músculo *Longissimus dorsi*, localizado entre as 12^a e 13^a vértebras do corpo do animal. Fatores importantes como o grau de conhecimento e de experiência do especialista, tipo e fabricante do equipamento, sondas utilizadas, o programa computacional de interpretação, além da característica avaliada são fundamentais para possibilitar a acurácia da técnica de ultrassonografia. A ultrassonografia de carcaça é um método para realizar avaliação de carcaça por predições *in vivo* das características de carcaça, principalmente em sistemas de produção de animais jovens, podendo-se obter a área de olho de lombo, a espessura da gordura subcutânea e o marmoreio. Os primeiros trabalhos que estudaram visão computacional foram propostos quando surgiram os primeiros computadores e esse ramo da computação evoluiu de maneira gradativa, concomitantemente, quando mais recursos computacionais, como, por exemplo, memória e capacidade de armazenamento, se tornaram disponíveis. A visão computacional trata-se da área de estudo que permite repassar para máquinas a incrível capacidade de visão, ou seja, o ato de captar imagens. Sistemas de visão computacional

compreendem métodos de processamento digital de imagens. Estes métodos envolvem dois procedimentos, ou seja, o reconhecimento e a mensuração das características. Durante o reconhecimento, deve-se obter características das imagens e utilizar inteligência computacional para realizar a diferenciação entre as imagens coletadas. Já a mensuração da imagem consiste em uma automatização de inspeção. A segmentação do conjunto de imagens é realizada com o auxílio de algoritmos. Na literatura, existem alguns algoritmos que realizam a segmentação automatizada, tais como: Método Otsu, K-means, S-LIC, U-Net. Estes algoritmos têm como objetivo inferir marcações próximas ou iguais às realizadas pelo especialista. Observou-se que dentre os trabalhos encontrados na literatura o algoritmo U-Net foi que teve mais resultados promissores. A visão computacional também pode ser utilizada para estudar características da carcaça de animais, por meio do reconhecimento de imagens ultrassonográficas do corpo do animal. Através das medidas mensuradas pelo especialista utilizando o ultrassom pode-se comparar com as mensurações realizadas por algoritmos de inteligência artificial, aonde se realiza o processamento digital dessas imagens. Diante do exposto, com o auxílio da visão computacional, é possível realizar o processamento das imagens ultrassonográficas com o intuito de obter as medidas de carcaça do animal, tendo assim uma previsão do rendimento de carne do indivíduo.

Palavras chave: Avaliação de carcaça, ultrassonografia, visão computacional

ABSTRACT:

The objective of this review was to describe all aspects of carcass evaluation through the recognition of ultrasound images of sheep using computer vision tools. Sheep farming developed gradually and punctually in the Brazilian territory, where sheep, as well as goats, were the first to be introduced in Brazil, as well as other species. Sheep farming is a very promising economic activity that has a high cost benefit in addition to the animal being well adapted to the most diverse types of ecosystems. The main quantitative and qualitative characteristics of the carcass that can be identified, in addition to weight and yield, are: conformation and fat cover, subjectively (visual assessment), morphological measures and their determination of indices, tissue and regional composition, in addition to the non-housing components. One of the main measures of carcass quality is the Rib Eye Area (REA) of the Longissimus dorsi muscle, located between the 12th and 13th vertebrae of the animal's body. Important factors such as the degree of knowledge and experience of the specialist, type and manufacturer of the equipment, probes used, the computer program for interpretation, in addition to the characteristic evaluated are fundamental to enable the accuracy of the ultrasound technique. Carcass ultrasonography is a method to perform carcass evaluation by in vivo predictions of carcass characteristics, mainly in production systems of young animals, being able to obtain the rib eye area, the thickness of the subcutaneous fat and the marbling. The first works that studied computer vision were proposed when the first computers appeared and this branch of computing evolved gradually, concomitantly, when more computational resources, such as, for example, memory and storage capacity, became available. Computer vision is the study area that allows to transfer to machines the incredible capacity of vision, that is, the act of capturing images. Computer vision systems comprise digital image processing methods. These methods involve two procedures, that is, the recognition and measurement of characteristics. During recognition, one must obtain characteristics of the images and use computational intelligence to differentiate between the collected images. Image

measurement, on the other hand, consists of inspection automation. The segmentation of the set of images is performed with the aid of algorithms. In the literature, there are some algorithms that perform automated segmentation, such as: Otsu Method, K-means, S-LIC, U-Net. These algorithms aim to infer markings close to or equal to those made by the specialist. It was observed that among the works found in the literature, the U-Net algorithm had the most promising results. Computer vision can also be used to study animal carcass characteristics, through the recognition of ultrasound images of the animal's body. Through the measurements measured by the specialist using the ultrasound, it is possible to compare with the measurements made by artificial intelligence algorithms, where the digital processing of these images takes place. Given the above, with the aid of computer vision, it is possible to perform the processing of ultrasound images in order to obtain the animal's carcass measurements, thus having a prediction of the individual's meat yield.

Keywords: Carcass evaluation, computer vision, ultrasound

1. INTRODUÇÃO

A ovinocultura de corte é um setor da agropecuária que se encontra em constante expansão, estando presente em, praticamente, todos os continentes. O ramo da ovinocultura está ganhando espaço no agronegócio brasileiro, tendo destaque, principalmente na região Nordeste, que possui mais da metade de todo o rebanho brasileiro, sendo o Piauí o 5º estado com maior número de efetivos de ovinos no Brasil e o 4º estado no Nordeste com 1.670.522 cabeças (IBGE, 2019).

Na produção de ovinos, o hábito e o consumo desta carne amplia esta atividade e requer que este ramo atenda às necessidades do mercado, o que torna necessário aumentar a produção de carne de maneira rápida e eficaz. Sendo assim, este setor exige alternativas tecnológicas dentro do melhoramento genético dos rebanhos para permitir medir fenótipos de características de carcaça com maior agilidade e maior precisão, afim de possibilitar progresso genético para características de carcaça em rebanhos ovinos e desta forma suprir as demandas do mercado consumidor. Entretanto, a produtividade da carne ovina, ao longo dos anos não tem mudado, principalmente pela falta de informações para tomadas de decisão, associado a deficiência nos manejos nutricional, sanitário e reprodutivo, além da ausência de avaliações rotineiras de características de carcaça para fins de seleção genética (LIRA; GONZAGA NETO; SOUSA et al., 2017).

A mensuração da área de olho de lombo (AOL) do músculo *Longissimus dorsi* de maneira padronizada, é importante para buscar o maior rendimento e melhor

qualidade da carcaça em sistemas de produção de carne ovina. A genética e o melhoramento animal são fundamentais para melhorar o desempenho animal (LIRA, 2016).

A medida de AOL pode ser tomada via ultrassonografia, que se trata de um procedimento não invasivo e considerado viável para esta metodologia, pois permite determinar a quantidade dos tecidos adiposos e musculares em animais vivos (MCMANUS; PAIM; LOUVANDINI et al., 2013).

Para uma maior qualidade da carcaça, utilizam-se características para determinar a quantidade e a qualidade da carcaça. Atualmente, a área de olho de lombo (AOL) é uma das medidas mais utilizadas. As mensurações de AOL podem ser obtidas por ultrassom em tempo real do músculo *Longissimus dorsi* por meio de imagens capturadas entre a 12^a e a 13^a costelas, utilizada como informação indicadora de musculabilidade e de qualidade da carcaça (CARTAXO; SOUSA, 2008; POLIZEL NETO; JORGE; MOREIRA et al., 2009; PINHEIRO; JORGE; YOKOO, 2010). Todavia, as medidas de AOL a partir de imagens produzidas por ultrassonografia requerem a manipulação das imagens no próprio aparelho ou em softwares para delimitação da seção do músculo e posterior cálculo de sua área, o que gera as medidas de AOL utilizadas para fins de estudos relacionados ao melhoramento animal e em decisões de manejo em geral.

Sendo assim, para contribuir com a fenotipagem dos animais com maior agilidade e com maior precisão, torna-se necessário o desenvolvimento de algoritmos que possam automatizar a leitura de imagens ultrassonográficas do músculo. Algoritmos de inteligência artificial podem contribuir de forma a promover a automatização da determinação da AOL a partir das imagens, com o intuito de facilitar a tomadas dessas medidas com maior precisão e rapidez. Desta maneira, o objetivo desta revisão é descrever as metodologias que possam ser utilizadas para a mensuração da área de olho de lombo de ovinos para avaliação da carcaça através do reconhecimento de imagens ultrassonográficas do músculo *Longissimus dorsi* utilizando visão computacional.

2. OVINOCULTURA DE CORTE

2.1. HISTÓRICO DA OVINOCULTURA

A ovinocultura desenvolveu-se de forma gradativa e pontual no território brasileiro, aonde os ovinos, assim como os caprinos, foram os primeiros a serem

introduzidos no Brasil, assim como outras espécies, tais como, os bovinos, trazidos pelos colonizadores portugueses para a Região Nordeste acerca de quase 500 anos, em 1535 (JAINUDEEN et al., 2004).

Os fatores históricos e geoclimáticos na Região Nordeste foram cruciais para a consolidação da ovinocultura, embora de maneira rudimentar, aonde adaptou-se para a produção de carne segundo as necessidades do Brasil. A fácil adaptação dos animais aos mais diferentes tipos de condições edafoclimáticas foi fundamental na expansão da criação de ovinos, a qual passou a ter duas finalidades: subsistência familiar e atividade econômica no meio rural (VIANA, 2008).

2.2. CARCAÇA OVINA E SEUS COMPONENTES

No sistema de produção de carne, os caracteres quantitativos e qualitativos são fundamentais, pois estão, diretamente, relacionados ao produto final. Atualmente, a alta demanda pela carne de cordeiros, amplia o interesse em intensificar a terminação de animais jovens, com a finalidade de acelerar a comercialização e produção de carcaças com boa qualidade. Esta depende de fatores inerentes ao animal, tais como: genética, manejo alimentar, idade e sexo; além de fatores externos que são ambiente, manejo alimentar, transporte e jejum (BURIN, 2016).

No sistema de produção de ovinos de corte, o componente mais importante é a carne e a carcaça dos animais, já que nela está presente a porção comestível de maior valor comercial (HASHIMOTO et al., 2012). A carcaça trata-se da unidade básica de transação entre os setores de produção ou comercialização da carne ovina. A avaliação de carcaça tem duas finalidades básicas: estimar a quantidade de porção comestível da carcaça e prever a qualidade da porção comestível (CEZAR e SOUZA, 2007).

A avaliação das características quantitativas da carcaça, através da determinação do rendimento, da composição regional, tecidual e da musculabilidade, é de suma importância para o processo produtivo, além de trazer benefícios para toda a cadeia produtiva da carne ovina (LEITE et al., 2013). A alimentação, a genética e o ambiente de criação também influenciam na qualidade das carcaças dos animais. A falta de uniformização das carcaças e irregularidade da oferta devido ao sistema de alimentação a que os animais são submetidos caracterizam-se como os principais fatores que dificultam a demanda crescente de carne ovina (MORENO e BOAVENTURA NETO, 2016).

Antes do abate, a avaliação dos animais através das medidas biométricas obtidas no animal *in vivo*, de forma conjunta com a avaliação visual subjetiva da condição corporal e conformação, é considerada uma ferramenta que pode ser utilizada pelos produtores rurais para auxiliar na determinação do momento ideal de abate. Embora, não permitirem a definição de maneira exclusiva das características da carcaça, auxiliam na estimação de características produtivas como peso, rendimento, conformação e rendimento dos cortes comerciais (FERNANDES et al., 2011).

Para concretizar a produção e comercialização da carne ovina, são utilizadas técnicas objetivas e claras para descrever os caracteres relacionados com a qualidade da carcaça. A morfometria gera informações úteis para a determinação de tendências ao longo dos anos em uma determinada raça (OSÓRIO et al., 2009).

As medidas morfométricas da carcaça podem ser influenciadas por determinados fatores, como por exemplo, o sexo do animal, o qual, Koritiaki *et al.* (2012), verificaram a superioridade dos machos em relação às fêmeas. Já Gois *et al.* (2018) observaram que o efeito idade provoca maior variação entre as medidas morfométricas avaliadas e que a influência do sexo cresce com o aumento da idade, sendo os machos superiores às fêmeas.

