



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO DE CIÊNCIAS, TECNOLOGIAS E SAÚDE DO CAMPUS ARARANGUÁ
CURSO DE GRADUAÇÃO EM ENGENHARIA DE COMPUTAÇÃO

Gustavo Zago Canal

**UTILIZAÇÃO DE TÉCNICAS DE APRENDIZAGEM DE MÁQUINA E
PROCESSAMENTO DE IMAGEM PARA ESTIMAR O PESO DE GADO DE CORTE**

Araranguá
2022

Gustavo Zago Canal

**UTILIZAÇÃO DE TÉCNICAS DE APRENDIZAGEM DE MÁQUINA E
PROCESSAMENTO DE IMAGEM PARA ESTIMAR O PESO DE GADO DE CORTE**

Trabalho de Conclusão do Curso de Graduação em Engenharia de Computação do Centro de Ciências, Tecnologias e Saúde do Campus Araranguá da Universidade Federal de Santa Catarina para a obtenção do título de Bacharel em Engenharia de Computação.

Orientador: Prof. Alexandre Leopoldo Gonçalves, Dr.

Coorientador: Prof. Antônio Carlos Sobieranski, Dr.

Araranguá

2022

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Canal, Gustavo Zago

Utilização de técnicas de aprendizagem de máquina e processamento de imagem para estimar o peso de gado de corte / Gustavo Zago Canal ; orientador, Alexandre Leopoldo Gonçalves, coorientador, Antonio Carlos Sobieranski, 2022.

34 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Campus Araranguá, Graduação em Engenharia de Computação, Araranguá, 2022.

Inclui referências.

1. Engenharia de Computação. 2. Redes Neurais Convolucionais. 3. Processamento de Imagens. 4. Estimativa de Peso. I. Gonçalves, Alexandre Leopoldo. II. Sobieranski, Antonio Carlos. III. Universidade Federal de Santa Catarina. Graduação em Engenharia de Computação. IV. Título.

Gustavo Zago Canal

**UTILIZAÇÃO DE TÉCNICAS DE APRENDIZAGEM DE MÁQUINA E
PROCESSAMENTO DE IMAGEM PARA ESTIMAR O PESO DE GADO DE CORTE**

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do Título de Bacharel em Engenharia de Computação, e foi aprovado em sua forma final pelo Curso de Engenharia de Computação.

Araranguá, 08 de março de 2022.

Prof^a. Analucia Schiaffino Morales, Dr^a.
Coordenadora do Curso

Banca Examinadora:

Prof. Alexandre Leopoldo Gonçalves, Dr.

Orientador

Universidade Federal de Santa Catarina

Prof. Antônio Carlos Sobieranski, Dr.

Coorientador

Universidade Federal de Santa Catarina

Prof. Anderson Luiz Fernandes Perez, Dr.

Avaliador

Universidade Federal de Santa Catarina

Prof. Martin Augusto Gagliotti Vigil, Dr.

Avaliador

Universidade Federal de Santa Catarina

Prof. Fábio Rodrigues De La Rocha, Dr.

Avaliador Suplente

Universidade Federal de Santa Catarina

Utilização de Técnicas de Aprendizagem de Máquina e Processamento de Imagem Para Estimar o Peso de Gado de Corte

