

Tiago de Moura Oliveira  
Orientador: Romuere Rodrigues Veloso e Silva

**Segmentação do Músculo *Longissimus Dorsi* e  
Predição da Área do Olho de Lombo em  
imagens de ultrassonografia de Pequenos  
Ruminantes**

Picos - PI  
6 de novembro de 2021

Tiago de Moura Oliveira  
Orientador: Romuere Rodrigues Veloso e Silva

**Segmentação do Músculo *Longissimus Dorsi* e Predição da Área do Olho de Lombo em imagens de ultrassonografia de Pequenos Ruminantes**

Monografia submetida ao Curso de Bacharelado em Sistemas de Informação como requisito parcial para obtenção de grau de Bacharel em Sistemas de Informação. Orientador: Prof. Dr. Romuere Rodrigues Veloso e Silva.

Universidade Federal do Piauí  
Campus Senador Helvídio Nunes de Barros  
Bacharelado em Sistemas de Informação

Picos - PI  
6 de novembro de 2021

**FICHA CATALOGRÁFICA**  
**Universidade Federal do Piauí**  
**Campus Senador Helvídio Nunes de Barros**  
**Biblioteca Setorial José Albano de Macêdo**  
**Serviço de Processamento Técnico**

**O48s** Oliveira, Tiago de Moura

Segmentação do músculo Longissimus dorsi e predição da área do olho de lombo em imagens de ultrassonografia de pequenos ruminantes / Tiago de Moura Oliveira – 2021.

Texto digitado

Indexado no catálogo *online* da biblioteca José Albano de Macêdo-  
CSHNB

Aberto a pesquisadores, com as restrições da biblioteca

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Piauí, Bacharelado em Sistemas de Informação, Picos-PI, 2021.

“Orientador: Dr. Romuere Rodrigues Veloso e Silva”

1. Ovinos. 2. Caprinos. 3. Carcaça. 4. Redes neurais convolucionais-Segmentação 5. Longissimus dorsi; 6. Imagens ultrassonográficas. 7. Pequenos ruminantes. I. Silva, Romuere Rodrigues Veloso e. II. Título

CDD 004



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DO PIAUÍ  
CAMPUS SENADOR HELVÍDIO NUNES DE BARROS  
Curso de Sistemas de Informação



ATA DE APRESENTAÇÃO DE MONOGRAFIA

Período: 2021.1

Livro: , Folha:

Instala-se nesta data, 22 de novembro de 2021, a Banca Avaliadora da Monografia apresentada pelo(a) Acadêmico(a) **Tiago de Moura Oliveira**, sob o tema: “**Segmentação do Músculo *Longissimus Dorsi* e Predição da Área do Olho de Lombo em imagens de ultrassonografia de Pequenos Ruminantes**”, orientado(a) por mim **Romuere Rodrigues Veloso e Silva**, composta pelos professores **Ana Caroline de Almeida Alves** e **Clésio de Araújo Gonçalves**, presidida por mim, **Romuere Rodrigues Veloso e Silva** nos termos do Regimento Interno do Curso de Sistemas de Informação e das normas pertinentes em vigor, como cumprimento do que estabelece a Matriz Curricular e o Projeto Pedagógico do Curso de Sistemas de Informação, devidamente aprovado pela UFPI. Para o que se estabelece:

- O Concluinte disporá de no mínimo 15 (quinze) minutos e no máximo 25 (vinte e cinco) minutos para a apresentação de sua produção, para o que se solicita a não interferência;
- Os componentes da Banca, encerrada a apresentação, disporão de até 25 (vinte e cinco) minutos para a arguição, para cada componente;
- Não será permitida nenhuma manifestação da parte da plenária, antes que seja declarada encerrada a sessão.

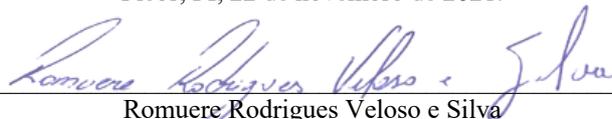
Declaramos aberta a sessão, oportunidade em que passamos a palavra ao concluinte para sua exposição, alertando-o para o tempo já anunciado.

---

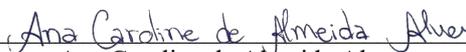
APÓS ANÁLISE, CONSIDERA O(A) CONCLUINTE TIAGO DE MOURA OLIVEIRA, COM CONCEITO/NOTA 9,0, (X) APROVADO ( ) APROVADO COM RESSALVA ( ) REPROVADO. CASO SEJA UMA DAS DUAS PRIMEIRAS OPÇÕES O CONCLUINTE FICA CONDICIONADO AO PLENO CUMPRIMENTO DAS PROPOSIÇÕES ANUNCIADAS PELA BANCA, NO PRAZO MÁXIMO DE 7 DIAS A CONTAR DESTA DATA, COMO TEMPO MÁXIMO PARA ENTREGA DA VERSÃO FINAL NA COORDENAÇÃO DO CURSO. O NÃO CUMPRIMENTO DAS PROPOSIÇÕES DA BANCA E DO PRAZO ACIMA ESTABELECIDO IMPLICARÁ EM REPROVAÇÃO.

Nada mais havendo a registrar encerro a presente sessão, da qual lavrou-se esta ATA que vai assinada por mim, pelos componentes desta Banca e pelo(a) Concluinte.

Picos, PI, 22 de novembro de 2021.



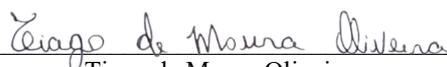
Romuere Rodrigues Veloso e Silva  
Presidente/Orientador(a)



Ana Caroline de Almeida Alves  
Membro/Avaliador(a)



Clésio de Araújo Gonçalves  
Membro/Avaliador(a)



Tiago de Moura Oliveira  
Concluinte

SEGMENTAÇÃO DO MÚSCULO *LONGISSIMUS DORSI* E PREDIÇÃO DA ÁREA DO OLHO DE LOMBO EM  
IMAGENS DE ULTRASSONOGRRAFIA DE PEQUENOS RUMINANTES

TIAGO DE MOURA OLIVEIRA

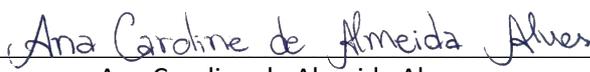
Monografia aprovada como exigência parcial para obtenção do grau de Bacharel em Sistemas  
de Informação.

Data de Aprovação

Picos – PI, 22 de novembro de 2021

  
\_\_\_\_\_

Prof. Romuere Rodrigues Veloso e Silva

  
\_\_\_\_\_

Ana Caroline de Almeida Alves

  
\_\_\_\_\_

Prof. Clésio de Araújo Gonçalves

# Agradecimentos

Agradeço primeiramente a Deus por conceder a realização deste trabalho. A Ele, toda a gratidão. A minha família, por ser a base de tudo. Amigos e em especial Isabelly Cristiny Martins Carvalho por estarem sempre comigo, incentivando e apoiando independente da situação. A meu orientador Romuere Rodrigues Veloso e Silva por me guiar e conceder a oportunidade desta pesquisa. Obrigado pela positividade, paciência e ensinamentos transmitidos e pelo grande exemplo de determinação oferecendo oportunidades de crescimento acadêmico. Aos meus professores da graduação, muito obrigado. Ao meu grupo de amigos que fiz na universidade, por desde o início da graduação fazerem parte disso, de forma direta ou indireta. Por fim, a todos que, acreditaram e contribuíram à realização deste objetivo.

*Só se pode alcançar um grande êxito quando nos mantemos fiéis a nós mesmos.*  
*Friedrich Nietzsche*

# Resumo

O Brasil é um dos principais países que atuam no setor do agronegócio. A ovino-caprinocultura é um dos segmentos do agronegócio brasileiro. A avaliação de cada carcaça de caprinos e ovinos é realizada por um especialista que as avalia com base nos aspectos visuais, estando suscetíveis a erros na avaliação final. Nesse contexto, o objetivo deste trabalho é utilizar Redes Neurais Convolucionais para segmentar a área do músculo *Longissimus dorsi* em imagens ultrassonográficas de pequenos ruminantes e prever os valores da AOL utilizando diferentes regressores. Nossos experimentos mostraram que a arquitetura PSPNet obteve os melhores resultados, apresentando uma taxa de IoU de 0,89, na etapa de predição o *Random Forest Regressor* destacou-se com um coeficiente  $r^2$  de 0,77. Assim, foi possível obter uma segmentação precisa das imagens, o que permitirá ao produtor diagnosticar corretamente as medidas dos animais com maior praticidade e economia de tempo.

**Palavras-chaves:** Ovinos; Caprinos; Carcaça; Redes neurais convolucionais; Segmentação; *Longissimus dorsi*; Imagens ultrassonográficas; Pequenos ruminantes.

# Abstract

Brazil is one of the main countries operating in the agribusiness sector. Sheep and goat farming is one of the segments of Brazilian agribusiness. The evaluation of each carcass of goats and sheep is carried out by a specialist who evaluates them based on visual aspects, being susceptible to errors in the final evaluation. In this context, the objective of this work is to use Convolutional Neural Networks to segment the *Longissimus dorsi* muscle area in ultrasonographic images of small ruminants and to predict the AOL values using different regressors. Our experiments showed that the PSPNet architecture obtained the best results, presenting an IoU rate of 0.89, the *Random Forest Regressor* stood out in the prediction stage with a coefficient  $r^2$  of 0.77. Thus, it was possible to obtain a precise segmentation of the images, which will allow the producer to correctly diagnose the measurements of the animals with greater practicality and saving time.