Os principais caracteres quantitativos e qualitativos da carcaça que podem ser identificados, além do peso e rendimento, são: conformação e cobertura de gordura, de maneira subjetiva (avaliação visual), medidas morfométricas, a composição tecidual e regional, além dos componentes não-carcaça (LIMA et al., 2013). A avaliação das carcaças trata-se de um estudo de parâmetros associados a medidas objetivas e subjetivas em relação à mesma e está ligada aos aspectos e atributos inerentes à porção comestível, sendo de fundamental importância para complementar a avaliação do desempenho do animal durante seu desenvolvimento e, desta forma, garantir um sistema de produção eficiente e a qualidade do produto final (SILVA et al., 2018).

Uma das principais medidas indicadoras da quantidade da carcaça é a Área de Olho de Lombo (AOL) do músculo *Longissimus dorsi*, localizado entre as 12^a e 13^a vértebras do corpo do animal. Esta mensuração, também, está relacionada diretamente com o rendimento e a musculosidade da carcaça, sendo uma das medidas mais estudadas e avaliadas para predizer o rendimento da carcaça antes do abate (CARTAXO e SOUZA et al., 2008). Outra medida mensurada acima deste músculo e que também pode influenciar na qualidade da carne é a Espessura da Gordura Subcutânea (EGS), a

qual evita o enrijecimento e escurecimento da carne (SOUZA et al., 2016). Uma outra mensuração tomada do músculo é o marmoreio que representa a gordura intramuscular e é uma característica importante que está intimamente ligada com os aspectos sensoriais da carne apreciadas pelo consumidor (COSTA et al., 2002).

As medidas área de olho de lombo e espessura de gordura subcutânea são utilizadas com muita frequência em pesquisas e em sistemas oficiais de avaliação do rendimento dos cortes comerciais e de carne magra da carcaça. A medida da AOL tem-se mostrado inversamente proporcional à espessura de gordura subcutânea, uma vez que, quanto maior o acúmulo de gordura, menor a proporção de músculo (OSÓRIO *et al.*, 2012).

2.3. ÁREA DE OLHO DE LOMBO DO MÚSCULO *Longissimus dorsi*

As medidas determinadas *in vivo* no músculo *Longissimus dorsi* com o equipamento de ultrassom têm sido muito semelhantes às encontradas na carcaça após o animal ser abatido (PRADO et al., 2004). Segundo Sugisawa et al. (2006), a AOL apresenta alta correlação com a musculosidade da carcaça.

A determinação da AOL trata-se de um bom indicativo da composição corporal de animais, já que determina o conteúdo da carne de cada animal e, desta maneira, obtendo considerável influência no estudo do preço final da carne e classificação da carcaça. É importante destacar que quando analisada a AOL de um animal abatido, esta mensuração é estimada por meio da área da seção transversal do músculo *Longissimus dorsi* na altura das 12^a e 13^a costelas (CEZAR E SOUSA, 2007).

A AOL é uma medida geralmente utilizada por sua característica de músculo de maturidade tardia e facilmente mensurada. A AOL tem a função de representar o desenvolvimento do tecido muscular, distribuição e quantidade e rendimentos de cortes (BONIFÁCIL et al., 1979; SAINZ, 1996). Desta forma, de posse do conhecimento desta medida se terá uma previsão da quantidade de carcaça que determinado animal terá e, conseqüentemente, do rendimento da carcaça daquele indivíduo, além de informações sobre a qualidade da carcaça.

3. ULTRASSONOGRAFIA DE CARÇAÇA

3.1. HISTÓRIA DA ULTRASSONOGRAFIA

A ultrassonografia começou a ser trabalhada em gado de corte em meados dos anos de 1950, por intermédio do Dr. James Stouffer da Universidade de Cornell. Durante esta época, os aparelhos eram primitivos, as mensurações eram difíceis e os resultados não muito significativos (STOUFFER, 1991).

A ultrassonografia teve um avanço significativo na década de 80, o qual o tempo real do ultrassom dispunha de uma maior quantidade de cristais dispostos de maneira linear, possibilitando a geração e recepção de sinais de forma mais rápida o qual diversas instituições passaram a utilizar o ultrassom para avaliar a carcaça (STOUFFER, 1991).

Com o advento da tecnologia da ultrassonografia, tornou-se mais fácil, ágil e barato fazer as mensurações de carcaça no animal *in vivo*, obtendo assim dados a um ano de idade. A *American Angus Association* dos Estados Unidos adotou a avaliação de carcaças em bovinos em 1974. De 1974 a 2001, 40.000 animais foram estudados, tornando possível a geração de DEPs para carcaça na raça *Angus*. Em 1998, a *American Angus Association* passou a adotar a ultrassonografia para mensurar características de carcaça. Entre 1998 e 2001, foram avaliados 150.000 animais (SUGUISAWA et al., 2013).

3.2. INSTITUIÇÕES QUE REALIZAM AVALIAÇÃO DE CARÇAÇA

O *Angus Breedplan* da Austrália utiliza a metodologia de ultrassonografia de carcaça desde 1990 e atualmente estão utilizando este trabalho em conjunto com as Associações da Nova Zelândia para a avaliação da carcaça de bovinos da raça *Angus* (SAINZ e ARAÚJO, 2002). A *Angus Breedplan* da Nova Zelândia, atualmente, trabalha com avaliação e gerenciamento do progresso genético de bovinos aonde um dos vários parâmetros a serem calculados são o peso da carcaça, a área de olho de lombo e espessura da gordura subcutânea (*Breedplan*, 2021).

A certificação adotada pela ATUBRA (Associação de Técnicos de Ultrassom do Brasil) para avaliar a carcaça de bovinos, reconhecida internacionalmente, segue os mesmos princípios da *Ultrasound Guidelines Council* (Conselho de diretrizes de ultrassom - UCG), modelo este consolidado nos Estados Unidos (EUA) e utilizado por todas as associações de raça norte-americanas. De acordo com a UCG existem quatro

programas certificados para avaliação de carcaça: Bia Field (DGT Brasil), Bia Pro Plus (DGT Brasil), Walter & Associates e UltraInsights (SUGUISAWA et al., 2013).

A Aval Serviços Tecnológicos é uma empresa brasileira que trabalha em parceria com os Programas de melhoramento genético e associações de raças de bovinos de corte capturando medidas acuradas das características avaliadas por ultrassom, em animais vivos (Aval, Brasil). As primeiras certificações de técnicos de campo no Brasil foram conduzidas em outubro de 2004. Em 2011, A Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), que já realiza avaliação de carcaça em bovinos, por intermédio da Associação Brasileira dos Criadores de Zebu (ABCZ) realizou a I Certificação de Técnicos de Campo e Laboratório para realizar a ultrassonografia de carcaça e qualidade da carne bovina (SUGUISAWA et al., 2013).

Atualmente, os aparelhos são muito aprimorados e os resultados podem ser excelentes. Entretanto, a confiabilidade destes dados depende bastante da habilidade do especialista que manuseará a máquina e da análise e interpretação corretas da imagens (SAINZ e ARAÚJO, 2002).

3.3. IMPORTÂNCIA E VANTAGENS DA ULTRASSONOGRAFIA

O aparelho de ultrassom é uma ferramenta de suma importância para o melhoramento genético, e tem sido amplamente utilizada na avaliação de carcaça (WILSON, 1992).

A ultrassonografia vem sendo usada para algumas finalidades dentro das técnicas de avaliação de carcaças, tais como: avaliação da composição corporal quanto à deposição de músculo e gordura, avaliação dos reprodutores e sua progênie; seleção em rebanhos; e rendimento de carcaça para o mercado consumidor. A técnica possibilita a coleta de três principais mensurações de carcaças do animal *in vivo*: espessura de gordura subcutânea (EGS), área de olho de lombo (AOL) e gordura de marmoreio, o qual esses indicadores, medidos por ultrassom, possuem boas correlações com as medidas de carcaça *post mortem*, além de permitir a obtenção em tempo real, de forma rápida e barata, das características de composição de carcaça em animais ainda vivos (SALES et al., 2019).

De acordo com Sales et al. (2019), a ultrassonografia por se tratar de um procedimento não-invasivo, não apresenta efeitos biológicos nocivos. O método poderá ser realizado em qualquer local, caracterizando-se por ser um procedimento seguro tanto

para o especialista quanto para o animal, além de ser uma técnica moderna e precisa que não necessita de uma segurança específica.

3.4. TÉCNICA DA ULTRASSONOGRAFIA E APLICAÇÕES

De início, utilizava-se a ultrassonografia de modo A, ou seja, capaz somente de realizar mensurações de forma linear como espessura da gordura subcutânea e profundidade de olho de lombo, as quais se utilizava apenas um transdutor. Posteriormente, foi desenvolvida a ultrassonografia de modo B, a qual um arranjo de maneira linear com vários transdutores. O aparelho de ultrassom em tempo real é o de modo B que obtêm a imagem de forma instantânea (BUSBOOM et al., 2000).

O ultrassom mensura, basicamente, a reflexão de ondas de alta frequência que acontece quando elas passam entre os tecidos. Em seguida, após o transdutor colocado em um local determinado no animal, o aparelho realiza a conversão de pulsos elétricos em ondas de alta frequência (ultrassons) que ao encontrar tecidos diferentes do corpo dentro do indivíduo realiza uma reflexão parcial (eco) em tecidos menos densos, ou de forma total em tecidos mais densos como os ossos. Mesmo com a ocorrência do eco, as ondas de alta frequência permanecem se propagando pelo corpo do animal e o conjunto de informações transmitidas pelas reflexões enviadas ao transdutor é projetado em uma tela como imagem, onde as medidas são tomadas (BUSBOOM et al., 2000).

Fatores importantes como o grau de conhecimento e de experiência do especialista, tipo e fabricante do equipamento, sondas utilizadas, o programa computacional de interpretação, além da característica avaliada são fundamentais para possibilitar a acurácia da técnica de ultrassonografia. O conhecimento sobre a característica que se quer avaliar por este método é fundamental, já que os coeficientes de correlação são muito influenciados pela variação existente entre os animais. Sendo assim, se existir uma grande variação da medida avaliada dentro do rebanho, torna-se indispensável a utilização da ultrassonografia em tempo real para melhor prever as diferenças apresentadas (BUSBOOM et al., 2000).

A ultrassonografia é uma técnica muito conhecida por sua rapidez, eficácia, segurança e baixo custo (SALES et al., 2019). Com o desenvolvimento do equipamento de ultrassom, houve a introdução dessa técnica em outras práticas, como na medicina e demais áreas biológicas, inicialmente como forma terapêutica e não diagnóstica (SEOANE et al., 2011) Algumas das várias aplicações usualmente utilizadas da

ultrassonografia e que será objeto de estudo desta revisão é a ultrassonografia de carcaça.

3.5. ULTRASSONOGRRAFIA DE CARÇAÇA

A ultrassonografia de carcaça é um método para realizar avaliação de carcaça por predições *in vivo* de algumas medidas da carcaça, principalmente em sistemas de produção de animais jovens, garantindo assim a economicidade do processo produtivo. Este método possibilita de forma não-destrutiva e não-invasiva, a estimativa da área de olho de lombo e espessura da gordura subcutânea, medidas essas que dão indicativo sobre a quantidade e qualidade do produto final. (SUIGUISAWA, 2002).

Além da Área de Olho de Lombo (AOL) medida tomada do músculo, temos a Gordura Intramuscular ou Marmoreio que influencia, diretamente, na qualidade da carne, pois interfere de maneira ampla em características organolépticas do produto como a textura e o sabor, possibilitando assim, um ranqueamento do produto e o destino para diferentes mercados, que procuram por qualidade excepcional da carcaça (GERALDO; QUIRINO; BELTRAME; COSTA, 2017).

Já a Espessura de Gordura Subcutânea (EGS) medida por meio da coleta de imagem de ultrassom para predizer a quantidade de gordura subcutânea na carcaça ovina e assim prevê o momento ideal para o abate. Esta medida possui relação com o teor de gordura a qual o conhecimento sobre a medida tem influência na uniformização da carcaça e assim pode permitir uma maior aceitação pelo consumidor (SANTOS, 2018).

Estas mensurações podem indicar composição da carcaça e de rendimento de cortes de alto valor comercial. A partir dessas mensurações, o produtor terá uma previsão de quais animais possuirão um maior rendimento da carcaça e influenciando, conseqüentemente, no produto final (LUCHIARI FILHO, 2000).