Using Machine Learning and Image Processing to Estimate Beef Cattle Live Weight

Gustavo Zago Canal * Alexandre Leopoldo Gonçalves †
Antonio Carlos Sobieranski ‡

2022, Março

Resumo

A pecuária bovina possui grande representatividade na economia brasileira, sendo que em 2020 o Brasil atingiu o maior rebanho mundial com 218 milhões de cabeças de gado. Mesmo com esta alta representatividade, o acompanhamento do peso dos animais é feito de forma rudimentar e, em muitos casos, não é realizado devido a quantidade necessária de trabalhadores para realizar o processo. O peso dos animais é uma característica importante, pois influencia em diversos fatores como lactação, crescimento e fertilidade. Ademais, é uma medida relevante para a correta definição da dosagem de medicamentos. Por este motivo, o presente trabalho tem como objetivo a proposição de um método para a estimativa não intrusiva do peso de gado de corte a partir de imagens por meio de Aprendizado de Máquina, mas especificamente por meio de Redes Neurais. Para a avaliação do método foi utilizado um conjunto de dados de animais da raça *Hereford* que possui 103 imagens com seus respectivos pesos. Este conjunto de dados foi submetido a duas arquiteturas diferentes de Redes Neurais Convolucionais, uma sequencial e uma baseada na rede *DenseNet*. Os resultados obtidos foram relevantes, sendo que o modelo sequencial alcançou um RMSE de 57,50kg e um MAPE de 10,2% e o modelo de *DenseNet* um RMSE de 35,67kg e um MAPE de 6,1%. Desta forma, conclui-se que o método proposto tem potencial para estimar o peso de gado de corte contribuindo para o bem-estar dos animais e auxiliando produtores no monitoramento de rebanhos.

Palavras-chaves: Redes Neurais Convolucionais, Processamento de Imagens, Estimativa de Peso de Gado de Corte.

*gustavo.canal@grad.ufsc.br

†a.l.goncalves@ufsc.br

‡a.sobieranski@ufsc.br

Utilização de Técnicas de Aprendizagem de Máquina e Processamento de Imagem Para Estimar o Peso de Gado de Corte

Using Machine Learning and Image Processing to Estimate Beef Cattle Live Weight

Gustavo Zago Canal * Alexandre Leopoldo Gonçalves †
Antonio Carlos Sobieranski ‡

2022, Março

Abstract

Cattle livestock has a great representativity to Brazilian economy, being that in 2020 Brazil was the owner of the largest herd with 218 million cattle. Even with this high representativity, the monitoring of the weight of the animals is done in an old fashion way and in many cases is not done at all due to the number of workers needed for this process. The weight of the animals is a very important characteristic, as it influences several factors such as lactation, growth and fertility. Moreover, it is an important measure used for medications dosage. For this reason, the present study aims to propose a method to estimate cattle live weight from images in a non-intrusive way by using Machine Learning, specifically through Neural Networks. In this study, a dataset containing 103 images of Hereford cattle and their respective weights was used. This dataset was submitted to two different architectures of Convolutional Neural Networks, one sequential and one based on the DenseNet network. The results obtained were relevant, the sequential model reached a RMSE of 57,50kg and a MAPE of 10,2% and the DenseNet model a RMSE of 35,67kg and a MAPE of 6,1%. Thus, it is concluded that the proposed method has the potential to estimate the weight of beef cattle, contributing to the welfare of the animals and helping the monitoring of the herd by the producers.

Key-words: Convolutional Neural Networks, Image Processing, Beef Cattle Weight Estimation.

*gustavo.canal@grad.ufsc.br

†a.l.goncalves@ufsc.br

‡a.sobieranski@ufsc.br

1 Introdução

A pecuária bovina brasileira possui grande representatividade para a macroeconomia do país. Em 2009 o Brasil possuía aproximadamente 205 milhões de cabeças de gado. Apenas 11 anos depois, em 2020, esse número aumentou para 218 milhões (IBGE, 2021) tornando o Brasil o detentor do maior rebanho mundial, com uma representatividade de 14,3% (EMBRAPA, 2020). Estudos mostram que o tamanho das fazendas ao redor do mundo está aumentando (LOWDER; SKOET; RANEY, 2016) e o número geral de fazendas diminuindo (DOHMEN; CATAL; LIU, 2021a). Isto dificulta o acompanhamento dos animais pelos criadores, pois além da preocupação com a saúde e bem-estar de um grande número de animais, estes são responsáveis por garantir um produto final de qualidade com foco na lucratividade (BERCKMANS, 2014).