# Lista de ilustrações

|   |    |
|---|----|
| Figura 1 – Arquitetura U-Net. Fonte: (RONNEBERGER; FISCHER; BROX, 2015)   | 16 |
| Figura 2 – Arquitetura FPN. Fonte: (LIN et al., 2017)   | 17 |
| Figura 3 – Arquitetura LinkNet. Fonte: (CHAURASIA; CULURCIELLO, 2017)   | 18 |
| Figura 4 – Arquitetura LinkNet. Fonte: (ZHAO et al., 2017)  | 19 |
| Figura 5 – Estrutura de uma Random Forest. Fonte: (CUTLER; CUTLER; STEVENS, 2012).  | 20 |
| Figura 6 – Estrutura de um <i>Decision Tree Regressor</i> . Fonte: (XU et al., 2005).   | 20 |
| Figura 7 – Metodologia proposta. (a) Aquisição da base de dados. (b) Pré-processamento das imagens. (c) Aplicação de diferentes arquiteturas CNN pré-treinadas. (d) Extração de características. (e) Aplicação de regressores para predição da AOL. | 25 |
| Figura 8 – Exemplos de imagens do banco de dados. Em (a) e (c) estão imagens de ultrassonografia, e em (b) e (d) suas respectivas regiões do músculo <i>Longissimus dorsi</i> marcadas pelo especialista da área.                                   | 26 |
| Figura 9 – Aprendizado da arquitetura PSPNet com base da métrica F1-Score.  | 31 |
| Figura 10 – Resultado da segmentação do método proposto na imagem com maior valor de F1-Score (Da esquerda para direita, imagem pré-processada, a segmentação do especialista e a segmentação com o modelo proposto).                               | 31 |
| Figura 11 – Resultado da segmentação do método proposto na imagem com menor valor de F1-Score (Da esquerda para direita, imagem pré-processada, a segmentação do especialista e a segmentação com o modelo proposto).                               | 31 |
| Figura 12 – Resultado da predição utilizando <i>Random Forest Regressor</i> . Em (a) é representado a predição na mascara do especialista, e em (b) é representado a predição na mascara do gerada pela segmentação da PSPNet.                      | 32 |
| Figura 13 – Resultado da predição utilizando <i>Decision Tree Regressor</i> . Em (a) é representado a predição na mascara do especialista, e em (b) é representado a predição na mascara do gerada pela segmentação da PSPNet.                      | 33 |
| Figura 14 – Resultado da predição utilizando <i>Support Vector Regression (SVR)</i> . Em (a) é representado a predição na mascara do especialista, e em (b) é representado a predição na mascara do gerada pela segmentação da PSPNet.              | 33 |

# Lista de tabelas

|   |    |
|---|----|
| Tabela 1 – Parâmetros utilizados no treinamento do modelo de segmentação proposto. . . . .  | 27 |
| Tabela 2 – Resultados obtidos pela metodologia proposta para cada modelo. . . .             | 30 |
| Tabela 3 – Resultados das métricas nas mascaras geradas pela segmentação da PSPNet. . . . . | 34 |
| Tabela 4 – Resultados das métricas nas máscaras do especialista. . . . .                    | 34 |

# Lista de abreviaturas e siglas

|      |                                 |
|------|---------------------------------|
| CNN  | Rede neural convolucional       |
| AOL  | Área de olho de lombo           |
| EGS  | Espessura de gordura subcutânea |
| IoU  | Intersecção sobre União         |
| COL  | Comprimento de olho de lombo    |
| POL  | Profundidade de olho de lombo   |
| ReLU | Unidade linear retificada       |
| MDI  | Diminuição média da impureza    |

# Sumário

|          |   |           |
|----------|---|-----------|
| <b>1</b> | <b>Introdução</b>                                     | <b>13</b> |
| 1.1      | Objetivos   | 14        |
| 1.2      | Contribuição  | 14        |
| 1.3      | Organização do Trabalho                               | 14        |
| <b>2</b> | <b>Referencial Teórico</b>                            | <b>15</b> |
| 2.1      | CNN   | 15        |
| 2.1.1    | Arquiteturas CNNs                                     | 15        |
| 2.1.2    | U-Net   | 16        |
| 2.1.3    | Feature Pyramid Networks - FPN                        | 17        |
| 2.1.4    | LinkNet   | 17        |
| 2.1.5    | PSPNet  | 17        |
| 2.2      | Atributos de forma                                    | 18        |
| 2.3      | Seleção de Atributos                                  | 19        |
| 2.4      | Regressão Linear                                      | 19        |
| 2.4.1    | Random Forest Regressor                               | 19        |
| 2.4.2    | Decision Tree Regressor                               | 20        |
| 2.4.3    | Support Vector Regression (SVR)                       | 21        |
| <b>3</b> | <b>Trabalhos Relacionados</b>                         | <b>22</b> |
| <b>4</b> | <b>Metodologia Proposta</b>                           | <b>25</b> |
| 4.1      | Aquisição de Imagens                                  | 25        |
| 4.2      | Pré-processamento de Imagens                          | 26        |
| 4.3      | Definindo o Modelo de CNN para Segmentação de Imagens | 26        |
| 4.4      | Extração de características                           | 27        |
| 4.5      | Regressão Linear                                      | 27        |
| 4.6      | Métricas de avaliação                                 | 28        |
| 4.6.1    | Métricas de Segmentação                               | 28        |
| 4.6.2    | Métricas de Regressão                                 | 28        |
| <b>5</b> | <b>Resultados e Discussões</b>                        | <b>30</b> |
| 5.1      | Segmentação do Músculo <i>Longissimus dorsi</i>       | 30        |
| 5.2      | Predição da Área de olho de lombo                     | 32        |
| <b>6</b> | <b>Conclusões e trabalhos futuros</b>                 | <b>35</b> |

|                                |           |
|--------------------------------|-----------|
| <b>7 Publicações</b> . . . . . | <b>36</b> |
| <b>Referências</b> . . . . .   | <b>37</b> |

# 1 Introdução

A ovinocaprinocultura, refere-se à criação de ovinos e caprinos com a finalidade de produção de carne, lã, couro, leite e outros derivados. No Brasil é uma atividade que encontra-se em constante crescimento. O atual quadro consta 18.948.934 ovinos e 10.696.664 caprinos, destacando a parte nordeste do país que detém 93,93% e 66,67% dos rebanhos, respectivamente (IBGE, 2020).

No Brasil esta atividade demonstra um importante papel no contexto do agronegócio, especialmente por conta da geração de oportunidades de emprego, renda e fixação do homem no campo. No entanto, é ainda precário em alguns pontos como no nível de produtividade, de gerenciamento, e de articulação entre os diversos elos da cadeia produtiva da carne e pele, dificultando a sustentabilidade, a competitividade e a remuneração dos produtores (ROSANOVA, 2004).

A atividade de classificação das carcaças em ovinos e caprinos tem um impacto significativo no preço final dos produtos gerados pela indústria de produção animal. O preço e a qualidade da carne que será fornecida ao consumidor final depende de uma classificação realizada por um especialista. Essa classificação é uma atividade que é considerada longa, cansativa e trabalhosa que tem a finalidade de avaliar a qualidade da carcaça com base em uma inspeção visual de suas características externas. Com base nessas características e nos critérios padronizados, o especialista atribui à carcaça do animal uma classificação e nível de gordura específicos.

Utilizar arquiteturas de CNNs para segmentação de imagens que foram aplicadas há outras espécies como bovinos e suínos tornou-se algo primordial, como empregado na avaliação de carcaça de imagens ultrassonográficas. Inserir tais técnicas na criação de ovinos e caprinos é necessário para contribuir no atendimento do mercado consumidor em crescimento (NETO, 2010). Segundo (TOUROCO, 2020), o método de avaliação da carcaça em tempo real por ultrassonografia caracteriza-se por ser não invasivo e não deixa resíduos nocivos na carne, oferecendo meios objetivos de avaliar os animais vivos em relação a sua composição corporal.

Uma das principais regiões que podem ser analisadas e que são importantes para o mensuração da qualidade de carcaça é o músculo *Longissimus dorsi* (CARTAXO; SOUSA, 2008). Nessa região é possível mensurar diferentes características, as mais importantes são: a AOL (área do olho de lombo), utilizada como característica indicadora de qualidade; a EGS (espessura de gordura subcutânea), que indica o grau de acabamento da carcaça e se relaciona com a qualidade da carne por proteger a carcaça durante o processo de resfriamento.

Métodos tradicionais dependem de um especialista da área (médico veterinário ou zootecnista) para segmentar manualmente a região do músculo *Longissimus dorsi* na imagem

de ultrassom, e a partir disso as características de AOL e EGS podem ser mensuradas. Nesse contexto, o propósito deste trabalho é segmentar a área do músculo *Longissimus dorsi* em imagens ultrassonográficas de pequenos ruminantes utilizando técnicas de visão computacional, e, após isso, predizer a AOL do animal.

## 1.1 Objetivos

Segmentar o músculo *Longissimus dorsi* em imagens de carcaças de pequenos ruminantes utilizando arquiteturas de CNNs pré-treinadas, e predizer os valores da AOL com base na extração de características utilizando regressão linear.

Os objetivos específicos deste trabalho são:

1. Avaliar diferentes métodos de segmentação de imagens de ultrassom da carcaça de pequenos ruminantes;
2. Predizer os valores de AOL utilizando diferentes modelos de regressores.

## 1.2 Contribuição

O presente trabalho tem como principal contribuição fornecer uma metodologia que faz a análise automática de imagens de ultrassom em pequenos ruminantes utilizando arquiteturas de CNNs. Para calcular a AOL da região *Longissimus dorsi*, auxiliando de forma rápida e eficiente os criadores de caprinos ao avaliar a qualidade da carcaça e na tomada de decisão no preço final do produto.

## 1.3 Organização do Trabalho

No Capítulo 2 explanamos sobre os métodos, conceitos, arquiteturas CNN utilizados e modelos de regressores no trabalho. No Capítulo 3 é apresentado os principais trabalhos do estado da arte para comparação com o método proposto. No Capítulo 4, apresentamos o método proposto e as métricas selecionadas para a avaliação. No Capítulo 5 os resultados obtidos a partir da execução da metodologia proposta. Por fim, no Capítulo 6, apresentamos as conclusões e os trabalhos futuros.

## 2 Referencial Teórico

Para melhor compreensão do assunto a ser tratado neste trabalho, é necessário detalhar Redes Neurais Convolucionais (CNNs), Atributos de forma, Seleção de Atributos e Regressão linear.

### 2.1 CNN

Uma CNN é um tipo particular de rede neural de várias camadas projetada para reconhecer padrões visuais diretamente de imagens. Introduzida por [LeCun et al. \(1998\)](#), a arquitetura CNN facilita o processamento da percepção humana utilizando campos receptores locais. Diversos modelos de arquiteturas de redes neurais foram construídas para ajudar a resolver diferentes tipos de problemas de classificação. A classificação de imagens é um dos principais problemas da Visão Computacional, com uma grande variedade de aplicações práticas. O objetivo da arquitetura da CNN é dimensionar a imagem para um tipo que possa ser processado facilmente sem comprometer as características importantes para obter uma predição correta. Os modelos de CNNs funcionam passando a imagem de entrada para o conjunto de várias camadas, como camada de convolução, camada de pooling e camada totalmente conectada para se obter um resultado aceitável. Neste trabalho, as CNNs serão utilizadas para segmentação e extração de atributos de imagens.

#### 2.1.1 Arquiteturas CNNs

As CNNs possuem destaque em competições relacionadas à Visão Computacional e ao processamento de Imagens por apresentar um desempenho exemplar ([KHAN et al., 2020](#)). Algumas das áreas de aplicação da CNN incluem classificação e segmentação de imagens, detecção de objetos, processamento de vídeo, processamento de linguagem natural e reconhecimento de fala. A poderosa capacidade de aprendizado da CNN deve-se principalmente ao uso de vários estágios de extração de atributos que podem aprender automaticamente as representações dos dados.

Com base em uma busca na literatura sobre quais CNNs para segmentação de imagens eram mais utilizadas foi percebido a maior presença da U-Net, Feature Pyramid Networks (FPN), LinkNet e PSPNet, por conta disso selecionamos essas quatro diferentes arquiteturas de CNNs para serem aplicadas no seguinte trabalho, as subseções [2.1.2](#), [2.1.3](#), [2.1.4](#) e [2.1.5](#) fornecem mais detalhes sobre cada uma dessas arquiteturas.