A ultrassonografia de carcaça é uma técnica alternativa para a mensuração das características de carcaça, aonde é possível extrair informações que permitirão predizer, antes do abate, o rendimento da carne de um animal, informações fundamentais para um produtor que trabalha com ovinos com aptidão para corte, além de determinar em um animal o ponto ideal para o seu abate, afim de evitar perda da qualidade da carcaça. A ultrassonografia é importante para se ter conhecimento sobre algumas medidas da

carcaça com o objetivo de uniformizar o rebanho, melhorar o manejo e a seleção de animais (SOUZA et al., 2016).

Através deste método, é possível obter as mensurações que são fundamentais para a avaliação de carcaça, todavia as medidas devem ser tomadas com menor erro possível, o que pode ser alcançado com o uso da visão computacional, que está cada vez mais presente e tem-se mostrado bastante promissora para diversas aplicações de estudos biológicos, podendo otimizar de forma significativa a sistematização das coletas de medidas de carcaça a partir de imagens ultrassonográficas.

4. VISÃO COMPUTACIONAL

4.1. HISTÓRIA

Os primeiros trabalhos que estudaram visão computacional foram propostos quando surgiram os primeiros computadores e esse ramo da computação evoluiu de maneira gradativa, concomitantemente, quando mais recursos computacionais, como por exemplo, memória e capacidade de armazenamento, se tornaram disponíveis (BACKES, 2016).

Roberts (1962), disponibilizou um dos primeiros detectores de borda em sua tese de doutorado pelo *Massachusetts Institute of Technology* (MIT). Em 1973, Harilick e colaboradores propuseram as matrizes de co-ocorrência para classificar as texturas (HARALICK et al. 1972).

Daugman (1980, 1985), apresentou modelos matemáticos com duas dimensões (filtros de Gabor) para realizar a simulação de comportamentos de campos de recepção do córtex visual. Logo após, em 1986, Canny propôs o primeiro algoritmo para realizar a detecção de bordas com elevada tolerância a ruídos (CANNY, 1986).

Mumford e Shah (1989) desenvolveram um algoritmo para segmentar regiões por meio da minimização de um funcional, denominado na época como funcional de Mumford e Shah, que é utilizado na segmentação de uma imagem. E finalmente em 2004, Lowe desenvolveu um excepcional algoritmo para a extração de características invariantes à imagem que possibilita a combinação entre objetos em diferentes perspectivas (LOWE, 2004).

Na atualidade, os trabalhos com visão computacional dispõem de um gama de algoritmos de elevado desempenho com finalidades específicas, como por exemplo segmentação em imagens médicas. Entretanto, quando refere-se a algoritmos no geral,

ainda há um longo processo para que se criem programas que simulem a capacidade biológica (BACKES, 2016).

4.2. IMPORTÂNCIA DA VISÃO COMPUTACIONAL

O surgimento do computador trouxe uma imensa ampliação da dimensão do homem, aumentando sua capacidade de calcular e armazenar grande quantidade de informação, e isso em nanossegundos, ampliou sua memória e o tempo de recuperação de uma informação. Simultaneamente, ocorreu um grande avanço nas tecnologias médicas voltadas ao diagnóstico por imagem, como por exemplo a tecnologia do aparelho de ultrassom que permite visualizar a estrutura de um órgão (LOBO, 2017).

Com isso, a Inteligência Artificial (IA) é um ramo da ciência da computação que imita os processos da inteligência humana, a capacidade de aprendizagem e o armazenamento de informações. Atualmente, a IA tem sido fortemente utilizada na análise de imagens e previsões, vários campos da medicina têm desenvolvido técnicas de aprimoramento da inteligência artificial ligada à melhoria da saúde no seu conceito mais, amplamente, aceito (BRAGA et al., 2018).

A tentativa de criação de sistemas inteligentes como o cérebro humano é algo muito antigo e que com o passar do tempo torna-se mais próximo com o avanço da computação e a criação de máquinas e softwares mais rápidos e potentes. Um desses processos na atualidade já é possível, como por exemplo o processo de reconhecimento de padrões, uma das características chave que até pouco tempo atrás diferenciava o ser humano das máquinas (MILLER, 2019).

O reconhecimento de padrões é o que possibilita que compreendamos o funcionamento ou a classificação de algo por meio de experiências passadas, embora nunca tenha se visto o algo em questão. Esse reconhecimento é feito com a tecnologia chamada de redes neurais artificiais, que se caracterizam em uma maneira de abordar a solução de problemas da inteligência artificial, sendo essas redes estando presentes dentro do ramo da visão computacional (MILLER, 2019).

Essas redes são sistemas computacionais paralelos que possuem unidades de processamento simples, também denominadas neurônios artificiais ou nodos, interligados entre si de maneira específica para realizar determinada tarefa (BINOTI et al., 2012).

A visão computacional trata-se da área de estudo que permite repassar para máquinas a incrível capacidade de visão, ou seja, o ato de captar imagens. Esta área da computação tem como objetivo, melhorá-las (por exemplo, remoção de ruídos ou aumento de contraste), delimitar as regiões de interesse de uma determinada imagem e extrair diversas informações de acordo com o tipo de imagem, e por fim, comparar a imagem com outras captadas anteriormente (BACKES, 2016).

Esta delimitação ou 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, 2009).

4.3. ALGORITMOS DE SEGMENTAÇÃO DE IMAGENS

Sistemas de visão computacional compreendem métodos de processamento digital de imagens. Estes métodos envolvem dois procedimentos, ou seja, o reconhecimento e a mensuração das características. Durante o reconhecimento, deve-se obter características das imagens e utilizar inteligência computacional para realizar a diferenciação entre as imagens coletadas. Já a mensuração da imagem consiste em uma automatização de inspeção. A segmentação do conjunto de imagens é realizada com o auxílio de algoritmos (FELICIANO et al., 2005).

A segmentação é um dos procedimentos mais importantes durante o processamento digital de imagens. Esta etapa tem como objetivo subdividir uma imagem em regiões. Esta fase deve parar quando os objetos ou regiões de interesse de uma determinada imagem são detectados. A exatidão da segmentação interfere diretamente nos procedimentos de análise do computador. A segmentação automatizada é realizada por algoritmos que têm como objetivo inferir marcações próximas ou iguais às realizadas por especialista (GONZALEZ e WOODS, 2000).

Os algoritmos de segmentação presentes na literatura baseiam-se em algumas similaridades, tais como: limiarização (*Thresholding*), crescimento de regiões (*Region Growing*), junção e separação (*Split & Merge*), aglomeração (*Clustering*), e em discontinuidades: detecção de pontos, retas e bordas através de máscaras de convolução (NEVES e PELAES, 2001).

O método Otsu é um algoritmo de limiar proposto por Nobuyuki Otsu. O algoritmo tem por objetivo determinar o valor limite ideal, ou seja, consiste em separar os elementos da região de interesse e do fundo, das imagens em tonalidades de cinza. A limiarização realizada pelo método de Otsu é fácil de ser implementada, com o entendimento do algoritmo. Além disso, o método de Otsu, por meio de procedimentos matemáticos, diminui a ocorrência de ruído nas imagens. Este algoritmo encontra-se presente em diversas bibliotecas de programas computacionais, tais como o *OpenCV*, *Matlab* e *Python* (OTSU, 1979).

Já o *K-means* é um dos mais populares algoritmos de aglomeração ou agrupamento (*clustering*), o qual se caracteriza por ser um algoritmo de aprendizado de máquina não supervisionado. O algoritmo tem como função segregar um conjunto de dados em um número específico de grupos, conhecido como *clustering*. Ao agrupar usando *K-Means*, uma o grupo de dados é dividido em “k” diferentes grupos, ou seja, se k for igual a 2 significa que o algoritmo identificará dois *clusters* na imagem. O agrupamento *K-Means* funciona bem quando não tem-se uma grande quantidade de dados. Este algoritmo tem diversas aplicações, desde a utilização no urbanismo e na biologia (como a segmentação de imagens médicas), como também no reagrupamento de epicentros de terremoto (GONZALEZ e WOODS, 2000).

O algoritmo S-LIC (Agrupamento iterativo linear simples), também é um algoritmo de agrupamento de aprendizado de máquina não supervisionado, muito semelhante do *k-means*, que trabalha com agrupamento de superpixel (ALEXANDRE, 2017).

Já o algoritmo U-Net trata-se de redes convolucionais para segmentação de imagens biomédicas usando estratégia de rede e treinamento do 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 (RONNENBERG et al., 2015).

Esse algoritmo de redes neurais convolucionais (U-Net) adapta-se, dinamicamente, às especificações de qualquer conjunto de dados. A essência da estrutura deste algoritmo é um procedimento completo de pré-processamento adaptativo, esquema de treinamento do próprio algoritmo e inferência dos dados. A segmentação feita pela U-Net é feita de maneira automatizada, sem interação manual,

com teste do conjunto de dados oferecendo soluções mais limpas (ISENSEE ET AL., 2018).

Vale ressaltar que segundo Ronnenberg et al. (2015), quando o algoritmo U-Net é utilizado na segmentação de imagens médicas obtêm resultados bastantes promissores, sendo, portanto, um dos algoritmos mais eficientes que permite trabalhar com um pequeno número de dados, aonde permite-se o treinamento do próprio algoritmo, mesmo com um número limitado de imagens.

4.4. APLICAÇÕES DA VISÃO COMPUTACIONAL

Aplicações da visão computacional podem ser encontradas em diversas áreas, tais como física, biologia, indústria, forças armadas, entre outras. Um exemplo que podemos citar é a detecção de terroristas em aeroportos, através de reconhecimento de face (biometria), análise morfológica de células, posicionamento de braços de robôs em reparos de submarinos e futebol de robôs (MILANO e HONORATO, 2010).

Com a crescente preocupação quanto a preservação do meio ambiente e, conseqüentemente, sua futura existência, aplicações ligadas a preservação ambiental também estão crescendo. Através do uso da visão computacional é possível identificar mudanças ambientais em tempo real, analisando imagens de satélites, obtendo informações de forma automática. É possível também estudar eventos específicos, como migração ou confinamento de aves em casos de estresse térmico, influenciadas pelo aquecimento global (RODRIGUES, 2006).

Outra área que ganha muito destaque é a Medicina. O uso de recursos computacionais pode ajudar no reconhecimento de padrões em imagens médicas, servindo, por exemplo, como um auxiliar no diagnóstico de algumas doenças, evitando um diagnóstico impreciso ou equivocado. A visão computacional também é utilizada para detectar anomalias, caracterizando-as e classificando-as, baseando-se num vasto conjunto de imagens e informações. Outro exemplo para a utilização da visão computacional é que a análise de uma radiografia, contribuindo bastante no diagnóstico de lesões (VIBORNY et al. 1994).

Outra área de forte utilização da visão computacional é na indústria, onde pode ser utilizada desde o controle da qualidade de determinado produto fabricado, até em áreas mais específicas, como caracterização e classificação de minério de ferro (FRICK, 2008).

Já no contexto da agricultura, a visão computacional pode ser empregada no diagnóstico de doenças e pragas, na estimativa de safra e na avaliação de maneira não invasiva de características como qualidade, aparência e volume, além de ser componente essencial em sistemas robóticos agrícolas (SANTOS et al., 2020).

Na agropecuária, têm-se diversas aplicações de utilização conhecidas sendo a pecuária de precisão um dos principais exemplos. Esta importante aplicação utiliza tecnologias para promover melhoria nos índices produtivos. Dentre estas tecnologias, destacamos a visão computacional, cujo objetivo é obter características de imagens e interpretá-las (WEBER et al, 2018).

Uma das aplicações da visão computacional na pecuária de precisão pode ser na identificação de bovinos, sendo que nessa tarefa apresenta como vantagem ser um método não invasivo, permite ainda auxiliar no manejo do rebanho. Uma das técnicas utilizadas em visão computacional pode alcançar resultados significativos na mesma função sem a exigência de coleta de informações específicas, bastando apresentar ao sistema computacional, exemplos de imagens de um bovino. É importante mencionar que a “pecuária 4.0” já faz parte da nossa realidade. As propostas para o uso de uma série de aplicativos chegam cada vez com maior intensidade no mercado zootécnico brasileiro (WEBER et al, 2018).

A visão computacional também pode ser utilizada para estudar características da carcaça de animais, por meio do reconhecimento de imagens ultrassonográficas do corpo do animal. Através das medidas mensuradas pelo especialista utilizando o ultrassom pode-se desenvolver algoritmos de inteligência artificial, para estimar as medidas de interesse a partir do processamento digital dessas imagens (RONNENBERG et al., 2015).