Um acompanhamento frequente do peso dos animais é de suma importância para maximizar o crescimento e monitorar o bem-estar e saúde dos animais, visto que, pode impactar em fatores como lactação, crescimento, gravidez e fertilidade dos mesmos (QIAO *et al.*, 2021). Por estes motivos, o acompanhamento tem o potencial de oferecer grandes benefícios ao criador e também para os animais (HANSEN *et al.*, 2018).

Atualmente, o acompanhamento mais comum do peso dos animais em fazendas é efetuado por meio de balanças mecânicas, que apresentam resultados com uma boa precisão. No entanto, realizar a pesagem de forma individual é oneroso para os criadores e estressante para os animais. Além disso, pelo fato das balanças ficarem expostas às intempéries, elas são mais propensas à manutenções frequentes. Por consequência, os criadores fazem apenas duas pesagens, uma no início e outra no fim do processo de criação, sendo levados em consideração apenas pequenos grupos de animais (KASHIHA *et al.*, 2014). Costa *et al.* (2019) apresenta uma revisão sobre danos causados ao bem-estar dos animais de acordo com seu convívio social, dietas restritivas e procedimentos dolorosos. Neste estudo, discute-se que o bem-estar dos animais depende em muito do convívio com os outros animais e da naturalidade da sua rotina. Desta forma, a realização da pesagem por meio de balanças, que requer o deslocamento dos animais de forma involuntária, prejudica este processo. Por isso, uma forma de realizar esta pesagem de forma não intrusiva e automatizada torna-se de grande utilidade em fazendas comerciais (QIAO *et al.*, 2021).

Com o aumento da capacidade computacional no decorrer dos últimos anos, soluções baseadas em visão computacional e aprendizado de máquina se tornaram viáveis, abrindo um leque de opções para diferentes áreas de aplicação, dentre elas, as fazendas inteligentes ou "*Smart farms*". *Smart Farms* é um conceito de aplicação de canais de monitoramento e automação em fazendas. Na prática, nessas fazendas são aplicadas novas tecnologias com o intuito de facilitar ou aperfeiçoar tarefas cotidianas (HANSEN *et al.*, 2018). Para tal, a utilização de *edge-computing* se encaixa perfeitamente, visto que em fazendas geralmente o acesso à *internet* é limitado e executar a transmissão de dados para um processamento em um servidor remoto pode ser inviável. *Edge-computing* se trata de trazer o processamento dos dados próximo do local em que são extraídos ao invés de enviar para localidades remotas (MURSHED *et al.*, 2021). Um exemplo de possível aplicação em fazendas, seria a captura de imagens dos animais por câmeras em seu local de convívio, com consequente processamento dessas por modelos de aprendizado de máquina visando efetuar a predição do peso.

Como mencionado anteriormente, o Brasil tem uma representatividade elevada em relação ao rebanho de gado mundial. Porém, estudos envolvendo novas tecnologias como inteligência artificial, ainda são raros, como demonstra o artigo de Bao e Xie (2022). Neste

sentido, o presente trabalho visa a estimativa do peso dos animais de forma não intrusiva e, para tal, se utiliza de um conjunto de imagens do dorso dos animais. Considerando o bom desempenho de Redes Neurais na área de reconhecimento de padrões e sua boa sinergia com imagens, esta técnica é utilizada neste trabalho. O treinamento do modelo em questão é efetuado por meio de aprendizado supervisionado a partir de imagens, como já mencionado, do dorso dos animais.

Este trabalho, além desta seção, está estruturado da seguinte forma: a Seção 2 apresenta uma introdução dos conceitos voltados à contextualização da problemática e para a estimativa do peso dos animais. A Seção 3 apresenta os trabalhos correlatos que tratam da estimativa do peso de animais utilizando técnicas de aprendizado de máquina e reconhecimento de imagens. Na Seção 4 é apresentado o método proposto neste trabalho, juntamente as técnicas utilizadas na sua implementação. A Seção 5 apresenta os resultados obtidos e, por fim, a Seção 6 sugere aplicações futuras que podem ser desenvolvidas a partir deste trabalho.