### 2.1.2 U-Net

U-Net é uma rede neural convolucional desenvolvida para segmentação biomédica de imagens (RONNEBERGER; FISCHER; BROX, 2015). A arquitetura é baseada na rede totalmente convolucional (LONG; SHELHAMER; DARRELL, 2015) e sua estrutura foi modificada e estendida para funcionar com menos imagens de treinamento e produzir segmentações mais precisas.

A arquitetura da U-Net é dividida em duas partes, sendo um caminho de contração e um caminho de expansão. O caminho de contração consiste na aplicação repetida de duas convoluções 3x3, cada uma seguida por uma ReLU e uma operação de normalização. Para cada etapa de redução da resolução, é duplicado o número de canais de atributos. Cada etapa no caminho de expansão consiste em uma ampliação da amostragem do mapa de características seguido por uma convolução 2x2, que divide pela metade o número de canais de recursos. Na camada final, uma convolução 1x1 é usada para mapear os canais para o número desejado de classes. No total, a rede tem 23 camadas convolucionais (RONNEBERGER; FISCHER; BROX, 2015).

A figura 1 apresenta a arquitetura U-Net com um exemplo para uma imagem de 32x32 pixels de entrada. Cada caixa azul represente um mapa de características. O número de canais é indicado na parte superior da caixa. O tamanho x-y é fornecido na borda esquerda inferior da caixa. As caixas brancas representam mapas de características copiados.

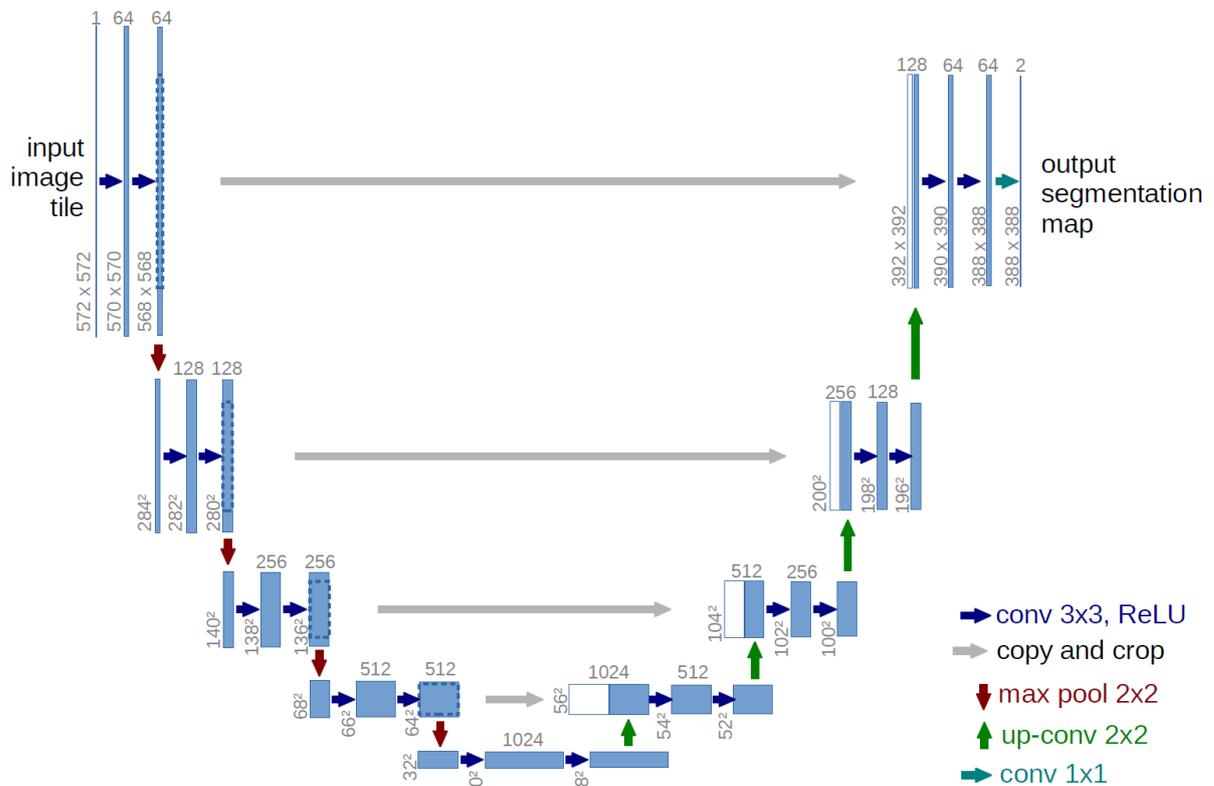


Figura 1 – Arquitetura U-Net. Fonte: (RONNEBERGER; FISCHER; BROX, 2015)

### 2.1.3 Feature Pyramid Networks - FPN

A FPN é uma rede neural convolucional que faz a extração de atributos de uma imagem em escala única e gera mapas de atributos de tamanho proporcional em vários níveis (LIN et al., 2017). A figura 2 apresenta a arquitetura FPN, uma arquitetura *Bottom-Up*: com conexões de salto, onde as previsões são feitas de forma ascendente, alavancando como uma pirâmide, com previsões feitas de forma independente em todos os níveis, *Top Down* o modelo tem uma estrutura semelhante, mas as previsões são feitas de forma descendente.

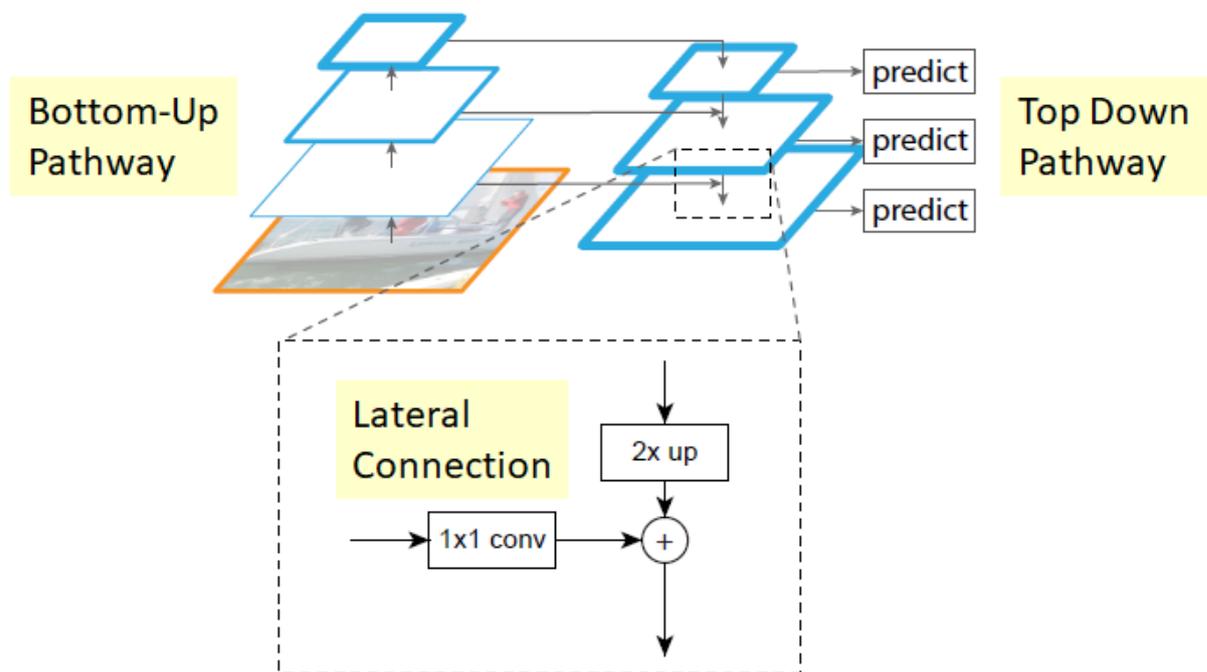


Figura 2 – Arquitetura FPN. Fonte: (LIN et al., 2017)

### 2.1.4 LinkNet

A LinkNet é uma rede neural convolucional projetada para realizar segmentação, que pode ser usada em diferentes contextos. Esta arquitetura foi projetada por membros do e-Lab da *Purdue University* (CHAURASIA; CULURCIELLO, 2017). A figura 3 apresenta a arquitetura em detalhes, que compartilha informações aprendidas pelo *encoder* com o *decoder* após cada bloco. Nesse caso, apresenta ser melhor do que a utilização de índices de agrupamento no *decoder* ou redes totalmente convolucionais no *decoder*.

### 2.1.5 PSPNet

A PSPNet é uma rede neural convolucional que explora a capacidade de informação de contexto global por agrupamento de cenários, baseada em diferentes regiões por meio do módulo de *pooling* de pirâmide. O módulo de *pooling* da pirâmide auxilia o modelo a

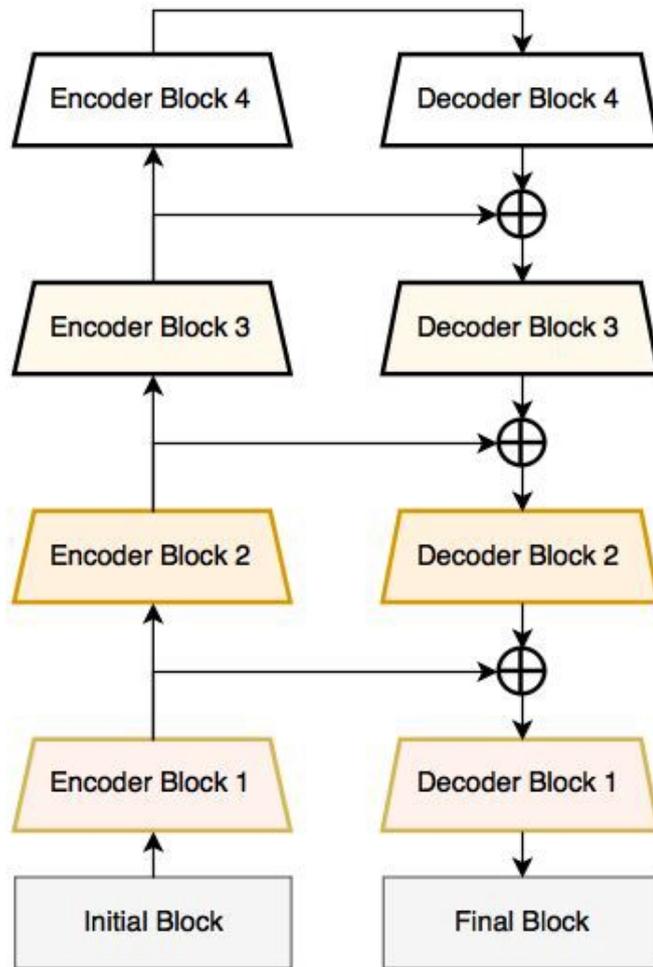


Figura 3 – Arquitetura LinkNet. Fonte: (CHAURASIA; CULURCIELLO, 2017)

capturar o quadro global, o que implica na classificação dos pixels com base na informação global existente (ZHAO et al., 2017).