5. CONCLUSÕES

Por meio de ferramentas da visão computacional, é possível avaliar a qualidade da carcaça em ovinos por meio da utilização da ultrassonografia de características da carcaça.

Através dessa metodologia o produtor poderá ter uma previsão da quantidade de carcaça que determinado animal poderá dar, facilitando bastante o manejo dos animais.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- ALEXANDRE, E. B. IFT-SLIC: geração de superpixels com base em agrupamento iterativo linear simples e transformada imagem-floresta. 2017. 101 f. Dissertação (Mestrado) – Curso de Ciência da Computação, Universidade de São Paulo, São Paulo (SP), 2017.
- BACKES, A. R., SÁ JÚNIOR, J. J. M. Introdução a visão computacional usando matlab. **Alta Books**. 2016. 290p.
- BINOTTI, D. H. B. BINOTTI, M. L. M. S. LEITE, H. G. SILVA, A., 2013. Redução dos custos em inventário de povoamentos equiâneos. **Revista Brasileira de Ciências Agrárias**, 8, 125-129. DOI:10.5039/agraria.v8i1a2209.
- BONIFÁCIO, L., KREMER, R., ORLANDO, D., 1979. Estudio comparativo de corderos Corriedale y Corriedale por Texel.2. Pesos alnacer, ganancias diarias y características de La carcasa. *Revista Veterinária*, 70, 63-71.
- BRAGA, A. V., LINS, A. F., SOARES, L. S., FLEURY, L. G., CARVALHO, J. C., PRADO, R. S., 2018. Inteligência artificial na medicina. III CIPEEX - Ciência para a redução das desigualdades: **Anais**. v. 2. 2018. Disponível em: <<http://anais.unievangelica.edu.br/index.php/CIPEEX/article/view/2997/1348>>. Acesso em abr. de 2021.
- BURIN, P. C., 2016. Aspectos gerais sob a produção de carcaças ovinas. **Revista Eletrônica de Veterinária**, 17, 1-19. <https://www.redalyc.org/pdf/636/63647454002.pdf>.
- BUSBOOM, J. A., BRETHOUR, J. R., ELIASCALLES, A., GASKINS, C. T., DUCCKETT, S. K., 2000. Using ultrasound for prediction feeding and marketing of cattle. Disponível em: <www.ansci.wsu.edu/wagsymp/articles97/busboom.htm>. Acesso em: 14 de abr de 2016.
- CANNY, J., 1986. A Computational Approach To Edge Detection, **IEEE Trans. Pattern Analysis and Machine Intelligence**, 8, 679-714.
- CARTAXO, F. Q., SOUSA, W. H., 2008. Correlações entre as características obtidas in vivo por ultra-som e as obtidas na carcaça de cordeiros terminados em confinamento. **Revista Brasileira de Zootecnia**, 37, 1490-1495. <http://dx.doi.org/10.1590/s1516-35982008000800022>.
- CERUTTI, L. F. S. Radiodiagnóstico e procedimentos radiológicos. Atena Editora, v. 2, 2019, 29 p. <https://www.atenaeditora.com.br/post-artigo/23602>.

- CEZAR, M. F., SOUZA, W. H., 2007. Carcaças Ovinas e Caprinas: obtenção, avaliação e classificação. Editora Agropecuária Tropical, 147p.
- COSTA, E. C., RESTLE, J., BRONDANI, I. L., PEROTTONI, J., FATURI, C., MENEZES, L. F. G., 2002. Composição física da carcaça, qualidade da carne e conteúdo de colesterol no músculo Longissimus dorsi de novilhos Red Angus superprecoces, terminados em confinamento e abatidos com diferentes pesos. *Revista Brasileira de Zootecnia*, 31, 417-428. <http://dx.doi.org/10.1590/S1516-35982002000200017>.
- DAUGMAN, J. G., 1980. Two-dimensional spectral analysis of cortical receptive field profiles. *Vision Research*, 20, 847-856.
- FELICIANO, F. F., SOUZA, I. L., LETA, F. R., 2005. Visão computacional aplicada à metrologia dimensional automatizada: considerações sobre sua exatidão. *Engevista*, 7, 38-50. <https://doi.org/10.22409/engevista.v7i2.164>.
- GERALDO, A. T., QUIRINO, C. R., BELTRAME, R. T., COSTA, R. L., 2017. Avaliação de carcaça ovina por tomografia computadorizada: estado da arte no Brasil e no mundo. *Pubvet*, 11, 91-102. <http://dx.doi.org/10.22256/pubvet.v11n1.91-102>.
- GONZAGA NETO, S., SILVA SOBRINHO, A. G., ZEOLA, N.M.B.L., et al., 2006. Características quantitativas da carcaça de cordeiros deslanados Morada Nova, em função da relação volumoso: concentrado na dieta. *Revista Brasileira de Zootecnia*, 35, 1487-1495. <https://doi.org/10.1590/S1516-35982006000500031>.
- GONZALEZ, R. C., WOODS, R. C. Processamento de imagens digitais, *Editora Blucher*, 3, 2000, 624f.
- HARALICK, R. M., SHANMUGAM, DINSTEIN, L. On some quickly computable features for texture. *Proceedings Symposium on Computer Image Processing and Recognition*, University of Missouri – Columbia, 2, 12, 1972.
- HASHIMOTO, J. H., OSÓRIO, J. C. S., OSÓRIO, M. T. M., BONACINA, M. S., LEHMEN, R. I., PEDROSO, C. E. S., 2012. Qualidade da carcaça, desenvolvimento regional e tecidual de cordeiros terminados em três sistemas. *Revista Brasileira de Zootecnia*, 41, 438-448. <https://doi.org/10.1590/S1516-35982012000200029>.
- IBGE – Instituto Brasileiro de Geografia e Estatística. Censo Agropecuário. 2019.
- ISENSEE, F., PETERSEN, J., KLEIN, A., ZIMMERER, D., JAEGER, P. F., et al., 2018. nnU-Net: Self-adapting Framework for U-Net-Based Medical Image Segmentation. *arXiv preprint*. arXiv:1809.10486.

- JAINUDEEN, M.R.; WAHID, H.; HAFEZ, 2004. Ovinos e Caprinos. **Reprodução animal**, 7, 173-182.
- LEITE, A. A., FAGAN, E. P., PORTO, P. P. LAVORATO JÚNIOR, F. J. V., MARQUES, R. S., 2013. Características morfométricas e quantitativas de carcaça de cordeiros suplementados com silagem de milho e pellet bagaço de cana. **Synergismus scyentifica**, 8, 1-3, 2013. <http://revistas.utfpr.edu.br/pb/index.php/SysScy/article/view/1740>.
- LIMA, N. L. L., SOBRINHO, A. G. S., ALMEIDA, F. A., et al., 2013. Quantitative and qualitative characteristics of the non-carcass components and the meat of lambs fed sunflower seeds and vitamin E. **Revista Brasileira de Zootecnia**, 42, 51-60.
- LIRA, A. B. Desempenho e características de carcaça de dois biótipos de ovinos da raça Santa Inês terminados a pasto e suplementados com blocos multinutricionais. 2016. 52 f. Tese (Doutorado) - Curso de Zootecnia, Universidade Federal da Paraíba, Areia (PB), 2016.
- LIRA, A. B., GONZAGA NETO, S., SOUSA, W. H., RAMOS, J. P. F., CARTAXO, F. Q., SANTOS, E. M., CÉZAR, M. F., FREITAS, F. F., 2017. 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**, 18, 313-326. <http://dx.doi.org/10.1590/s1519-99402017000200010>.
- LOBO, L. C., 2017. Inteligência Artificial e Medicina. **Revista Brasileira de Educação Médica**, 41, 185-193. <https://doi.org/10.1590/1981-52712015v41n2esp>.
- LOWE, D. G., 2004. Distinctive Image Features from Scale-Invariant Keypoints. e **International Journal of Computer Vision**. <https://www.cs.ubc.ca/~lowe/papers/ijcv04.pdf>.
- LUCHIARI FILHO, A. Pecuária da carne bovina. São Paulo: LinBife, 2000. 134p.
- MARENGONI, M., STRINGHINI, D., 2009. Tutorial: Introdução a visão computacional usando OpenCV. **Revista de Informática Teórica e Aplicada**, 16, 125-160. https://www.seer.ufrgs.br/rita/article/view/rita_v16_n1_p125/7289.
- MCMANUS, C., PAIM, T. P., LOUVANDINI, H., DALLAGO, B., DIAS, L. T., TEIXEIRA, R. A., 2013. Avaliação ultrasonográfica da qualidade de carcaça de ovinos Santa Inês. **Ciência Animal Brasileira**, 14, 8-16. <http://dx.doi.org/10.5216/cab.v14i1.12336>.

- MILLER, T. B. Aplicação de redes neurais artificiais na avicultura comercial. 2019. 44 f. Trabalho de Conclusão de Curso (Graduação) – Curso de Medicina Veterinária, Universidade Federal do Rio Grande do Sul, Porto Alegre (RS), 2019.
- MORENO, G. M. B., BOAVENTURA NETO, O., 2016. Avaliação e cortes da carcaça em ovinos e caprinos. **Ciência Veterinária nos Trópicos**, 19, 32-42. http://www.revvt.org.br/volume19_2/Revista%20Cient%C3%ADfica2.pdf.
- MUMFORD, D., SHAH, J., 1989. Optimal Approximations by Piecewise Smooth Functions and Associated Variational Problems. **Communications on Pure and Applied Mathematics XLII**, 5, 577–685. doi: 10.1002/cpa.3160420503,MR0997568, Zbl0691.49036.
- NEVES, S. C. M., PELAES, E. G., 2001. Estudo e implementação de técnicas de segmentação de imagens. **Revista Virtual de Iniciação Acadêmica da UFPA**, 1, 1-11. <http://www.ufpa.br/revistaic>.
- OSÓRIO, J. C. S. OSÓRIO, M. T. M., VARGAS JÚNIOR, F. M., et al., 2012. Critérios para abate do animal e a qualidade da carne. **Revista Agrarian**, 5, 433-443. <https://ojs.ufgd.edu.br/index.php/agrarian/article/view/1822/1217>.
- OTSU, N. A., 1979. threshold selection method from gray-level histograms. **IEEE transactions on systems, man, and cybernetics**, 9, 62-66. <https://ieeexplore.ieee.org/document/4310076>.
- POLIZEL NETO, A., JORGE, A. M., MOREIRA, P. S. A., GOMES, H. F. B., PINHEIRO, R. S. B., ANDRADE, E. N., 2009. Correlações entre medidas ultrassônicas e na carcaça de bovinos terminados em pastagem. **Revista Brasileira de Saúde e Produção Animal**, 10, 137-145. <https://periodicos.ufba.br/index.php/rbspa/article/view/39749>.
- PRADO, C. S., PÁDUA, J. T., CORRÊA, M. P. C., FERRAZ, J. B. S., MIYAGI, E. S., RESENDE, L. S., 2004. Comparação de diferentes métodos de avaliação da área de olho de lombo e cobertura de gordura em bovinos de corte. **Revista Ciência Animal Brasileira**, 5, 141-149. <https://www.revistas.ufg.br/vet/article/view/26837>.
- ROBERTS, L. G., 1962. Pictures coding using pseudo-random noise. **Ire Transition on Information Theory**, 8, 145-154.
- RONNEBERGER, O., FISHER, P., BROX, T., 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. **Medical Image Computing and Computer-Assisted Intervention (MICCAI)**, 9351, 234-241. arXiv:1505.04597.

SAINZ, R. D., ARAÚJO, F. R. C. Uso de tecnologias de ultra-som no melhoramento do produto final carne. In: V Congresso Brasileiro das Raças Zebuínas, Uberaba (MG), 2002. Disponível em:

<http://admin.webplus.com.br/public/upload/downloads/ABCZ_2002_final.pdf>.

Acesso em fev de 2021.

SAINZ, R.D. Qualidade das carcaças e da carne ovina e caprina. In: REUNIÃO ANUAL DA SOCIEDADE BRASILEIRA DE ZOOTECNIA, 32, 1996, Fortaleza. **Anais...** Fortaleza: Sociedade Brasileira de Zootecnia, 1996. p. 3-14.

SALES, R. O., BRAGA, P. S., BRAGA FILHO, C. T., 2019. A importância da ultrassonografia na Medicina Veterinária: Ensino. **Revista Brasileira de Higiene e Sanidade Animal**, 13, 156-178. <http://dx.doi.org/10.5935/1981-2965.20190012>.