2 Fundamentação Teórica

2.1 Predição do Peso

Atualmente o método tradicional de fazer a pesagem de animais em fazendas consiste na utilização de balanças mecânicas (Figura 1 a) que fornece um valor preciso do peso dos animais. Para a aplicação deste método é necessário o deslocamento dos animais até o local onde está localizada a balança, bem como a intervenção humana para supervisionar o processo e fazer anotações dos valores. Apesar da balança ser uma boa solução para a estimativa do peso, existem alguns pontos negativos nesta abordagem. O primeiro refere-se ao tempo e ao esforço necessários para realizar a pesagem. Outro ponto negativo refere-se a interferência na rotina dos animais com a realização frequente da pesagem, impactando no bem-estar dos mesmos. Ademais, balanças mecânicas possuem um custo elevado e pelo fato de estarem em contato direto com os animais aumenta a probabilidade de problemas de funcionamento no decorrer do tempo.

Em fazendas menores o uso de balanças não é tão comum, visto o valor do investimento necessário. Um processo alternativo de baixo custo pode ser utilizado para a pesagem dos animais e acompanhamento do crescimento do rebanho, ainda que os valores não sejam tão precisos. Este processo é realizado utilizando fitas medidoras (Figura 1 b). Estas fitas se utilizam do fato do perímetro do peitoral dos animais ter alta correlação com o seu peso, ou seja, foram mapeadas de forma que uma determinada medida do peitoral corresponda a um valor de peso (HEINRICHS; ERB *et al.*, 2007). Além disso, nelas existem faixas para diferentes raças assim como para diferentes portes de animais.

Ambas alternativas supracitadas auxiliam os criadores no acompanhamento do crescimento do rebanho, porém são formas manuais que requerem um esforço dos criadores para serem executadas. Em casos de grandes fazendas, estas alternativas não são viáveis para um acompanhamento frequente devido ao fato do número de animais ser elevado. Diante disto, técnicas de acompanhamento não intrusiva e automatizada vêm sendo pesquisadas. Tais soluções, em sua grande maioria, fazem uso de visão computacional combinada com o aprendizado de máquina. De forma similar às técnicas manuais, são utilizadas as medidas dos animais para fazer a estimativa do peso, todavia, as medidas são extraídas de imagens de forma direta ou indireta.

Figura 1 – Métodos tradicionais de pesagem do gado



(a) Balança mecânica

(b) Fita medidora

Fonte: Stajanko *et al.* (2022) e Fonseca, Alves e Passini (2012).

A extração direta de dados de imagens torna o problema similar ao resolvido pelas fitas medidoras. Porém com os dados extraídos de forma digital eles podem ser processados por meio de um algoritmo de aprendizado de máquina de forma automática. As características mais comuns em estudos de predição de peso são perímetro do peitoral, altura da cernelha, largura e altura do quadril visto que possuem uma boa correlação com o peso dos animais (HEINRICHS; ROGERS; COOPER, 1992; ENEVOLDSEN; KRISTENSEN, 1997; TASDEMIR; URKMEZ; INAL, 2011; HEINRICHS; HEINRICHS *et al.*, 2017) e são relativamente fáceis de serem obtidas das imagens.

No trabalho de Song *et al.* (2018), um método de extração direta das características é aplicado. Para isso os autores propuseram uma solução que realiza a modelagem da parte superior dos animais através de imagens obtidas com uma câmera 3D. Estas imagens, passam por 6 etapas de processamento aplicadas pela ferramenta Matlab[®]. Ao término do processamento, foi possível obter um molde 3D do dorso dos animais (Figura 2), sendo extraídas as seguintes características: altura e largura do quadril e comprimento da região dorsal. Estas medidas, juntamente com idade, número de gestação e *DIM*¹, foram aplicadas em um modelo de múltiplas regressões lineares para a realização da estimativa do peso.