A figura 4 apresenta a arquitetura da PSPNet, onde dada uma imagem de entrada é usado a CNN para obter o mapa de características da última camada convolucional, seguido de um módulo de análise de pirâmide para a coleta de diferentes representações, seguido por *upsampling* e camadas de concatenação formando a representação de atributo final, que carrega informações de contexto local e global. Por fim, a representação é alimentada em uma camada de convolução para obter a previsão final.

## 2.2 Atributos de forma

No processamento de imagens, representar uma região consiste na especificação dos níveis de cinza e também na delimitação da fronteira com base no formato dos objetos (OLIVEIRA, 2005). Estabelecendo medidas como área, distância e perímetro diversos atributos podem ser formados (PRATT, 1991).

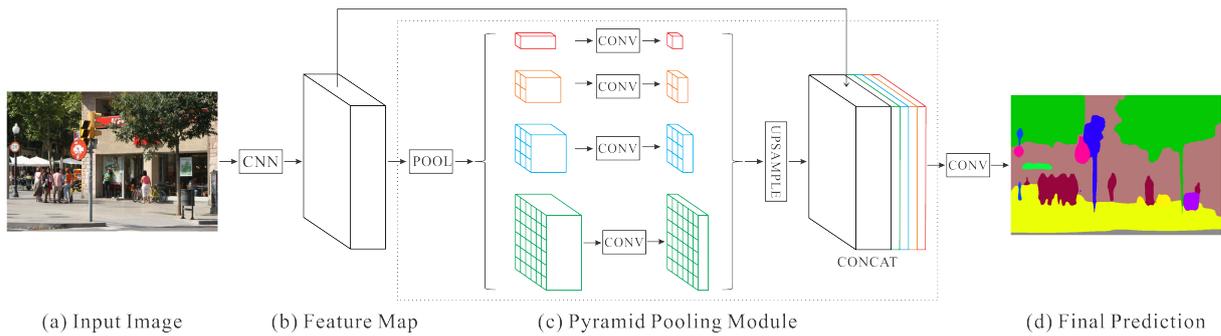


Figura 4 – Arquitetura LinkNet. Fonte: (ZHAO et al., 2017)

## 2.3 Seleção de Atributos

A seleção de atributos parte do pressuposto que os dados podem conter características que são redundantes ou irrelevantes, deste modo, a remoção desses atributos podem acontecer de forma que não ocorra o aumento de perdas de informações (KRATSIOS; HYNDMAN, 2021). Foi utilizado no seguinte trabalho dois algoritmos para calcular a importância dos atributos, sendo eles o algoritmo de importância das características usando diminuição média da impureza (MDI) e o algoritmo importância de atributos por permutação.

O algoritmo de importância das características usando MDI calcula como a média e o desvio padrão de associações da diminuição de impurezas em cada árvore (LI et al., 2019). Por outro lado, no cálculo do algoritmo de importância de atributos por permutação os atributos são embaralhados  $N$  vezes e o modelo é reajustado para avaliar sua relevância (BREIMAN, 2001).

## 2.4 Regressão Linear

A regressão linear (WU et al., 2019), é uma técnica utilizada para predição de valores que mostra resultados que envolvem relações entre uma variável e uma coleção de conjunto de dados.

### 2.4.1 Random Forest Regressor

O *Random Forest Regression* é um algoritmo de aprendizado supervisionado que ajusta árvores de decisão em diversas amostras do conjunto de dados e utiliza a média para aumentar a predição (CUTLER; CUTLER; STEVENS, 2012). A figura 5 apresenta a estrutura de uma *Random Forest*. Percebe-se que as árvores são executadas de formas isoladas sem nenhuma interação entre elas.

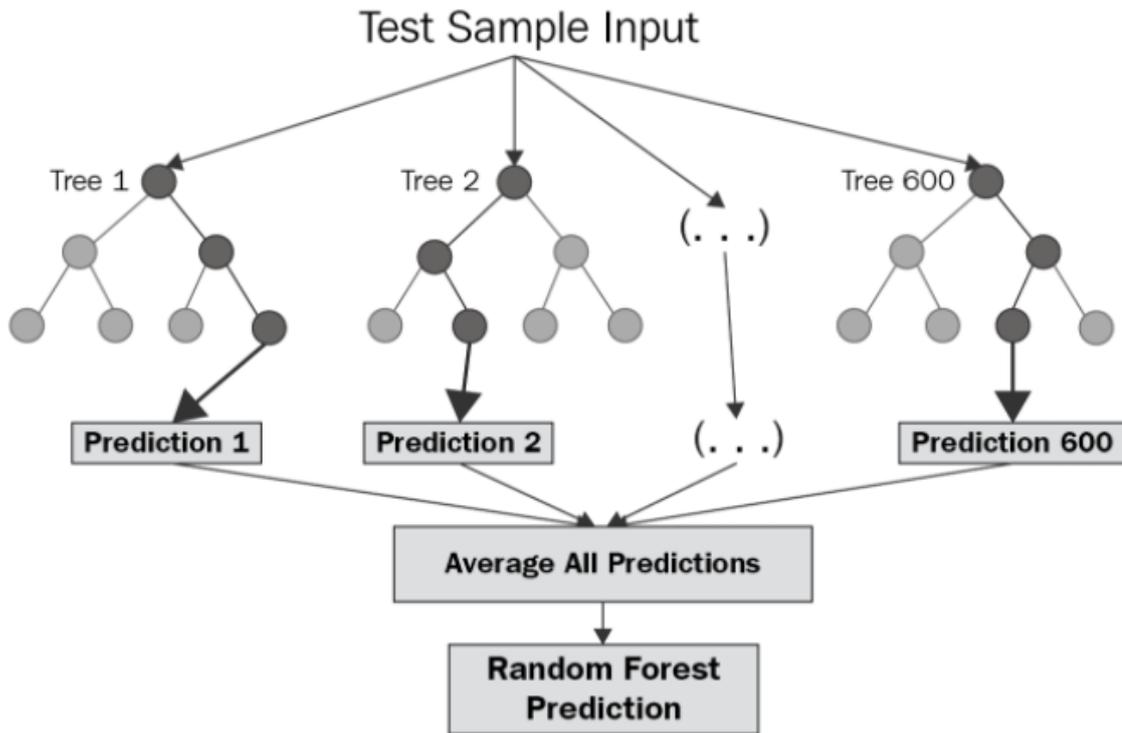


Figura 5 – Estrutura de uma Random Forest. Fonte: (CUTLER; CUTLER; STEVENS, 2012).

### 2.4.2 Decision Tree Regressor

O *Decision Tree Regressor* é um algoritmo de aprendizado supervisionado com o objetivo de criar um modelo que preveja o valor de uma variável alvo. Ele divide um conjunto de dados em subconjuntos, gerando uma árvore de decisão. O resultado final é uma árvore estruturada com nós de decisão e nós folhas (XU et al., 2005). A figura 6 apresenta a estrutura de um *Decision Tree Regressor* onde um nó de decisão pode ter dois ou mais ramos, cada nó retrata valores para o atributo testado.

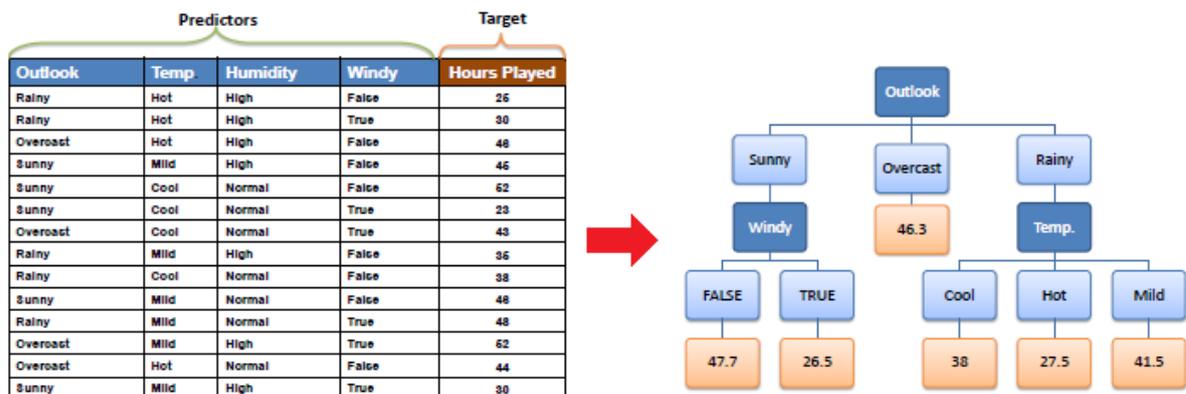


Figura 6 – Estrutura de um *Decision Tree Regressor*. Fonte: (XU et al., 2005).

### 2.4.3 Support Vector Regression (SVR)

O *SVR* é um algoritmo de aprendizado supervisionado que na etapa de treinamento utiliza uma função de perda, que pune de forma idêntica as estimativas erradas sejam elas valores altos ou baixos. Depende apenas de um subconjunto dos dados para treinamento, pois a função de custo ignora as amostras cujos valores de previsão estão próximos de seu alvo ([AWAD; KHANNA, 2015](#)).

### 3 Trabalhos Relacionados

No trabalho de (FURNOLS et al., 2014), foi feita previsões da composição e da gordura intramuscular (IMF) de seções que foram estimadas a partir de uma imagem transversal tirada no nível da 10<sup>a</sup> costela ao nível da 11<sup>a</sup> costela IMF ou de uma série de imagens transversais tiradas entre a 9<sup>a</sup> e 11<sup>a</sup> costelas com scanner de tomografia computadorizada (TC). As amostras de costelas foram escaneadas com equipamento de scanner CT HiSpeed Zx/i CT da General Electric na IRTA-CENTA em Monells (Girona, Espanha). Três varreduras foram feitas de cada seção de costela. Os dados foram divididos aleatoriamente em um conjunto de calibração (2/3 dos dados) e um conjunto de validação (1/3 dos dados). Os dados das imagens de calibração foram analisados por regressão linear. O trabalho mostra diferentes maneiras de estimar o conteúdo do IMF. A partir de uma imagem em corte transversal de 10 cm de espessura tirada no nível da 10<sup>a</sup> costela. O IMF também foi previsto a partir do histograma da Região de interesse do músculo Longissimus, que se relaciona mais de perto com a posição da qual a amostra foi retirada para a medição de referência do IMF. Nesse caso, a acurácia diminuiu significativamente e não foi bem validada com o conjunto de dados externo. Uma combinação de distribuições de volume de acordo com os valores de toda a imagem transversal e da região de interesse do músculo *L. thoracis* resultou em graus semelhantes de precisão em contraste com o uso de uma única imagem. O conteúdo do IMF foi estimado a partir de todas as imagens da seção de costela e a precisão resultante não melhorou. Nesse caso, o conjunto de validação produziu um grau de acurácia semelhante ao conjunto de resultados estatísticos.