VIANA, J. G. A. Panorama geral da ovinocultura no Mundo e no Brasil. **Revista Ovinos**, 12, 2008. www.uniovinos.unipampa.edu.br/index.php?option=com_docman.

SANTOS, C. A. Características qualitativas da carne de cordeiros ½ Dorper +1/2 Santa Inês abatidos com diferentes espessuras de gordura subcutânea. 2018. 56f. Dissertação (Mestrado) – Curso de Zootecnia, Universidade Federal de Sergipe, São Cristóvão (SE), 2018.

SEOANE, M. P. R., GARCIA, D. A. A., FROES, T. R., 2011. A história da ultrassonografia veterinária em pequenos animais. **Archives of Veterinary Science**, 16, 54-61. <https://revistas.ufpr.br/veterinary/article/view/17646/14963>.

SILVA, F. V., BORGES, I., SÁ, H. C. M., et al., 2018. Performance and carcass characteristics of lambs fed a solution of cheese whey during feedlot and pre-slaughter lairage. **Revista Brasileira de Zootecnia**, 47, 1 - 6. <https://doi.org/10.1590/rbz4720170026>.

SOUZA, S. F., BOAVENTURA NETO, O., MORENO, G. M., MUNIZ, E. N., 2016. Aplicação da ultrassonografia para avaliação de condição corporal e acabamento de carcaça em pequenos ruminantes. **Ciência Veterinária nos Trópicos**, 19. Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1074282/aplicacao-da-ultrassonografia-para-avaliacao-de-condicao-e-acabamento-de-carcaca-em-pequenos-ruminantes>>. Acesso em fev de 2021.

STOUFFER, J. R., 1991. Using Ultrasound to Objectively Evaluate Composition and Quality Livestock. **21st Century Concepts Important to Meat-Animal Evaluation – Wisconsin**, 49-54.

SUGUISAWA, L., MATTOS, W. R. S., OLIVEIRA, H. N. et al., 2006. Correlações simples entre as medidas de ultra-som e a composição da carcaça de bovinos jovens. **Revista Brasileira de Zootecnia**, 35,169-176. <https://doi.org/10.1590/S1516-35982006000100022>.

SUGUISAWA, L., MATOS, E. C., SUGUISAWA, J. M., 2013. Uso da ultrassonografia na avaliação de características de carcaça e de qualidade da carne. Melhoramento genético aplicado em gado de corte, **Embrapa**, 97-108, 2013. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/127707/1/Melhoramento-Genetico-livro-completo.pdf>. Acesso em abr de 2021.

SUGUISAWA, L. Ultra-sonografia para predição das características e composição da carcaça de bovinos. 2002. 70f. Dissertação (Mestrado) – Curso de Agronomia, Universidade de São Paulo, Piracicaba (SP), 2002.

WILSON, D. E., 1992. Application of ultrasound for genetic improvement. **Journal of Animal Science**, 70, 973-983. <https://doi.org/10.2527/1992.703973x>.

CAPÍTULO II

Predição da área do músculo *Longissimus dorsi* a partir de imagens ultrassonográficas em ovinos utilizando visão computacional

Predição da área do músculo *Longissimus dorsi* a partir de imagens ultrassonográficas em ovinos utilizando visão computacional

Francisco Albir Lima Júnior^{a,*}, José Lindenberg Rocha Sarmiento^b

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

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

*Autor correspondente.

Endereços de e-mail: albirjunior@hotmail.com (F.A. Lima Júnior),
sarmento@ufpi.edu.br (J.L.R. Sarmento).

RESUMO:

No Brasil, a grande parte da carne ovina ofertada é oriunda de animais com baixa qualidade de carcaça. Para que o produto final atenda à demanda do mercado consumidor, é fundamental que os produtores disponibilizem carne ovina de excelente qualidade. Sendo assim, a ultrassonografia para avaliar a carcaça é uma técnica eficaz para o estudo das características produtivas e reprodutivas. Uma dessas medidas obtidas é a área de olho de lombo (AOL) tomada do músculo *Longissimus dorsi*, uma das características de carcaça mais utilizadas e estudadas relacionada ao rendimento e deposição de músculos, pois esta mensuração possui alta correlação com a musculosidade da carcaça. Estas medidas podem ser identificadas a partir de imagens do músculo tomadas no animal com o auxílio de algoritmos matemáticos de visão computacional. As redes neurais convolucionais (U-Net) destacam-se por apresentar resultados mais promissores comparando-se com outros algoritmos. Dessa maneira, objetivou-se com esta pesquisa realizar a mensuração da Área de Olho de Lombo do músculo *Longissimus dorsi* em ovinos utilizando redes neurais convolucionais. A metodologia proposta para este trabalho foi dividida em 4 etapas. Na etapa de coleta de dados, 121 imagens ultrassonográficas de fêmeas ovinas foram coletadas com auxílio de aparelho de ultrassom. Durante a segmentação das regiões de interesse, utilizou-se apenas um método de segmentação automatizado com o intuito de reconhecer as regiões de interesse nelas presentes na imagem do músculo por redes neurais (U-Net). Para a avaliação de segmentações automáticas, utilizou-se as métricas de coeficiente de dados *Dice* e a métrica de intersecção sobre união (IoU). Na extração de atributos, encontrou-se características importantes para a previsão de AOL (Área de Olho de Lombo). Na última etapa, foi realizada uma análise de regressão, sendo a variável independente os valores dos atributos obtidos com os descritores utilizados e a variável dependente a AOL calculado por profissional para a imagem de ultrassom do animal, aonde utilizou-se as métricas de quadrado médio do resíduo (QMR) e erro médio absoluto (EMA). Dois algoritmos de regressão foram utilizados, *AdaBoost Regressor* (ABR) e *Random Forest Regressor* (RFR). Os valores obtidos pela métrica *Dice* foi de 0,94 e a da IoU foi de 0,89 o que demonstra alta similaridade entre o real e o previsto, pois os valores foram muito próximos de 1. Os valores de QMR, EMA e R^2 para o ABR é de, respectivamente, 2,61, 1,22 e 0,48 e para o RFR é de 2,15, 1,12 e 0,56, o que demonstra uma correlação positiva entre os valores preditos e os valores reais, aonde observou-se que o RFR teve QMR e EMA menores e R^2 maior comparando-se com ABR, enfatizando que o *Random Forest* apresentou resultados mais promissores que o *Adabooster*. Observou-se também que a padronização adotada durante a coleta de imagens foi fundamental para aumentar a precisão dos resultados. Portanto, a medição automatizada da AOL pelo algoritmo de maneira padronizada a partir de imagens ultrassonográficas é promissora e com maior eficiência na realização desta medida em grandes quantidades de imagens com alta precisão, sem a intervenção humana na delimitação da área do músculo *Longissimus dorsi* em ovinos de corte de carcaça padronizada.

Palavras chave: carcaça, inteligência artificial, produção de carne, u-net

ABSTRACT:

In Brazil, most of the sheep meat offered comes from animals with low carcass quality, which is probably related to genetics and management used. However, for the final product to meet the demand of the consumer market, it is essential that producers supply sheep meat of excellent quality. Therefore, ultrasonography for carcass evaluation is an effective technique for the study of productive and reproductive characteristics. One of these corresponding measures is the rib eye area (REA) removed from the Longissimus dorsi muscle, one of the most used and studied carcass characteristics related to muscle yield and deposition, since this measure has a high correlation with the carcass muscularity. These measures can be identified from images of the resource in the animal with the aid of mathematical algorithms of computer vision. Convolutional neural networks (U-Net) stand out for presenting more promising results when compared to other algorithms. Thus, the objective of this research was to measure the Rib Eye Area of the Longissimus dorsi muscle in sheep using convolutional neural networks. The methodology proposed for this work was divided into 4 stages. In the data collection stage, 121 ultrasound images of sheep were collected with the aid of an ultrasound device. In the search stage of the regions of interest, only an automated search method was used in order to recognize the regions of interest present in them in the image of the muscle by neural networks (U-Net). For the evaluation of automatic segmentations, the Dice data coefficient metrics and the intersection over union (IoU) metrics were used. During a resource extraction stage, the objective was to find the important characteristics for the forecast of the REA (Rib Eye Area). In the last step, a regression analysis was performed, using the values of the resources provided with the descriptors used and the dependent variable REA as an independent variable, by professional for the ultrasound image of the animal, where the metrics of the mean square were used. Mean square error (MSE) and mean absolute error (MAE). Two regression algorithms were used, AdaBoost Regressor (ABR) and Random Forest Regressor (RFR). The values obtained by the metric Dice was 0.94 and the IoU was 0.89, which shows a great similarity between the real and the predicted, since the values were very close to 1. The values of MSE, MAE and R^2 for the ABR is 2.61, 1.22 and 0.48, respectively, and for the RFR it is 2.15, 1.12 and 0.56, which demonstrates a positive correlation between the predicted values and the values real, where it is observed that the RFR had lower MSE and MAE and higher R^2 in relation to ABR, emphasizing that Random Forest presented more promising results than Adabooster. It was also observed that a standardization adopted during the collection of the images was fundamental to increase the precision of the results. Therefore, an automated measurement of AOL by the algorithm in a standardized way from ultrasound images is promising and will allow greater efficiency in performing this measurement in large quantities of images with high precision, since it does not require human intervention in the delimitation of Longissimus. The area of the dorsi muscle in sheep with standardized carcass is an efficient method to predict meat yield.

Keywords: artificial intelligence, carcass, meat production, u-net

1. INTRODUÇÃO

No Brasil, a grande parte da carne ovina ofertada é oriunda de animais com baixa qualidade de carcaça o que, provavelmente, está relacionado à baixa genética e aos manejos nutricionais e sanitários e reprodutivos. Para que o produto final seja competitivo e atenda à demanda do mercado consumidor, é fundamental que os produtores disponibilizem carne ovina de excelente qualidade (MCMANUS et al., 2013).

A qualidade da carcaça ovina pode sofrer influência da raça, idade, peso de abate, sexo, dentre outros fatores (MÜLLER, 1993). O objetivo em ovinos de corte é a obtenção de animais capazes de direcionar elevadas quantidades de nutrientes para produzir músculos, uma vez que o acúmulo desse tecido é desejável e reflete a maior parte da porção comestível de uma carcaça, refletindo, conseqüentemente, em uma maior qualidade da carne (SANTOS et al., 2001).

A ultrassonografia para avaliar a carcaça é uma técnica eficaz para o estudo das características produtivas (SILVA et al., 2005). Esta metodologia vem sendo utilizada no campo com aparelhos portáteis, demonstrando alta repetibilidade, baixo custo e fácil operação, sendo rápida e objetiva respondendo às demandas do mercado sem diminuir a qualidade do produto final (RIPOLL et al., 2010).

Diversas medidas podem ser obtidas com a ultrassonografia de carcaça, sendo a área de olho de lombo (AOL) tomada do músculo *Longissimus dorsi*, uma das mais utilizadas e estudadas para avaliar a quantidade de músculo, pois esta mensuração possui alta correlação com a musculosidade da carcaça (SUGISAWA et al., 2006). O monitoramento de características como a AOL, além de auxiliar na escolha dos animais para o abate, fornece informações úteis para incorporação em modelos de crescimento e seleção animal (BERGEN et al., 1996).

Estas medidas podem ser identificadas a partir da imagem do músculo no animal com o auxílio de algoritmos matemáticos da visão computacional que podem proporcionar vantagens para diminuir os erros de leitura e acelerar o processo de mensuração em larga escala. Estes algoritmos podem extrair, durante a segmentação das imagens, a região de interesse de uma imagem e remover além do fundo da imagem, os ruídos (MARENGONI e STRINGHINI, 2009). Existem diversos algoritmos presentes na literatura, que podem realizar a segmentação de imagens médicas, entretanto, segundo Ronnenberg et al. (2015), o algoritmo de redes neurais convolucionais (U-Net)

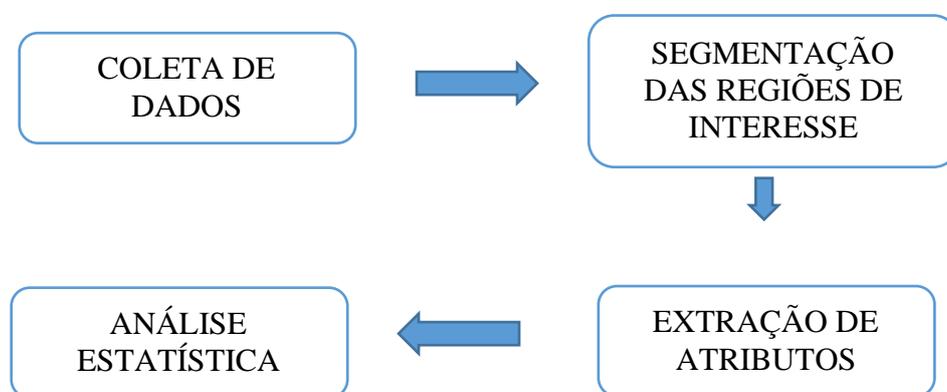
é o que mais se destaca por apresentar resultados mais promissores comparado aos demais algoritmos.