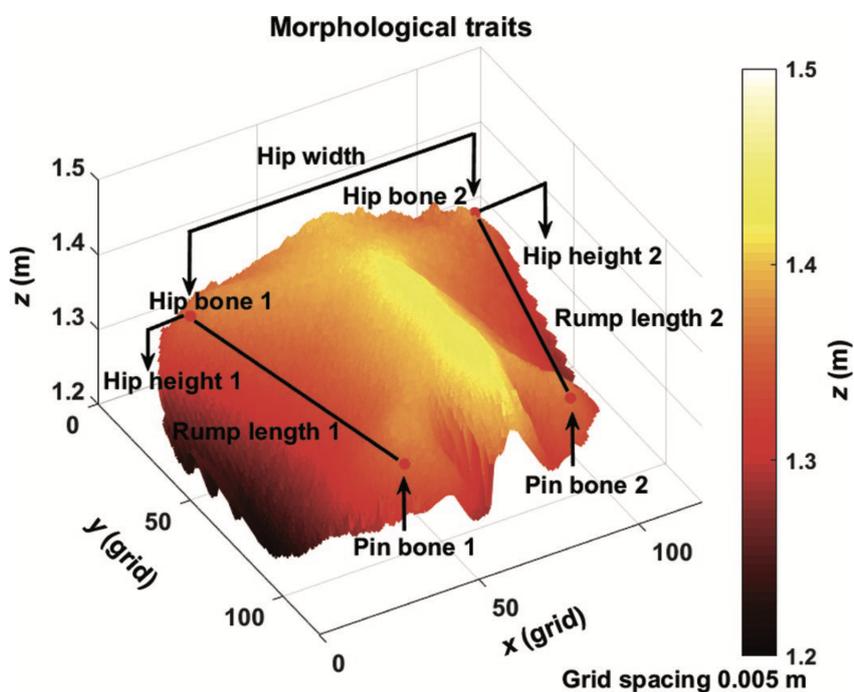
Uma abordagem diferente, ainda utilizando câmeras 3D é apresentada em Nir *et al.* (2018). Neste trabalho, foi utilizada uma câmera 3D para realizar a captura das imagens dos animais, porém as características são extraídas por meio de uma técnica conhecida como ajuste de elipses que, após esta etapa, foram submetidas a um modelo de múltiplas regressões lineares para a obtenção do peso estimado.

A extração das características também é aplicada em Weber *et al.* (2020), porém, neste estudo imagens 2D foram utilizadas. As imagens, da parte superior dos animais foram segmentadas e alinhadas horizontalmente. Após isso, o perímetro do dorso do animal foi preenchido com pontos, os quais foram conectados entre si para obter medidas a partir das distâncias entre eles. Estas medidas foram então submetidas à modelos de aprendizado de máquina para a obtenção do valor estimado do peso.

Por outro lado, a extração indireta das características consiste na utilização mais intensa de algoritmos de aprendizado de máquina, em que o processamento de imagem é utilizado apenas para redimensionamento e correções básicas de cores, sendo a imagem por inteira submetida a um modelo para a realização da predição do peso. Um exemplo desta abordagem é apresentada por Gjergji *et al.* (2020). Neste estudo, as imagens são

¹ Days in Milk: período que o animal está em lactação.

Figura 2 – Modelo em 3 dimensões do dorso de um animal elaborado com o objetivo de extrair suas características



Fonte: Song *et al.* (2018).

capturadas com uma câmera 2D localizada acima do bebedouro dos animais. Estas imagens são submetidas a uma Rede Neural Convolutiva que as processa e realiza a estimativa do peso.