(PEÑA et al., 2014), avalia a capacidade preditiva de imagens de ultrassom de touros em diferentes idades com base na composição do corte da costela 10<sup>a</sup>-12<sup>a</sup>. Aplicando múltiplos coeficientes de regressão em diferentes varreduras para a determinação de tecidos cortados da 10-12<sup>a</sup> costela de raças Charolês, Limousin e Retinta. As medições de ultrassom feitas em todas as raças forneceram baixa acurácia de predição para a composição do corte 10-12<sup>a</sup> costela = 0,12 e  $r^2 = 0,46$ . Por outro lado, foi mostrado evidências claras de que os melhores coeficientes de determinação para a predição das porcentagens de tecido cortado na 10<sup>a</sup>-12<sup>a</sup> costela estão em Retinta. Nessa raça, o resultado da regressão múltipla obtida na última varredura antes do abate foram responsáveis por 46%, 43% e 44% da variação na porcentagem de massa magra, gordura e osso, respectivamente. Os coeficientes de regressão melhoraram com a inclusão de duas ou três varreduras. Semelhante quando foi considerado um único escaneamento, a acurácia das previsões aumenta com a diminuição do tempo entre o escaneamento e o abate. Em geral, esses coeficientes aumentaram ao considerar as medidas de ultrassom de vários exames que apenas um ponto de tempo foi usado.

(OLIVER et al., 2010), realizaram uma regressão múltipla do peso da carcaça e do

escore de conformação do Sistema Europeu de Classificação de Carcaça (SEUROP) no rendimento de carne. Além disso, realizaram uma medida da precisão do sistema SEUROP nos quatro rendimentos da categoria de qualidade de corte comercial (extra, primeiro, segundo e terceiro). Foi realizada a análise de regressão *stepwise* do peso da carcaça e das 33 medidas de análise morfométricas da imagem, além do rendimento de carne e das quatro categorias de qualidade de corte comercial. A maior acurácia foi alcançada usando análise de imagem. Os valores do coeficiente de regressão estavam entre  $r^2 = 0,66$  e  $r^2 = 0,93$  ( $P < 0,001$ ) para o sistema SEUROP e entre  $r^2 = 0,81$  e  $r^2 = 0,94$  ( $P < 0,001$ ) para o método de análise de imagem. Os resultados sugerem que o método de análise de imagem deve ser útil como um meio de complementar e melhoria do sistema SEUROP para classificação de carcaças de bovinos. O peso da carcaça foi a variável que melhor explicou a composição da carcaça. Se o peso da carcaça for restrito à primeira variável independente, a acurácia adicional alcançada pela incorporação de medidas mais caras pode então ser avaliada (KEMPSTER et al., 1982).

(DANIEL et al., 2020), apresentam um sistema de visão computacional em combinação com um sistema de sensoração para a classificação em tempo real. Na etapa de Pré-processamento e seleção de contorno, foi corrigida e preparada cada uma das imagens para homogeneizar a amostra de dados, selecionando o contorno (silhueta) da carcaça e extraindo seus pixels. Uma vez obtida a borda da imagem, o próximo passo na etapa de Detecção de pontos de referência para segmentação de carcaça bovina é dividir a carcaça em diferentes regiões. Esta divisão é formada por uma série de linhas imaginárias que os especialistas usam para classificar a carcaça. Para fazer esta divisão, aplicam a técnica de detecção de pontos de referência (JAIN; LI, 2011), comumente usado em processos de reconhecimento facial. O trabalho realizado pelos autores em (LINDNER et al., 2016), o Random Forest Regression-Voting (CUTLER; CUTLER; STEVENS, 2012) é aplicado por ser um sistema rápido de treinar e avaliar. O processo de correção de cores é realizado na fase de pré-processamento da imagem. Este processo é essencial ao fazer uma estimativa correta e normalizada do nível de gordura presente na carne. Uma vez detectada a gordura na imagem completa da carcaça, o percentual de gordura em cada uma das divisões de corte é calculada. Para esta tarefa, a divisão feita através dos pontos de segmentação calculados são aplicados. Após a obtenção dos resultados de um conjunto, foi possível concluir que o sistema pode prever, com alta precisão, os resultados da classificação feita por um conjunto de 6 especialistas. No tempo que um especialista humano levaria para classificar um total de 40 peças, o sistema pode classificar com precisão até 10 vezes mais peças e enviar os resultados em tempo real para o sistema.

Nesse contexto, diferente dos trabalhos citados o presente trabalho analisa imagens de ultrassom de pequenos ruminantes, tendo como referência anatômica o espaço intercostal entre a 12° e 13° costela. Utilizando diferentes arquiteturas de CNNs pré-treinadas para segmentação da área do músculo *Longissimus dorsi* e predição dos valores da AOL com

base na extração de características utilizando diferentes modelos de regressores.

## 4 Metodologia Proposta

Neste trabalho, avaliamos carcaças de pequenos ruminantes por meio de um modelo de reconhecimento de imagens ultrassonográficas e a predizemos os valores da AOL utilizando diferentes tipos de regressores. Desta forma, as arquiteturas CNN conhecidas são treinadas com o objetivo de extrair os atributos das imagens ultrassonográficas para efetuar sua segmentação.

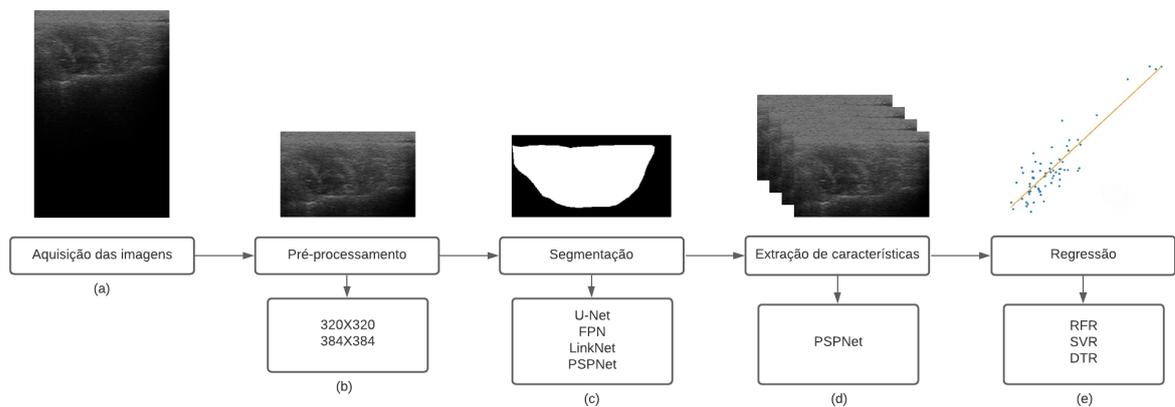


Figura 7 – Metodologia proposta. (a) Aquisição da base de dados. (b) Pré-processamento das imagens. (c) Aplicação de diferentes arquiteturas CNN pré-treinadas. (d) Extração de características. (e) Aplicação de regressores para predição da AOL.

### 4.1 Aquisição de Imagens

A coleção de imagens pertence ao Laboratório de Genética e Melhoramento Animal da Universidade Federal do Piauí (UFPI), contendo imagens ultrassonográficas de ovinos e caprinos, foi feita a captura em propriedades com animais registrados em associações de criadores. Esses animais são destinados a abatedouros e criados na região Meio-Norte do Brasil, localizada nos estados do Maranhão e Piauí. Participaram da pesquisa animais de ambos sexos com idade adulta no momento da coleta de dados.

Na avaliação da carcaça *in vivo*, são realizadas capturas de imagens ultrassonográficas por meio de aparelho de ultrassom equipado com transdutor linear de 13 cm, utilizando-se ajuste da frequência de 5,0 MHz. Para avaliar a musculabilidade são mensuradas as seguintes características: AOL, POL e COL. Essas características são avaliadas através de imagens de ultrassom de corte transversal do músculo *Longissimus dorsi*, tendo-se como referência anatômica o espaço intercostal entre a 12<sup>a</sup> e 13<sup>a</sup> costela. A AOL é dada em cm<sup>2</sup>, enquanto que POL e COL em cm. Além disso, o conjunto de imagens possui a marcação do músculo *Longissimus dorsi*.

Durante a captura das imagens ultrassonográficas, houve uma contenção do animal em estudo, de maneira confortável e relaxada para obtenção de uma maior qualidade das imagens. Também foi realizado a mensuração das características supracitadas por meio da ferramenta de medidas do próprio aparelho de ultrassom a fim de possibilitar a validação das avaliações posterior ao desenvolvimento do software de reconhecimento de imagens ultrassonográficas de características de carcaça. Dessa forma foram obtidas 206 imagens. A Figura 8 mostra exemplos de imagens de nosso banco de dados bem como as suas respectivas marcações.

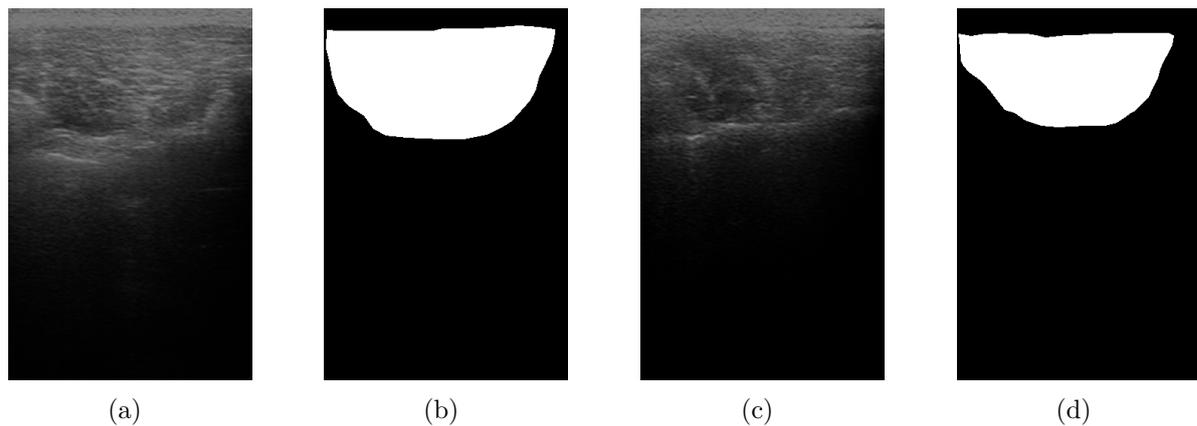


Figura 8 – Exemplos de imagens do banco de dados. Em (a) e (c) estão imagens de ultrassonografia, e em (b) e (d) suas respectivas regiões do músculo *Longissimus dorsi* marcadas pelo especialista da área.