Dessa maneira, objetivou-se realizar a mensuração da Área de Olho de Lombo do músculo *Longissimus dorsi* em ovinos para auxiliar na avaliação de carcaça utilizando redes neurais convolucionais (U-Net) e conseqüentemente, realizar a fenotipagem dos animais com intuito de ampliar o maior número de informações sobre os animais em estudo com maior precisão.

2. METODOLOGIA

O resumo da descrição das etapas da metodologia está representado na Figura 1.

Figura 1: Fluxograma das etapas da metodologia



Os dados utilizados no estudo pertencem ao projeto Estudo genômico aplicado ao melhoramento genético de ovinos Santa Inês para características de carcaça, nº 340/17 e aprovado pela Comissão de Ética no Uso de Animais (CEUA/UFPI), 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. A metodologia proposta para este trabalho foi dividida em 4 etapas.

2.1. COLETA DE DADOS

2.1.1. COLETA DO BANCO DE DADOS

Na primeira etapa foram coletadas 121 imagens ultrassonográficas de fêmeas ovinas, sendo 27 da raça Dorper e 94 da raça Santa Inês. As imagens foram coletadas do aparelho de ultrassom *sonoscape* modelo A5V (Figura 2) equipado com um transdutor multifrequenciais aonde utilizou-se a frequência entre 7,5 a 8,5 MHz.



Figura 2 – Coleta de imagem ultrassonográfica do músculo *Longissimus dorsi* em um ultrassom *Sonoscape* modelo A5V.

2.1.2. CARACTERÍSTICAS MENSURADAS

Foram registradas as seguintes informações: número do animal, sexo e área de olho de lombo (AOL) em cm². As mensurações de AOL 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^o e 13^o costela. Durante o registro das imagens, o animal em estudo foi contido, de maneira confortável para melhor qualidade da imagem ultrassonográfica (Figura 2). 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. A determinação da medida da AOL foi realizada através da ferramenta de medida do próprio aparelho de ultrassom por profissional treinado.



Figura 3 – Imagem ultrassonográfica do músculo *Longissimus dorsi* (TA1 – área de olho de lombo; D1 – profundidade de olho de lombo; D2 – comprimento de olho de lombo; D3 – espessura da gordura subcutânea).

2.1.3. PRÉ-PROCESSAMENTO DE IMAGENS

A base de imagens utilizada foi dividida em imagens originais e imagens com as delimitações da área do músculo *Longissimus dorsi* que deram origem as médias para AOL (máscaras de segmentações). As originais foram coloridas em um sistema de cores VVA (vermelho-verde-azul) enquanto as máscaras de segmentação são imagens binárias.

Ao analisar as primeiras imagens, verificou-se que os seus três canais de cores são idênticos em intensidades de *pixels*. Assim, o primeiro canal de cor V (vermelho) foi utilizado, de modo que ambos os conjuntos, original e máscara, foram formados por imagens em escala de cinza, sendo formado por um único canal de cor. Sendo assim, a utilização de informações repetidas e processamento desnecessário é evitado.

Depois de realizar a segmentação utilizando máscaras de algoritmos de segmentação e a própria base criada por especialistas, operações foram realizadas para obter somente a caixa delimitadora da região de interesse (ROI). Este último passo foi útil para evitar dados desnecessários ao longo do experimento, evitando um custo computacional adicional e indução de erros.

Para evitar problemas com as dimensões, por não estarem no mesmo formato na regressão, aplicou-se uma operação de preenchimento de zero.

A etapa de pré-processamento resultou em imagens em níveis de cinza, de tamanho 217×323 *pixels*, na escala de 0-255, apropriado para a segmentação. É importante destacar que antes da segmentação realizada com U-net (redes neurais convolucionais), além dos procedimentos já mencionados, uma nova operação de preenchimento de zero foi utilizado, de modo que todas as imagens foram redimensionadas para 320×320 *pixels* (formato de entrada de rede neural), sem perda da qualidade com a distorção.

2.2. SEGMENTAÇÃO DAS REGIÕES DE INTERESSE

Esta pesquisa utilizou apenas um método de segmentação automatizado com base em algoritmo de redes neurais (U-Net). O objetivo é inferir marcações próximas ou iguais as feitas pelo especialista que coletou as imagens no ultrassom. Os métodos foram escolhidos com base em sua relevância para a segmentação em imagens de ultrassom (RONNENBERG, et al., 2015).

Durante a segmentação, do total das imagens, 70% foram utilizadas para treinamento do algoritmo e 30% para testes.

2.2.1. MÉTRICAS DE SEGMENTAÇÃO

Para a avaliação de segmentações automáticas, duas métricas foram aplicadas que indicam, através de seus valores, a qualidade das segmentações. Cada uma dessas métricas são abordadas abaixo.

A métrica do coeficiente de dados (Dice) é definida como a razão entre o tamanho da intersecção e o tamanho das regiões segmentadas, automaticamente, (A) e, manualmente, regiões marcadas (B) (SORENSEN, 1948; DICE; LEE, 1945). Essa operação é expressa pela Equação 1:

$$(1) \quad Dice = \frac{2|A \cap B|}{|A| + |B|}$$

Já a Equação 2 refere-se à métrica IoU (Intersecção sobre União), também conhecido como índice Jaccard. A IoU (mediu o número de pixels comuns entre a segmentação e as máscaras de previsão (intersecção) dividido pelo número total de pixels

presentes em ambas as máscaras (união) (ALBATINEH e NIEWIADOMSKA, 2011). As máscaras são as imagens segmentadas pelo algoritmo.

$$(2) \quad IoU = \frac{\text{Segmentação} \cap \text{Predição}}{\text{Segmentação} \cup \text{Predição}}$$

2.3. EXTRAÇÃO DE ATRIBUTOS (CARACTERÍSTICAS)

Com o objetivo de encontrar características importantes para a previsão de AOL (Área de Olho de Lombo), a extração de atributos foi investigada usando duas categorias de imagem de algoritmos de script e duas redes neurais artificiais pré-treinadas usando um ferramenta online *LabelMe*, que trata-se de uma ferramenta de anotação online para construir bancos de dados de imagens para pesquisa de visão computacional. (RUSSELL et al., 2008). Utilizou-se o *RegionProps* que obteve as mensurações da área de olho de lombo a partir de cada imagem (ARDHIANTO e BUDIARSO, 2013).

2.4. ANÁLISE ESTATÍSTICA

2.4.1. ANÁLISE DE REGRESSÃO

Nesta pesquisa a análise de regressão foi dada pela relação entre uma variável dependente e uma ou mais variáveis independentes, a variável dependente foi chamada de Y e as independentes, de X, onde X são os valores dos atributos obtidos com os descritores utilizados e o Y estimado é a AOL prevista para a imagem de ultrassom do animal.

Dois algoritmos de regressão foram utilizados, *AdaBoost Regressor* e *Random Forest Regressor*. (CAO et al., 2013; BREIMAN, 1996). O conjunto de características foi dividido, com os valores já normalizados entre 0 e 1, em treinamento e teste, 50 e 50%, respectivamente. Os dois algoritmos foram treinados no conjunto de treinamento e o modelo foi testado no conjunto de teste.

2.4.2. MÉTRICAS DE REGRESSÃO

Nesta subseção, as métricas mais utilizadas na avaliação de desempenho de modelos de regressão são abordadas, ambas 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 3, calcula a média dos erros do modelo ao quadrado, ou seja, diferenças menores são menos importantes, enquanto diferenças maiores recebem mais peso, aonde y_i é a o valor real e \hat{y}_i é o valor predito.

$$(3) \quad QMR(y, \hat{y}) = \frac{1}{n_{amostras}} \sum_{i=0}^{n_{amostras}-1} (y_i - \hat{y}_i)^2$$

O EMA é uma métrica de risco representada pela Equação 4 sendo y_i o valor real e \hat{y}_i é o valor predito.

$$(4) \quad EMA(y, \hat{y}) = \frac{1}{n_{amostras}} \sum_{i=0}^{n_{amostras}-1} |y_i - \hat{y}_i|$$

De acordo com Quinino et al. (1991), O valor de R^2 ou coeficiente de determinação, está representado na Equação 5, sendo y_i o valor real e \hat{y}_i é o valor predito.

$$(5) \quad R^2(y, \hat{y}) = 1 - \frac{\sum_{i=0}^{n_{amostras}-1} (y_i - \hat{y}_i)^2}{\sum_{i=0}^{n_{amostras}-1} (y_i - \bar{y})^2}$$

A análise de regressão foi realizada por meio da linguagem de programação em *Python* (Python, 2021).

2.4.3. ESTATÍSTICA DESCRITIVA E COMPARAÇÃO DE MÉDIAS

As médias de área de olho de lombo determinadas por especialista com ultrassom (AOL) e as preditas pelo software (AOL 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 % de probabilidade. Estes procedimentos foram realizados com o auxílio do *software* SAS® (SAS University Edition, EUA).

3. RESULTADOS E DISCUSSÃO

3.1. RESULTADOS DA SEGMENTAÇÃO

Observa-se na Tabela 1, a representação dos resultados obtidos com os métodos de segmentação automática a partir das imagens de ultrassonografia dos ovinos por meio da utilização do algoritmo U-Net. As métricas de coeficiente de dados e interseção sobre união 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 121 imagens de ultrassom foram apresentados na Tabela 1.

Tabela 1: Resultados da segmentação realizada com o algoritmo U-net

Técnica de Segmentação	Métrica de coeficiente de dados (<i>Score Dice</i>)	Índice Jaccard (IoU)
U-Net	0,9424	0,8911

Os valores obtidos para as métricas foram próximos a 1 (*Score Dice*, 0,94; e *IoU*, 0,89) em uma escala de 0 a 1. Segundo Albatineh e Niewiadomska-Bugaj (2011), as duas métricas utilizadas são métricas de similaridade, onde serve para comparar dois resultados, ou seja, os dois índices mostram a 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 real e o predito. Desta maneira, este algoritmo se mostrou eficiente na segmentação das imagens.