2.2 Inteligência Artificial

A Inteligência Artificial (IA) é uma área da ciência abrangente e que vem sendo cada vez mais utilizada considerando uma extensa variedade de problemas que podem ser solucionados a partir dela. Pode ser definida como "o estudo de como fazer os computadores realizarem tarefas que hoje em dia são realizadas de melhor forma por humanos" (RICH, 1985). Esta definição faz sentido, porém não deve ser mal interpretada. Apesar da IA ter chegado a um ponto em que possibilite a realização de cálculos complexos e o reconhecimento de padrões com certa facilidade, deve-se considerar que muitas aplicações desenvolvidas com IA servem para ajudar os humanos a realizarem tarefas e não para substituí-los.

Diversas aplicações que estão à nossa disposição fazem uso de técnicas de IA, por exemplo, os assistentes virtuais, como Google Assistant®, Alexa® e Siri®, que utilizam reconhecimento de voz para ajudar o usuário a realizar tarefas ou para oferecer uma opção ao invés da digitação. Também pode ser vista em sistemas de recomendações, onde são sugeridas aos usuários opções baseadas nas suas pesquisas e no que outras pessoas estão acessando. Este comportamento ocorre em plataformas de *streaming*, onde são sugeridas séries ou filmes do mesmo estilo aos assistidos previamente. Também pode ser percebido em lojas *online* em que são sugeridos produtos com base nas suas pesquisas. Outro exemplo

são os carros autônomos, que fazem uso de sensores em conjunto com a IA para detectar outros automóveis, pessoas, e mesmo, o caminho que devem seguir.

As aplicações supracitadas fazem parte de uma subárea da IA chamada Aprendizado de Máquina (do inglês *Machine Learning* - ML). Aprendizado de máquina, como o nome sugere, consiste em ensinar o computador a resolver problemas, todavia, isto não quer dizer que seja possível resolver todos os problemas de forma única. Quando se fala em IA, as soluções para os problemas são chamadas de modelos. Ao se analisar o exemplo dos carros autônomos de forma superficial, é possível identificar um modelo que realiza a detecção de objetos, automóveis e pessoas que estão na mesma via ou nas proximidades, a velocidade, entre várias outras características. A partir desses dados, torna-se necessária a utilização de outro modelo capaz de tomar decisões que levem o passageiro ao seu destino de forma segura.

Existem diferentes formas produzir os modelos na aprendizagem de máquina. Cada tipo de aprendizagem corresponde a diferentes tarefas, sendo os mais comuns o aprendizado supervisionado e o não supervisionado (AYODELE, 2010). O aprendizado supervisionado requer um conjunto de dados que apresente o dado a partir de um rótulo associado. Por exemplo, na estimativa do peso de um animal a partir das imagens, o dado seria a foto do animal e o rótulo o valor do peso. Isto é importante por que o aprendizado supervisionado utiliza-se dos rótulos para fazer correções no modelo de predição de acordo com o resultado de uma entrada específica (KOTSIANTIS; ZAHARAKIS; PINTELAS *et al.*, 2007). O método de aprendizado não supervisionado utiliza dados sem rótulos no treinamento, logo, sua aplicação serve para modelos com objetivos diferentes. Este pode ser utilizado para detecções de anomalias em um conjunto de dados por meio de algoritmos de agrupamentos, entre outros (USAMA *et al.*, 2019).

2.2.1 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) podem ser definidas como estruturas compostas por uma grande quantidade de elementos interconectados, chamados de neurônios, onde cada um destes elementos realiza processamentos simples (BASHEER; HAJMEER, 2000). A inspiração reside no comportamento do cérebro humano, que possui bilhões de neurônios interconectados para o funcionamento do sistema nervoso.