## 4.2 Pré-processamento de Imagens

Os modelos CNN usados têm como entrada imagens de tamanho quadrado ( $320 \times 320$ ) e ( $384 \times 384$ ). Assim, é necessário redimensionar as imagens de entrada para essas dimensões. Além disso, os modelos de CNNs esperam valores de pixel entre 0 e 1. Nossas imagens têm valores de pixel entre 0 e 255. Dessa forma, realizou-se um ajuste linear, escalar, transformação dos níveis de cinza dos pixels para se adequarem aos requisitos dos modelos de CNNs.

## 4.3 Definindo o Modelo de CNN para Segmentação de Imagens

Neste trabalho, selecionamos quatro diferentes arquiteturas CNNs pré-treinadas para segmentação das imagens, são elas: U-Net (RONNEBERGER; FISCHER; BROX, 2015); FPN (LIN et al., 2017); LinkNet (CHAURASIA; CULURCIELLO, 2017); e PSPNet (ZHAO et al., 2017). Foram definidos alguns parâmetros para realizar o treinamento do modelo com base nas arquiteturas de CNNs pré-treinadas. A Tabela 1 mostra as características das arquiteturas CNN utilizadas neste trabalho e os parâmetros de treinamento.

Na configuração dos parâmetros utilizados para a segmentação foram feita dezenas de testes utilizando diferentes parâmetros, os parâmetros demonstrados na tabela 1 se sobressaíram e portanto foram usados para segmentação.

| <b>Tipo</b>        | <b>Parâmetros</b>            |
|--------------------|------------------------------|
| CNN                | U-Net, FPN, LinkNet e PSPNet |
| Função de Ativação | Sigmoid                      |
| Otimizador         | Adam                         |
| Função de Perda    | Jaccard Distance             |
| Batch Size         | 16                           |
| Épocas             | 100                          |
| Backbone           | Resnet34                     |
| Métricas           | F1-Score e IoU Score         |

Tabela 1 – Parâmetros utilizados no treinamento do modelo de segmentação proposto.

## 4.4 Extração de características

Após perceber que o modelo de arquitetura da PSPNet obteve os melhores resultados foi feita a extração de características com base nos resultados desse modelo. Dessa forma foi utilizado o algoritmo de importância das características usando MDI e o algoritmo de importância de características por permutação para calcular a importância dessas características.

## 4.5 Regressão Linear

No presente trabalho, os seguintes atributos foram extraídos das imagens para realizar a predição da AOL: centróide, área convexa, excentricidade, diâmetro equivalente, extensão, área preenchida, tensor de inércia, tensor de inércia eigvals, centróide local, comprimento do eixo principal, comprimento do eixo menor, orientação, perímetro, solidez e centróide ponderado, totalizando 15 atributos.

Foi feita uma análise com base nos conceitos desses atributos para saber quais desses atributos são realmente importantes para fazer a predição da AOL. Foi utilizado o algoritmo de importância do recurso de permutação e o algoritmo de importância das características usando Diminuição média da impureza (MDI) para calcular a importância dos atributos. O processo foi incremental: primeiro calculamos a importância de cada atributo; depois ordenamos os atributos do melhor para o pior; após isso, fizemos a predição aumentando a quantidade de atributos de um por um.

Com base em uma busca na literatura sobre quais regressores eram mais utilizadas, foi percebido a maior presença do *Random Forest Regressor* (CUTLER; CUTLER; STEVENS, 2012), *Decision Tree Regressor* (XU et al., 2005), e *Support Vector Regression*

(AWAD; KHANNA, 2015), por conta disso estes foram os regressores utilizados no seguinte trabalho.

## 4.6 Métricas de avaliação

Nesta seção, relatamos as métricas utilizadas para a avaliação nos experimentos da segmentação e a regressão.

### 4.6.1 Métricas de Segmentação

Como forma de avaliar os resultados da segmentação, foi utilizado as métricas Loss, IoU e F1-Score.

Na função de perda (*Loss*) e na métrica IoU foi utilizado o coeficiente de similaridade de Jaccard, representado pela Equação 4.1, que consiste em uma estatística usada para comparar a similaridade e diversidade dos conjuntos de amostras. A métrica (*Loss*) e Iou Definido como o tamanho da interseção dividido pelo tamanho da união de dois conjuntos de rótulos, é usado para comparar o conjunto de rótulos previstos para uma amostra com o conjunto de rótulos correspondente. (PEDREGOSA et al., 2011).

$$L(A, B) = 1 - \frac{A \cap B}{A \cup B}. \quad (4.1)$$

O F1-Score (coeficiente *dice*), representado pela Equação 4.2, é uma estatística usada para medir a similaridade de duas amostras e pode ser interpretado como uma média ponderada da *precision* e *recall*, onde um F1-score atinge seu melhor valor em 1 e o pior resultado em 0 (SORENSEN, 1948).

$$F_{\beta}(\textit{precision}, \textit{recall}) = (1 + \beta^2) \frac{\textit{precision} \cdot \textit{recall}}{\beta^2 \cdot \textit{precision} + \textit{recall}}. \quad (4.2)$$

### 4.6.2 Métricas de Regressão

Como forma de avaliar os resultados da regressão, foi utilizado as métricas MAE, MSE, e coeficiente  $r^2$ .

O MAE, representado pela Equação 4.3 uma métrica de risco correspondente ao valor esperado da perda de erro absoluto ou  $l_1$ -perda de norma (PEDREGOSA et al., 2011). Se  $\hat{y}_i$  é o valor previsto do  $i$ -ésima amostra,  $y_i$  é o valor verdadeiro correspondente, então o MAE estimado ao longo  $n_{\text{samples}}$  é definido como:

$$\text{MAE}(y, \hat{y}) = \frac{1}{n_{\text{samples}}} \sum_{i=0}^{n_{\text{samples}}-1} |y_i - \hat{y}_i|. \quad (4.3)$$

O MSE, representado pela Equação 4.4, é uma métrica de risco que corresponde ao valor esperado do erro ou perda quadrática (PEDREGOSA et al., 2011). Se  $\hat{y}_i$  é o valor

previsto do  $i$ -ésima amostra,  $y_i$  é o valor verdadeiro correspondente, então o MSE estimado ao longo  $n_{\text{samples}}$  é definido como:

$$\text{MSE}(y, \hat{y}) = \frac{1}{n_{\text{samples}}} \sum_{i=0}^{n_{\text{samples}}-1} (y_i - \hat{y}_i)^2. \quad (4.4)$$

O coeficiente  $r^2$ , representado pela Equação 4.5, é uma estatística utilizada no contexto de modelos estatísticos cujo objetivo principal é a previsão de resultados futuros ou o teste de hipóteses, com base em outras informações relacionadas. Ele fornece uma medida de quão bem os resultados observados são replicados pelo modelo, com base na proporção da variação total dos resultados explicada pelo modelo (DRAPER; SMITH, 1981), onde  $SS_{res}$  é a soma dos quadrados dos resíduos (ARCHDEACON, 1994) e  $SS_{tot}$  é a soma total dos quadrados (EVERITT; SKRONDAL, 2010).

$$r^2 = 1 - \frac{SS_{res}}{SS_{tot}}. \quad (4.5)$$

## 5 Resultados e Discussões

Nesta seção, apresentamos os resultados obtidos nos experimentos da segmentação através das CNNs pré-treinadas U-Net, FPN, LinkNet e PSPNet e os resultados da regressão linear, a partir dos regressores *Random Forest Regressor*, *Decision Tree Regressor* e *Support Vector Regression*.

### 5.1 Segmentação do Músculo *Longissimus dorsi*

Para calcular a qualidade da segmentação obtida pelas redes neurais utilizamos três métricas: *loss*, IoU e F1-Score. Nossa metodologia de segmentação usou CNNs pré-treinadas combinados com pré-processamento. O conjunto de imagens foi dividido em 60%, para treinamento 20% para validação e 20% para teste. Os resultados obtidos são apresentados na Tabela 2.

| Modelo        | Loss                 | IoU                  | F1-Score             |
|---------------|----------------------|----------------------|----------------------|
| U-Net         | 0,1992±0,0068        | 0,8911±0,0047        | 0,9424±0,0026        |
| FPN           | 0,1928±0,0108        | 0,8861±0,0050        | 0,9396±0,0028        |
| LinkNet       | 0,1965±0,0109        | 0,8913±0,0051        | 0,9425±0,0029        |
| <b>PSPNet</b> | <b>0,1672±0,0067</b> | <b>0,8904±0,0060</b> | <b>0,9420±0,0033</b> |

Tabela 2 – Resultados obtidos pela metodologia proposta para cada modelo.

Os resultados dos modelos foram semelhantes, porém o PSPNet se sobressaiu pelo fato de ter obtido o menor valor na função de *loss* com 0,16, IoU de 0,89 e F1-Score de 0,94. A Figura 9 apresenta o gráfico de treino e validação na métrica F1-Score nesse modelo, observa-se que a partir da época 40 existe pouca variação no aprendizado da rede. Isso mostra que a rede convergiu para um resultado robusto em uma quantidade de épocas menor quando comparado com outros trabalhos que usam esse tipo de CNN (ARAÚJO; ARAÚJO; SILVA, 2021).

As Figuras 10 e 11 mostram resultados visuais do método proposto PSPNet. Nessas imagens, podemos observar a imagem pré-processada, a segmentação do especialista e a segmentação do método proposto, respectivamente. A Figura 10 apresenta o melhor caso, e a Figura 11 apresenta o pior caso, baseado no valor de F1-Score obtido. A partir do melhor caso é possível notar que o resultado obtido com o modelo consegue obter um nível de detalhes melhor que o especialista, visto que as bordas são mais sutis e arredondadas que na segmentação do especialista.

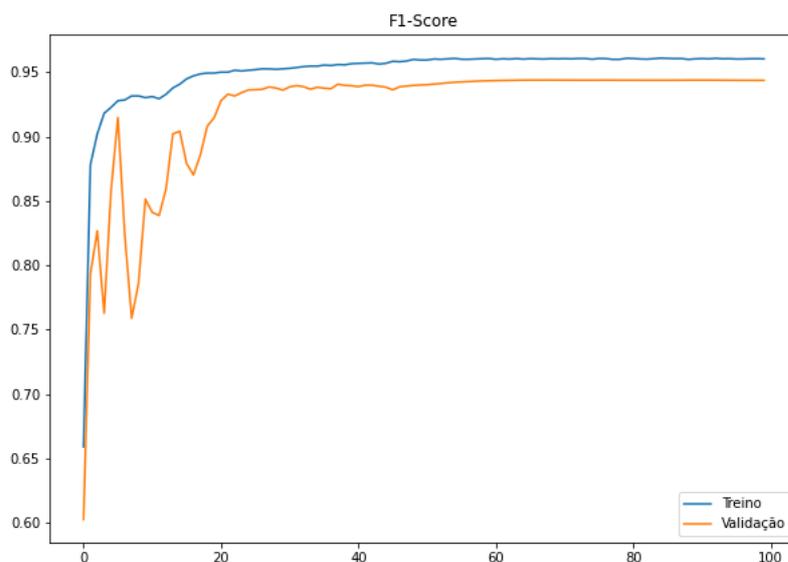


Figura 9 – Aprendizado da arquitetura PSPNet com base da métrica F1-Score.