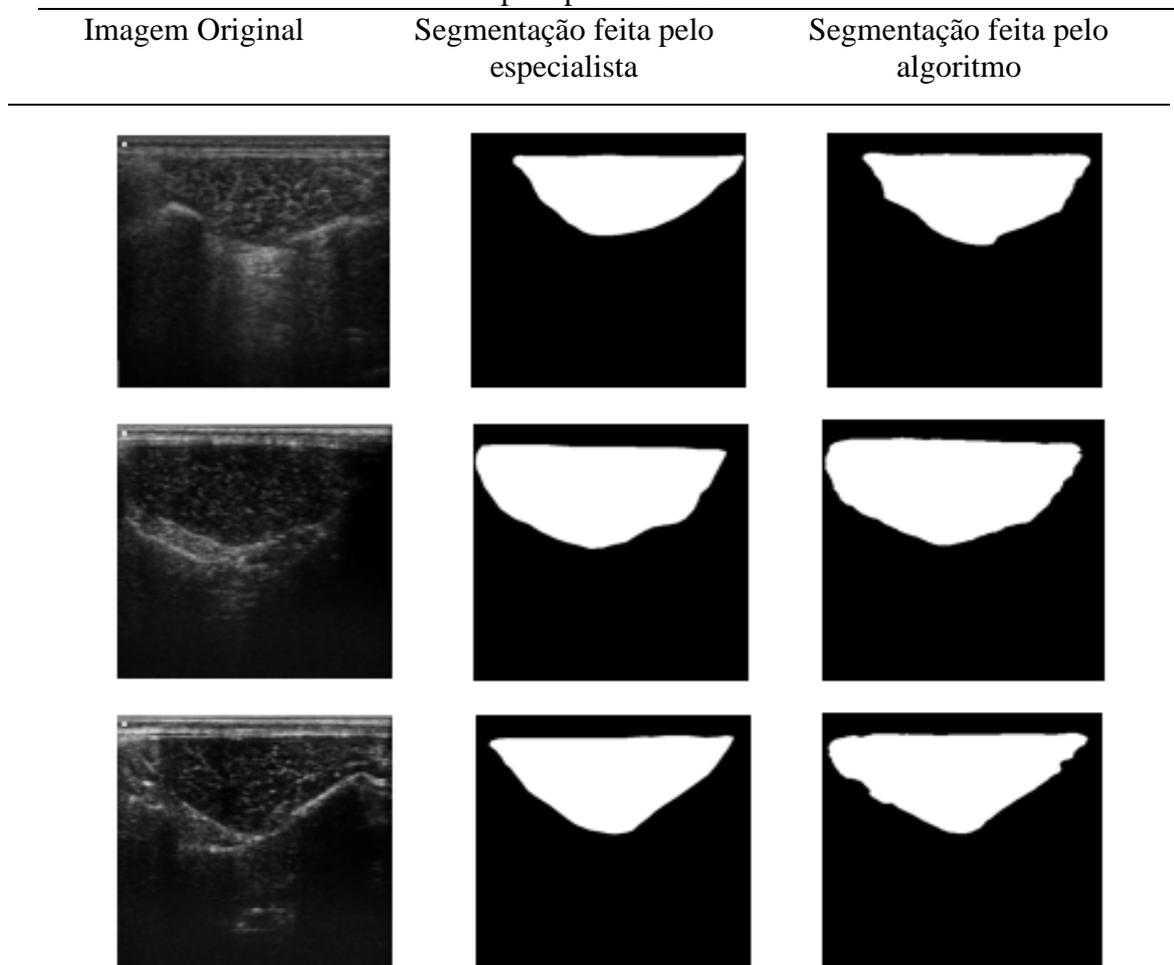
Estas duas métricas serviram também para mostrar o quanto o algoritmo U-Net é eficiente para segmentar regiões de interesse visto que os valores foram próximos a 1. Eelbode et al. (2020) afirmam que o *score Dice* e o índice *Jaccard* (métrica *IoU*) são utilizados para avaliar o desempenho da segmentação, em muitas imagens médicas e tarefas clássicas de visão computacional. Enquanto, Bertels et al. (2019) afirmam que o *score Dice* e a métrica *IoU* são métricas, geralmente, utilizadas para a avaliação de funções de segmentação em imagens médicas.

Já Fidon et al. (2017) afirmam que a métrica de coeficiente de dados (*Dice*) é amplamente utilizada para segmentação binária por conta da sua robustez ao desequilíbrio de classes. Esta métrica possibilita, ainda, o uso para treinar redes neurais convolucionais.

Junkuszew e Ringdorfer (2005), afirmam que tanto as imagens segmentadas pelo profissional e as segmentadas pelo algoritmo são fundamentais para a previsão da composição corporal de cordeiros. Estes autores também relatam que a ultrassonografia é uma ferramenta útil para predizer a composição corporal de cordeiros em rebanhos, podendo ser utilizada como instrumento nos programas de melhoramento genético animal.

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

Figura 4: Segmentação das imagens ultrassonográficas feitas pelo algoritmo U-Net e pelo profissional.



Observa uma grande similaridade entre as imagens segmentadas pelo algoritmo de aprendizagem não-supervisionada e as imagens segmentadas pelo especialista (Figura 4), o que torna a metodologia eficiente e capaz de predizer a área de olho de lombo dos animais em estudo. Ronnenberg et al. (2015) relata que o algoritmo em

questão mostra um desempenho muito bom em programas de segmentação de imagens ultrassonográficas.

Laheras et al. (2020) em um conjunto em torno de 100 imagens, observaram-se uma precisão em torno de 95% demonstrando resultados promissores. De acordo com Gonzalez e Wintz (1987), a segmentação é uma etapa muito importante no processamento digital de imagens, já que, é através deste processo regiões de interesse são extraídos de uma imagem para posteriores processamentos, como a obtenção de características e, conseqüentemente, o reconhecimento da imagem. Saldanha e Freitas (2009), afirmam que a segmentação de imagens é de fundamental importância para a etapa de análise, já que, através desta fase é possível se extrair informações importantes a partir de imagens digitais.

Haykin (1999), afirma que as redes neurais são capazes de armazenar o conhecimento baseado em aprendizagem (experiência) e, assim, disponibilizar essa informação para posteriores análises. Já Tarallo (2007) afirma que as redes neurais artificiais têm sido aplicadas em processamento de imagens médicas, com comprovada eficiência e adaptabilidade aos dados.

3.2. RESULTADOS DA ANÁLISE ESTATÍSTICA

A seguir são apresentados os resultados obtidos com os regressores *AdaBoostRegressor* e *RandomForestRegressor*. Os resultados foram divididos em experimentos com os atributos extraídos das segmentações feitas, manualmente, com o algoritmo U-Net e foram representados na Tabela 2.

Tabela 3: Resultados obtidos com a regressão usando Regressor *AdaBoost* e Regressor *Random Forest* e imagens obtidas por segmentação usando U-Net.

	<i>AdaBooster</i>			<i>Random Forest</i>		
	QMR	EMA	R ²	QMR	EMA	R ²
VALOR	2,61	1,22	0,48	2,15	1,12	0,56

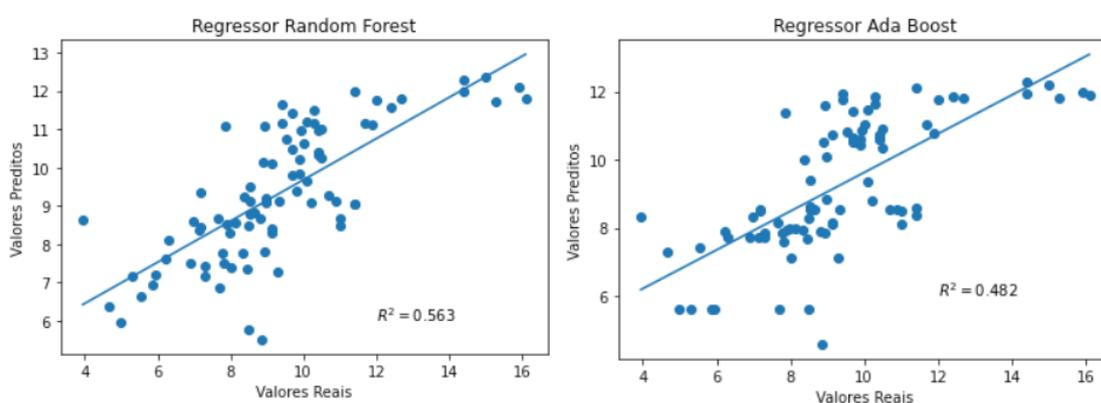
QMR: Quadrado Médio do Resíduo; EMA: Erro Médio Absoluto; R²: Coeficiente de determinação da variância.

De acordo com a Tabela 2, o regressor *Random Forest* apresentou QMR e EMA menores e R² indicando melhor qualidade de ajuste aos dados, comparado aos resultados obtidos pelo regressor *Adabooster*. Innani et al. (2016), utilizando ambos os regressores fazendo uso do *Machine Learning* para estudar energia solar, também

encontrou valores de QMR no *Random Forest* superiores aos do QMR do *Adabooster*, destacando mais ainda os resultados mais promissores do *Random Forest*.

Na Figura 5 estão representados os gráficos das análises de regressão realizada a partir dos resultados obtidos com os dois regressores mencionados anteriormente. Observa-se que os valores preditos pela metodologia proposta aproximam muito dos valores reais, representando no gráfico uma correlação positiva entre os valores de AOL preditos e a AOL reais, demonstrando que o algoritmo é eficiente em prever a AOL em ovinos.

Figura 5: Equação de regressão e dispersão dos dados das áreas de olho de lombo reais e preditas



Os valores dos coeficientes de determinação das equações de regressão encontrados com os regressores *RandomForest* e *AdaBooster* para a AOL foram de, respectivamente, 0,56 e 0,48, valores semelhantes aos encontrados por Pinheiro et al. (2010), o que segundo esses autores esses valores são considerados médios, indicando um bom ajustamento da equação aos dados. McManus et al. (2013) afirmam que valores de R^2 entre 0,4 e 0,6 (correlação positiva) são considerados bons para prever a AOL dos animais em estudo.

Polizel Neto et al. (2009), ao estudarem correlações entre medidas de carcaça de bovinos, encontraram correlações baixas, em torno de 0,4 ocasionadas pela não padronização nas coletas, ou seja, as medidas não foram tomadas pelo mesmo especialista, o que destaca a importância deste processo durante a mensuração de medidas ultrassonográficas. Quando dois ou mais técnicos realizam o mesmo procedimento, poderá aumentar o erro diminuindo a acurácia da predição. Sendo assim, torna-se importante ocorrer uma padronização de atribuições durante a coleta, 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.

Na tabela 4, está representada a estatística descritiva das médias de Área de Olho de Lombo predita (AOL predita) e observada (AOL observada) mensuradas em Ovinos, que foram submetidas a comparação de médias pelo teste “t” de *student*.

Tabela 4: Estatística descritiva das médias de Área de Olho de Lombo predita e observada mensuradas em Ovinos

Característica estudada	μ	CV	EPM	A	σ^2	Intervalo de confiança para a média a 95% de probabilidade	
						Limite inferior	Limite superior
						AOL observado	9,29a
AOL predito	9,31a	16,78	0,20	6,97	2,44	8,92	9,72

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

As médias de AOL observada e AOL predita foram muito semelhantes e não apresentaram diferença significativas ($p < 0,05$) pelo teste t de *student*, o que enfatiza a eficiência da ferramenta já que as médias foram muito próximas. Fica evidente a contribuição que essa proposta pode trazer para a fenotipagem em larga escala da avaliação de carcaça em ovinos de corte.

Observou-se que o CV para AOL predita foi menor do que obtido para a AOL real, o que indica menor dispersão nos dados nos resultados encontrados pela ferramenta proposta. O CV para AOL predita foi baixo comparado aos resultados obtidos por Taveira et al. (2016) ao avaliar a carcaça de bovinos por ultrassonografia. Verificou-se ainda que o erro padrão da média (EPM), a amplitude (A) e o intervalo de confiança (IC) foram menores para a AOL predita, o que se deve a padronização que o método proposto imprime aos dados coletados, ficando evidente assim o sucesso da ferramenta.

Como o EPM foi menor no predito do que no observado, a confiabilidade na média predita é maior do que na observada, destacando a importância da utilização da ferramenta tecnológica. Observou-se ainda que a variância para AOL predita foi menor

do que a observada, o que enfatiza 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 AOL predita (Tabela 4) fica evidente, mais uma vez, a maior confiabilidade da estimativa para AOL predita pelo algoritmo, o que mais uma vez evidencia que a ferramenta tecnológica desenvolvida foi eficiente para prever a AOL.

Apesar da diferença na variabilidade das medidas tomadas, as médias calculadas foram muito próximas, não se observando diferença significativa ($P > 0,05$) entre elas, o que evidencia a acurácia e predição para a medida determinada pelo algoritmo proposto, visto que se aproxima bastante da mensuração feita pelo especialista, com menor variação.

Sena (2019), encontrou resultados semelhantes, em seu trabalho, mensurando características de carcaça em ovinos Santa Inês, o qual a média de AOL encontrada foi de 8,99 cm² e o CV obtido foi de 34,58, o que enfatiza mais ainda o sucesso da pesquisa desenvolvida neste trabalho.

Segundo Sugisawa (2002), a área de olho de lombo está diretamente relacionada ao rendimento de cortes da carne, sendo esta medida capaz de inferir sobre a quantidade e qualidade da carcaça, o que justifica o fato de a AOL ser mais testada e mais aceita. Gonzaga Neto et al. (2006) afirmam que a área de olho de lombo é uma medida que tem relação com a quantidade de carne comercializável, o que justifica investimento em tecnologias que podem auxiliar os produtores e programas de melhoramento genético de ovinos no Brasil.

Prado et al. (2004), afirmam em sua pesquisa que o estudo da área de olho de lombo (AOL) por meio da ultrassonografia, proporcionou um grau de confiabilidade de 80% em comparação com a avaliação de carcaça em bovinos de corte, mostrando ser uma metodologia viável para a predição deste parâmetro no animal ainda vivo. Diante do exposto, fica evidenciada a importância de utilização da ferramenta na seleção dos animais

Já McManus et al. (2013) ao avaliar a qualidade de carcaça em ovinos Santa Inês, afirmam que em programas de melhoramento genético que tenham como objetivo avaliar a característica de área de olho de lombo, pode utilizar esta medida como critérios de seleção, visto que esta mensuração é realizada de maneira facilitada e mais barata e com maior número de animais sem ser necessário abater o animal.