Figura 10 – Resultado da segmentação do método proposto na imagem com maior valor de F1-Score (Da esquerda para direita, imagem pré-processada, a segmentação do especialista e a segmentação com o modelo proposto).



Figura 11 – Resultado da segmentação do método proposto na imagem com menor valor de F1-Score (Da esquerda para direita, imagem pré-processada, a segmentação do especialista e a segmentação com o modelo proposto).

## 5.2 Predição da Área de olho de lombo

Nos experimentos de predição da AOL, utilizamos duas versões da base: segmentação obtida pelo especialista; e, segmentação obtida pelo melhor resultado de segmentação da seção anterior (PSPNet). Objetivo foi comparar os resultados e verificar se a segmentação obtida consegue obter resultados similares aos obtidos com a segmentação do especialista.

Na Figura 12 são apresentados os resultados referentes a  $r^2$  obtidos da regressão linear do *Random Forest Regressor* tanto na imagem da máscara do especialista quanto na máscara do gerada pela segmentação da PSPNet.

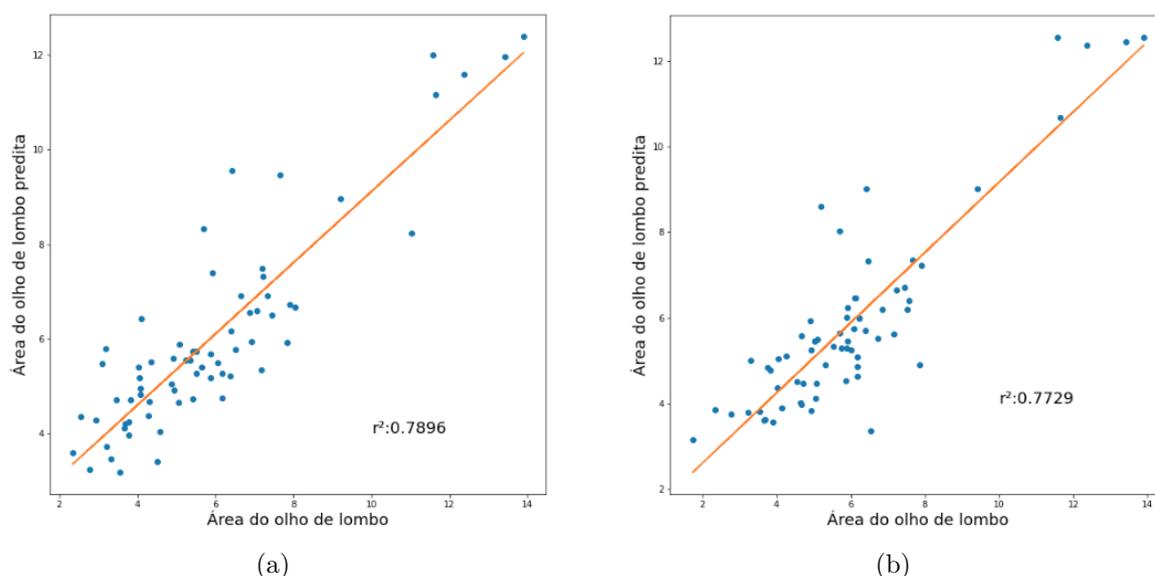


Figura 12 – Resultado da predição utilizando *Random Forest Regressor*. Em (a) é representado a predição na máscara do especialista, e em (b) é representado a predição na máscara do gerada pela segmentação da PSPNet.

Na Figura 13 são apresentados os resultados referentes a  $r^2$  obtidos da regressão linear do *Decision Tree Regressor* tanto na imagem da máscara do especialista quanto na máscara gerada pela segmentação da PSPNet.

Na Figura 14 são apresentados os resultados referentes a  $r^2$  obtidos da regressão linear do *Support Vector Regression* tanto na imagem da máscara do especialista quanto na máscara gerada pela segmentação da PSPNet.

Analisando os resultados das Figuras 12, 13 e 14 observamos que os resultados obtidos com a segmentação proposta são similares e até superiores aos obtidos com a segmentação do especialista. Isso valida o algoritmo de segmentação, visto que os atributos extraídos para realizar a regressão linear são diretamente relacionados à forma da região segmentada.

Na Tabela 3 são apresentados os resultados obtidos das regressões nas segmentações das máscaras geradas pela PSPNet. Destacou-se o *Random Forest Regressor* com melhor  $r^2$  (0,77) e maior média do  $r^2$  (0,56). Foram utilizados apenas nove atributos para obtenção do melhor resultado, em comparação com os resultados do *Random Forest Regressor* das

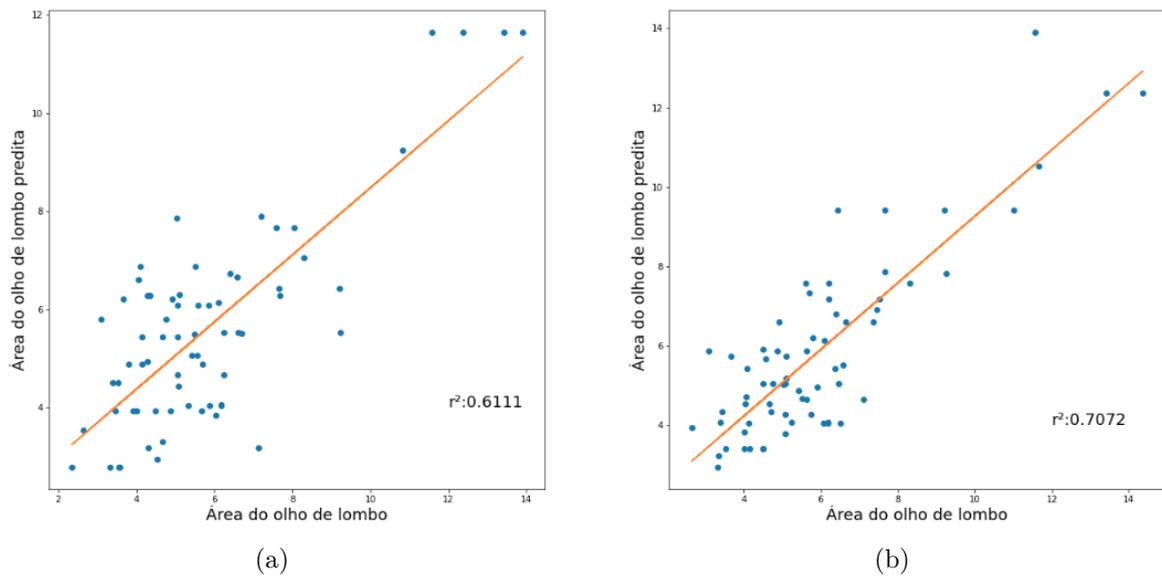


Figura 13 – Resultado da predição utilizando *Decision Tree Regressor*. Em (a) é representado a predição na máscara do especialista, e em (b) é representado a predição na máscara do gerada pela segmentação da PSPNet.

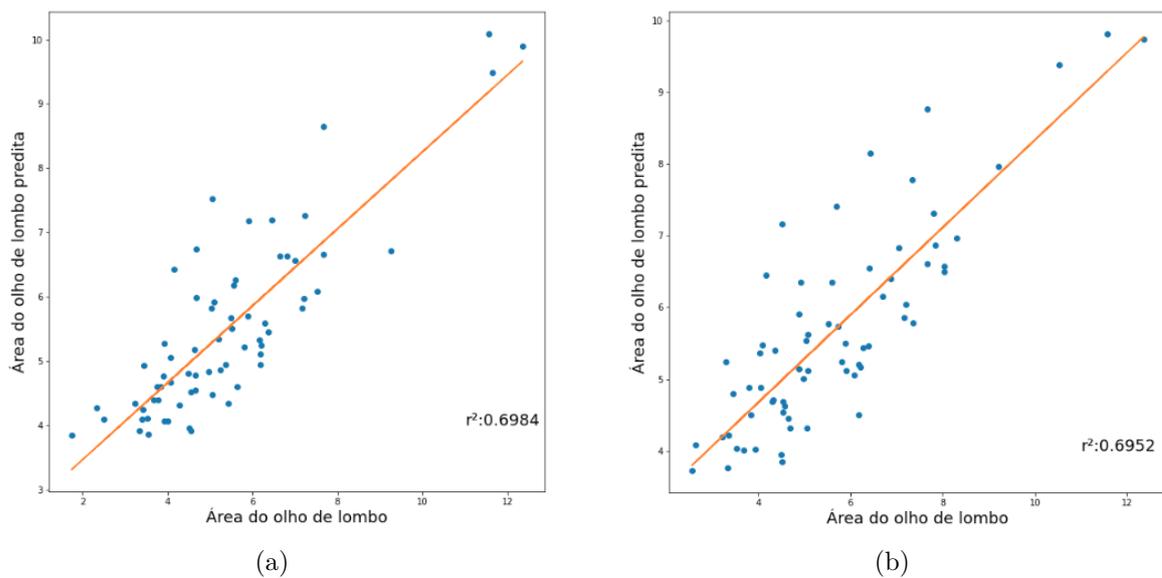


Figura 14 – Resultado da predição utilizando *Support Vector Regression (SVR)*. Em (a) é representado a predição na máscara do especialista, e em (b) é representado a predição na máscara do gerada pela segmentação da PSPNet.

Tabela 3 – Resultados das métricas nas máscaras geradas pela segmentação da PSPNet.

| Regressores | Atributos | Melhor $r^2$ | $r^2$         | MSE           | MAE           |
|-------------|-----------|--------------|---------------|---------------|---------------|
| <i>RFR</i>  | 9         | 0,7729       | 0,5675±0,1474 | 1,0942±0,1185 | 2,0298±0,4147 |
| <i>DTR</i>  | 8         | 0,7072       | 0,4285±0,2283 | 1,2801±0,1259 | 2,8494±0,6056 |
| <i>SVR</i>  | 12        | 0,6952       | 0,5600±0,0951 | 1,0446±0,1037 | 1,9397±0,5295 |

Tabela 4 – Resultados das métricas nas máscaras do especialista.

| Regressores | Atributos | Melhor $R^2$ | $R^2$         | MSE           | MAE           |
|-------------|-----------|--------------|---------------|---------------|---------------|
| <i>RFR</i>  | 15        | 0,7895       | 0,5653±0,1602 | 1,1494±0,1033 | 2,1963±0,3446 |
| <i>DTR</i>  | 15        | 0,6110       | 0,2855±0,3397 | 1,3338±0,1619 | 3,1543±0,7255 |
| <i>SVR</i>  | 22        | 0,6984       | 0,5614±0,0905 | 1,0603±0,1175 | 2,0417±0,6069 |

métricas nas máscaras do especialista foi utilizados menos atributos em comparação com os resultados do RFR aplicado as máscaras do especialista. Isso demonstra maior agilidade na predição das máscaras geradas pela segmentação da PSPNet. Por outro lado, o *Support Vector Regression* obteve os menores valores de MSE (1,04) e MAE (1,93), com um  $r^2$  de 0,56.

Na Tabela 4 são apresentados os resultados obtidos das regressões nas segmentações manuais. Destacou-se o *Random Forest Regressor* com melhor  $r^2$  (0,78) e maior média do  $r^2$  (0,56). Por outro, o *Support Vector Regression* obteve os menores valores de MSE (1,06) e MAE (2,04), com um  $r^2$  de 0,56.

## 6 Conclusões e trabalhos futuros

Este trabalho apresenta um método para segmentação automática do músculo *Longissimus dorsi* a partir de imagens de ultrassom de pequenos ruminantes e a predição da AOL utilizando algoritmos de regressão e métricas de desempenho como erro médio quadrático e absoluto, e coeficiente  $r^2$ . Neste trabalho foram realizados experimentos em que diversos modelos de arquiteturas de CNNs foram testados e comparados. Ao comparar tais métodos foram mostrados resultados semelhantes, observamos que na etapa de segmentação a arquitetura PSPNet se destacou das demais já na predição da AOL o regressor *Radom Forest Regressor* obteve os melhores resultados.

O presente estudo mostrou que a utilização de métodos automáticas para o reconhecimento de imagens ultrassonográficas neste âmbito é aceito, pois a avaliação manual de imagens ultrassonográficas de pequenos ruminantes é uma atividade que pode ser longa, cansativa e trabalhosa. Essa metodologia pode trazer mais agilidade e precisão ao trabalho desses profissionais. Com base nos testes, foi possível obter uma avaliação precisa e rápida da carcaça das imagens inseridas, o que poderá permitir ao produtor um diagnóstico correto das mensurações dos animais, com maior praticidade e economia de tempo.

Como trabalhos futuros, iremos utilizar o resultado obtido na segmentação para realizar a predição da EGS. Para isso, serão extraídos atributos das imagens a partir da forma da músculo. Nesse processo, serão utilizados algoritmos de regressão e métricas de desempenho como erro médio quadrático e absoluto, e coeficiente  $r^2$  para efetuar essa predição.

## 7 Publicações

Tiago M. Oliveira, José L. R. Sarmiento, Luiz A. S. Figueiredo Filho, Romuere R. V. Silva. “Segmentação de imagens de ultrassonografia da carcaça em pequenos ruminantes utilizando *Deep Learning*” **XIV Encontro Unificado de Computação do Piauí (ENUCOMPI).XI Simpósio de Sistemas de Informação (SINFO)**. SBC, 2021.

## Referências

- ARAÚJO, R. L.; ARAÚJO, F. H. D. de; SILVA, R. R. V. e. Automatic segmentation of melanoma skin cancer using transfer learning and fine-tuning. *Multimedia Systems*, 2021. ISSN 1432-1882. Disponível em: <<https://doi.org/10.1007/s00530-021-00840-3>>. Citado na página 30.
- ARCHDEACON, T. J. *Correlation and regression analysis: a historian's guide*. [S.l.]: Univ of Wisconsin Press, 1994. Citado na página 29.
- AWAD, M.; KHANNA, R. Support vector regression. In: *Efficient learning machines*. [S.l.]: Springer, 2015. p. 67–80. Citado 2 vezes nas páginas 21 e 28.
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, n. 1, p. 5–32, 2001. Citado na página 19.
- CARTAXO, F. Q.; SOUSA, W. H. d. Correlações entre as características obtidas in vivo por ultra-som e as obtidas na carcaça de cordeiros terminados em confinamento. *Revista Brasileira de Zootecnia*, SciELO Brasil, v. 37, p. 1490–1495, 2008. Citado na página 13.
- CHAURASIA, A.; CULURCIELLO, E. Linknet: Exploiting encoder representations for efficient semantic segmentation. In: IEEE. *2017 IEEE Visual Communications and Image Processing (VCIP)*. [S.l.], 2017. p. 1–4. Citado 4 vezes nas páginas 8, 17, 18 e 26.
- CUTLER, A.; CUTLER, D. R.; STEVENS, J. R. Random forests. In: *Ensemble machine learning*. [S.l.]: Springer, 2012. p. 157–175. Citado 5 vezes nas páginas 8, 19, 20, 23 e 27.
- DANIEL, H. et al. Non-invasive automatic beef carcass classification based on sensor network and image analysis. *Future Generation Computer Systems*, Elsevier, v. 113, p. 318–328, 2020. Citado na página 23.
- DRAPER, N.; SMITH, H. Applied regression analysis: Wiley interscience. *New York*, 1981. Citado na página 29.
- EVERITT, B. S.; SKRONDAL, A. The cambridge dictionary of statistics. 2010. Citado na página 29.
- FURNOLS, M. Font-i et al. Composition and intramuscular fat estimation of holstein bull and steer rib sections by using one or more computed tomography cross-sectional images. *Livestock Science*, Elsevier, v. 170, p. 210–218, 2014. Citado na página 22.
- IBGE. *Pesquisa da Pecuária Municipal*. 2020. Último acesso em 13 de outubro de 2020. Disponível em: <<https://sidra.ibge.gov.br/tabela/3939>>. Citado na página 13.
- JAIN, A. K.; LI, S. Z. *Handbook of face recognition*. [S.l.]: Springer, 2011. Citado na página 23.
- KEMPSTER, A. et al. *Carcass evaluation in livestock breeding, production and marketing*. [S.l.]: Granada Publishing Limited, 1982. Citado na página 23.

- KHAN, A. et al. A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, Springer, v. 53, n. 8, p. 5455–5516, 2020. Citado na página 15.
- KRATSIOS, A.; HYNDMAN, C. Neu: A meta-algorithm for universal uap-invariant feature representation. *Journal of Machine Learning Research*, v. 22, n. 92, p. 1–51, 2021. Citado na página 19.
- LECUN, Y. et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, Ieee, v. 86, n. 11, p. 2278–2324, 1998. Citado na página 15.
- LI, X. et al. A debiased mdi feature importance measure for random forests. *arXiv preprint arXiv:1906.10845*, 2019. Citado na página 19.
- LIN, T.-Y. et al. Feature pyramid networks for object detection. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2017. p. 2117–2125. Citado 3 vezes nas páginas 8, 17 e 26.
- LINDNER, C. et al. Fully automatic system for accurate localisation and analysis of cephalometric landmarks in lateral cephalograms. *Scientific reports*, Nature Publishing Group, v. 6, p. 33581, 2016. Citado na página 23.
- LONG, J.; SHELHAMER, E.; DARRELL, T. Fully convolutional networks for semantic segmentation. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2015. p. 3431–3440. Citado na página 16.
- NETO, A. D. B. Posicionamento estratégico do setor de carnes de caprinos e ovinos no mercado de carnes brasileiro. *Revista Tecnologia & Ciência Agropecuária*, v. 4, n. 4, p. 81–85, 2010. Citado na página 13.
- OLIVEIRA, J. de A. *Classificação de regiões usando atributos de forma e seleção de atributos*. Tese (Doutorado) — Master’s thesis, Instituto Nacional de Pesquisas Espaciais, São José dos . . . , 2005. Citado na página 18.
- OLIVER, A. et al. Predicting meat yields and commercial meat cuts from carcasses of young bulls of spanish breeds by the seurop method and an image analysis system. *Meat science*, Elsevier, v. 84, n. 4, p. 628–633, 2010. Citado na página 22.
- PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011. Citado na página 28.
- PEÑA, F. et al. The use of ultrasound scanning at different times of the finishing period in lean cattle. *Livestock Science*, Elsevier, v. 167, p. 381–391, 2014. Citado na página 22.
- PRATT, W. K. Digital image processing john wiley & sons. *Inc., New York*, 1991. Citado na página 18.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. *International Conference on Medical image computing and computer-assisted intervention*. [S.l.], 2015. p. 234–241. Citado 3 vezes nas páginas 8, 16 e 26.

ROSANOVA, C. Fatores favoráveis e limitantes ao desenvolvimento da cadeia produtiva da ovinocaprino-cultura de corte no Brasil. *Monografia, Universidade Federal de Lavras*, 2004. Citado na página 13.

SORENSEN, T. A. A method of establishing groups of equal amplitude in plant sociology based on similarity of species content and its application to analyses of the vegetation on Danish commons. *Biol. Skar.*, v. 5, p. 1–34, 1948. Citado na página 28.

TOUROCO. *A Utilização da Técnica de Ultrassonografia em Tempo Real para Avaliação e Seleção de Características de Carcaça em Animais de Corte*. 2020. Disponível em: <[http://www.diadecampo.com.br/arquivos/materias/\%7B60C32BAC-9BE8-4C0E-BA26-D6107ACB7E7D\%7D\\\_Melhoramento\\\_de\\\_bovinos\\\_de\\\_corte\\\_atraves\\\_da\\\_ultrassonografia.pdf](http://www.diadecampo.com.br/arquivos/materias/\%7B60C32BAC-9BE8-4C0E-BA26-D6107ACB7E7D\%7D\_Melhoramento\_de\_bovinos\_de\_corte\_atraves\_da\_ultrassonografia.pdf)>. Acesso em: 13 October 2020. Citado na página 13.

WU, J. et al. Personalized collaborative filtering recommendation algorithm based on linear regression. In: IEEE. *2019 IEEE International Conference on Power Data Science (ICPDS)*. [S.l.], 2019. p. 139–142. Citado na página 19.

XU, M. et al. Decision tree regression for soft classification of remote sensing data. *Remote Sensing of Environment*, Elsevier, v. 97, n. 3, p. 322–336, 2005. Citado 3 vezes nas páginas 8, 20 e 27.

ZHAO, H. et al. Pyramid scene parsing network. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2017. p. 2881–2890. Citado 4 vezes nas páginas 8, 18, 19 e 26.



**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA  
“JOSÉ ALBANO DE MACEDO”**

**Identificação do Tipo de Documento**

- ( ) Tese  
( ) Dissertação  
( X ) Monografia  
( ) Artigo

Eu,     Tiago de Moura Oliveira    , autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação Segmentação do Músculo Longissimus Dorsi e Predição da Área do Olho de Lombo em imagens de ultrassonografia de Pequenos Ruminantes de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI   19   de   Maio   de   2022  .

    Tiago de Moura Oliveira    

Assinatura

    Tiago de Moura Oliveira    

Assinatura