Damy et al. (2010), ao estudar os procedimentos fundamentais da experimentação, afirmam que procedimentos padronizados para determinar as respostas e os objetivos bem definidos permitem aceitar ou rejeitar a hipótese inicial mesmo com o número de animais reduzidos, o que evidencia a importância da padronização utilizada durante a pesquisa.

É importante salientar que além de comprovar a precisão obtida com a padronização durante a coleta, esta pesquisa também contribuiu para a fenotipagem dos ovinos de ovinos em larga escala, 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 permite um monitoramento maior dos indivíduos facilitando na seleção dos animais. Grattapaglia (2004), em discussão sobre o teste de DNA para a maciez da carne, afirmou que a fenotipagem e o melhoramento genético animal são combinados com o intuito de produzir estimativas mais acuradas, aonde são tomadas as decisões de seleções.

4. CONCLUSÕES

Através das ferramentas da visão computacional, como o algoritmo de redes neurais convolucionais (U-Net) é possível prever a área de olho de lombo do músculo *Longissimus dorsi* com acurácia e rapidez, para ter-se uma previsão sobre o rendimento da carcaça.

A ferramenta tecnológica (U-Net) mostrou-se bastante eficiente com elevada confiabilidade, podendo ser utilizada com segurança otimizando, assim, o tempo da avaliação do animal.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- ALBATINEH, A.N., NIEWIADOMSKA-BUGAJ, M., 2011. Correcting Jaccard and other similarity indices for chance agreement in cluster analysis. **Advances in Data Analysis and Classification**, 5, 179–200. <https://doi.org/10.1007/s11634-011-0090-y>.
- ARDHIANTO, E., BUDIARSO, W. H. Z., 2013. Implementasi Metode Image Subtracting dan Metode Regionprops untuk Mendeteksi Jumlah Objek Berwarna RGB pada File Video. **Jurnal Teknologi Informasi DINAMIK**, 18, 91-100. <https://www.unisbank.ac.id/ojs/index.php/fti1/article/view/1697/612>.

- BERGEN, R. D., McKINNON, J. J.; CHRISTENSEN, D. A. et al., 1996, Prediction of lean yield in yearling bulls using real-time ultra-sound. **Canadian Journal of Animal Science**, v.76, p.305-311, <https://doi.org/10.4141/cjas96-046>.
- BERTELS, J., EELBODE, T., BERMAN, M., VANDERMEULEN, D., MAES, F., BISSCHOPS, R., BLASCHKO, M. B., 2019. Optimizing the Dice Score and Jaccard Index for Medical Image Segmentation: Theory and Practice. In: Shen D. et al. (eds) **Medical Image Computing and Computer Assisted Intervention – MICCAI**, 11765, 92-100. https://doi.org/10.1007/978-3-030-32245-8_11
- BREIMAN, L., 1996. Bagging predictors. **Mach Learn**, 24, 123–140. <https://doi.org/10.1007/BF00058655>.
- CAO, Y., MIAO, Q. G., LIU, J. C., GAO, L., 2013. Advance and Prospects of AdaBoost Algorithm. **Acta Automatica Sinica**, 39, 745-758. [https://doi.org/10.1016/S1874-1029\(13\)60052-X](https://doi.org/10.1016/S1874-1029(13)60052-X).
- DAMY, S. B., CAMARGO, R. S., CHAMMAS, R., FIGUEIREDO, L. F. P., 2010. Aspectos fundamentais da experimentação animal - aplicações em cirurgia experimental. **Revista da Associação Médica Brasileira**, 56, 103-111. <https://doi.org/10.1590/S0104-42302010000100024>.
- DICE, L. R., 1945. Measures of the Amount of Ecologic Association Between Species. **Ecology**, 26, 297-302. doi:10.2307/1932409.
- EELBODE, T., BERTELS, J., BERMAN, M., 2020. Optimization for Medical Image Segmentation: Theory and Practice When Evaluating With Dice Score or Jaccard. **IEEE Transactions on Medical Imaging**, 39, 3679-3690. doi: 10.1109/TMI.2020.3002417.
- FIDON, L., LI, W., HERRERA, L. C. G. P., EKANAYAKE, J., KITCHEN, N., OURSELIN, S., VERCAUTEREN, T., 2017. Generalised Wasserstein Dice Score for Imbalanced Multi-class Segmentation Using Holistic Convolutional Networks. **Lecture Notes in Computer Science**, 10670. 64-76. https://doi.org/10.1007/978-3-319-75238-9_6.
- GONZALEZ, R. C., WINTZ, P. Digital image processing, 2 ed. 1987. 503p.
- GRATTAPAGLIA, D. Testes de DNA para maciez da carne. Palestra, In: IV Simpósio Nacional das Raças Simental e Simbrasil, 2004. São Paulo-SP.
- HAYKIN, S. Neural networks: A comprehensive foundation. 2 ed. Upper Saddle River: Prentice-Hall, 1999. 842 p.

- INNANI, A., TRIPATHI, Y., DHATWALIA, S. JAMBHULKAR, V., 2016. Solar Power Predictor Using Ensemble Learning. **International Journal of Innovative Science and Research Technology**, 10. 2016. https://ijisrt.com/assets/upload/submitted_files/1585702709.pdf.
- KRAMER, O., 2016. Scikit-Learn. In: Machine Learning for Evolution Strategies. **Studies in Big Data**, 20. https://doi.org/10.1007/978-3-319-33383-0_5.
- LAHERAS, L. P. RODRIGUES, P. S. S. GIRALDI, G. A. Algoritmos Bio-Inspirados e Redes Neurais Aplicados à Segmentação de Imagens Médicas. X Simpósio de Iniciação Científica, Didática e de Ações Sociais da FEI. **Anais**. São Bernardo do Campo. 2020.
- MCMANUS, C., PAIM, T. P., LOUVANDINI, H., DALLAGO, B., DIAS, L. T., TEIXEIRA, R. A., 2013. Avaliação ultrasonográfica da qualidade de carcaça de ovinos Santa Inês. **Ciência Animal Brasileira**, 14, 8-16. <http://dx.doi.org/10.5216/cab.v14i1.12336>.
- MÜLLER, L. Qualidade da carne – tipificação de carcaças bovinas e ovinas. In: Simpósio Reunião Anual Da Sociedade Brasileira De Zootecnia, 30, 53-69. Rio de Janeiro. **Anais**. Viçosa: SBZ, 1993.
- PINHEIRO, R. S. B., JORGE, A. M. YOKOO, M. J., 2010. Correlações entre medidas determinadas in vivo por ultrassom e na carcaça de ovelhas de descarte. **Revista Brasileira de Zootecnia**, 39, 1161-1167. <https://doi.org/10.1590/S1516-35982010000500030>.
- POLIZEL NETO, A., JORGE, A. M., MOREIRA, P. S. A., GOMES, H. F. B., PINHEIRO, R. S. B., ANDRADE, E. N., 2009. Correlações entre medidas ultrassônicas e na carcaça de bovinos terminados em pastagem. **Revista Brasileira de Saúde e Produção Animal**, 10, 137-145. <https://periodicos.ufba.br/index.php/rbspa/article/view/39749>.
- PRADO, C. S., PÁDUA, J. T., CORRÊA, M. P. C., FERRAZ, J. B. S., MIYAGI, E. S., RESENDE, L. S., 2004. Comparação de diferentes métodos de avaliação da área de olho de lombo e cobertura de gordura em bovinos de corte. **Revista Ciência Animal Brasileira**, 5, 141-149. <https://www.revistas.ufg.br/vet/article/view/26837>.
- QUININO RC, REIS EA, BESSEGATO LF. O coeficiente de determinação R2 como instrumento didático para avaliar a utilidade de um modelo de regressão linear múltipla. Belo Horizonte: UFMG; 1991. http://www.est.ufmg.br/portal/arquivos/rts/PD_28102011_Final.pdf.

- RIPOLL, G., JOY, M., SANZ, A., 2010. Estimation of carcass composition by ultrasound measurements in 4 anatomical locations of 3 commercial categories of lamb. **Journal of Animal Science**, 88, 3409-3418. 10.2527/jas.2009-2632.
- RONNEBERGER, O., FISHER, P., BROX, T., 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. **Medical Image Computing and Computer-Assisted Intervention (MICCAI)**, 9351, 234-241. arXiv:1505.04597.
- RUSSELL, B.C., TORRALBA, A., MURPHY, K.P. et al., 2008. LabelMe: A Database and Web-Based Tool for Image Annotation. **International Journal of Computer Vision**, 77, 157–173. <https://doi.org/10.1007/s11263-007-0090-8>.
- SALDANHA, M. F., FREITAS, C. Segmentação de imagens digitais: Uma revisão. **Divisão de Processamento de Imagens-Instituto Nacional de Pesquisas Espaciais (INPE)**, São Paulo, 2009.
- SANTOS, C. L., PÉREZ, J. R. O., MUNIZ, J. A., GERASEEV, L. C., SIQUEIRA, E. R., 2001. Desenvolvimento relativo dos tecidos ósseo, muscular e adiposo dos cortes da carcaça de cordeiros Santa Inês. **Revista Brasileira de Zootecnia**, 30, 487-492. <https://doi.org/10.1590/S1516-35982001000200027>.
- SENA, L. S. Estudo Genômico aplicado ao melhoramento genético de ovinos Santa Inês para características de carcaça. 2019. 125f. Tese (Doutorado) – Curso de Ciência Animal, Universidade Federal do Piauí, Teresina (PI), 2019.
- SILVA, S. R., GOMES, M. J., DIAS, A. S., GIL, L. F., AZEVEDO, J. T., 2005. Estimation *in vivo* of the body and carcass chemical composition of growing lambs by real-time ultrasonography. **Journal of Animal Science**, 83, 350-357. 10.2527/2005.832350x.
- SORENSEN, T., 1948. A method of establishing rroups of equal amplitude in plant sociology based on similarity of species and its application to analyses of the vegetation on Danish commons. **Kongelige Danske Videnskabernes Selskab**, 5, 1-34. https://www.royalacademy.dk/Publications/High/295_S%C3%B8rensen,%20Thorvald.pdf.
- SUGUISAWA, L., MATTOS, W. R. S., SOUZA, A. A., SILVEIRA, A. C., OLIVEIRA, H. N. ARRIGONI, M. B., BURINI, D. C. M., 2006. Ultra-sonografia para predição da composição da carcaça de bovinos jovens. **Revista Brasileira de Zootecnia**, 35, 177-185. <http://dx.doi.org/10.1590/s1516-35982006000100023>.

SUGUISAWA, L. Ultra-sonografia para predição das características de carcaça e composição da carcaça de bovinos. 2002. 70f. Dissertação (Mestrado) – Curso de Agronomia, Universidade de São Paulo, Piracicaba (SP), 2002.

TARALLO, A. S. Segmentação e classificação de imagens digitais de úlceras cutâneas através de redes neurais artificiais. 2007. 138 f. Dissertação (Mestrado) – Curso de Engenharia Elétrica, Universidade de São Paulo, São Carlos (SP), 2007.

TAVEIRA, R. Z., ALMEIDA, O. C., SILVEIRA, O. J., et al., 2016. Avaliação de carcaça de bovinos da raça Tabapuã com ultrassonografia. **Pubvet**, 10, 100-104. DOI: 10.22256/pubvet.v10n1.100-104.

6. CONSIDERAÇÕES FINAIS

Para trabalhos futuros, pretende-se realizar o aperfeiçoamento da ferramenta computacional para a mensuração automatizada de outras características da carcaça de importância econômica, o qual se pretende disponibilizar essa tecnologia para o uso pelos produtores de ovinos e pela comunidade científica contribuindo, assim, com a genética e o melhoramento genético animal. Desta forma, os pesquisadores poderão ter uma ferramenta para auxiliar no processo de fenotipagem dos animais em estudo contribuindo, consideravelmente, para a pesquisa, pois assim terá-se disponível um maior número de informações sobre os animais. Com esta pesquisa, o produtor terá uma previsão mais acurada de quais animais terão maior quantidade de carne, e assim ele poderá aumentar a produtividade dentro da propriedade.