Uma das RNAs mais conhecidas é o Perceptron de Multicamadas (do inglês Multilayer Perceptron - MLP) que consiste de três tipos de camadas, a de entrada, a oculta e a de saída. Cada camada é composta por neurônios artificiais conectados na camada à sua frente e estas conexões recebem um peso, conhecidos como pesos sinápticos, que representam o quanto cada neurônio influencia no valor de saída do modelo (LORENCIN *et al.*, 2020). De maneira geral, esta arquitetura de rede realiza a predição da seguinte forma: (a) cada neurônio da camada de entrada é multiplicado pelo peso atribuído a conexão dele e o neurônio da camada oculta; (b) o valor obtido por todas as multiplicações é então somado e adicionado a um valor de *bias*; (c) o valor resultante é submetido a função de ativação que determina o valor de saída do neurônio; (d) este valor é passado para a próxima camada oculta e o processo se repete até chegar na última camada (CANAL *et al.*, 2022). A equação que descreve a operação realizada em cada neurônio é apresentada na Equação 1. As MPLs são treinadas utilizando um tipo de aprendizado supervisionado chamado de *backpropagation*. Ao obter um resultado, é calculado o erro do valor predito e este é utilizado para ajustar os pesos sinápticos das conexões (HEIDARI *et al.*, 2019). Com o *backpropagation*, tais ajustes são realizados nas camadas mais próximas a camada

de saída em direção à camada de entrada.

$$y_j = f \left(\sum_{i=1}^n (w_{ij} I_i) + b \right) \quad (1)$$

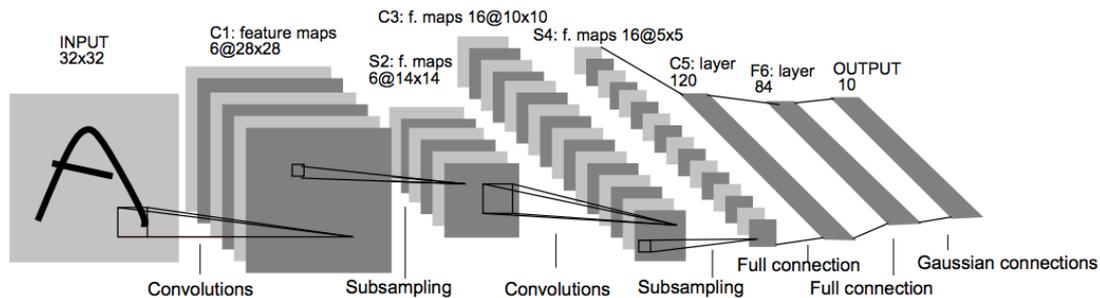
onde y_j é o valor de saída de um neurônio j , f a função de ativação, n representa o número de entradas, w_{ij} o peso da conexão, I_i a variável de entrada e b o bias.

2.2.2 Aprendizagem Profunda

Aprendizagem Profunda (do inglês *Deep Learning* - DL) é um ramo dentro da área de ML, que trata de aprendizados profundos. Este tipo de aprendizado recebe este nome, pois os modelos que aplicam esta técnica possuem várias camadas ocultas, logo uma rede profunda. Uma das maiores vantagens do DL é que os modelos realizam interpretações e criam hipóteses sobre os dados de forma autônoma, conseguindo solucionar relações não lineares de forma eficiente (DONG; WANG; ABBAS, 2021).

O contexto em que a DL se encaixa neste trabalho reside em uma de suas arquiteturas, as Redes Neurais Convolucionais (do inglês *Convolutional Neural Network* - CNN). O funcionamento de uma CNN é parecida com a do MLP. A principal diferença reside nos tipos de camadas ocultas, sendo essas a camada de convolução, *pooling*, e camada densa. Essas camadas podem ser vistas na LeNet-5, uma rede neural convolucional apresentada em (LECUN *et al.*, 1998). Esta rede foi introduzida com o objetivo de identificar dígitos escritos a mão e, para tal, possui 7 camadas (excluindo a camada de entrada) como pode ser visto na Figura 3.

Figura 3 – Arquitetura da rede LeNet-5



Fonte: Lecun *et al.* (1998).

2.2.2.1 Camada de Convolução

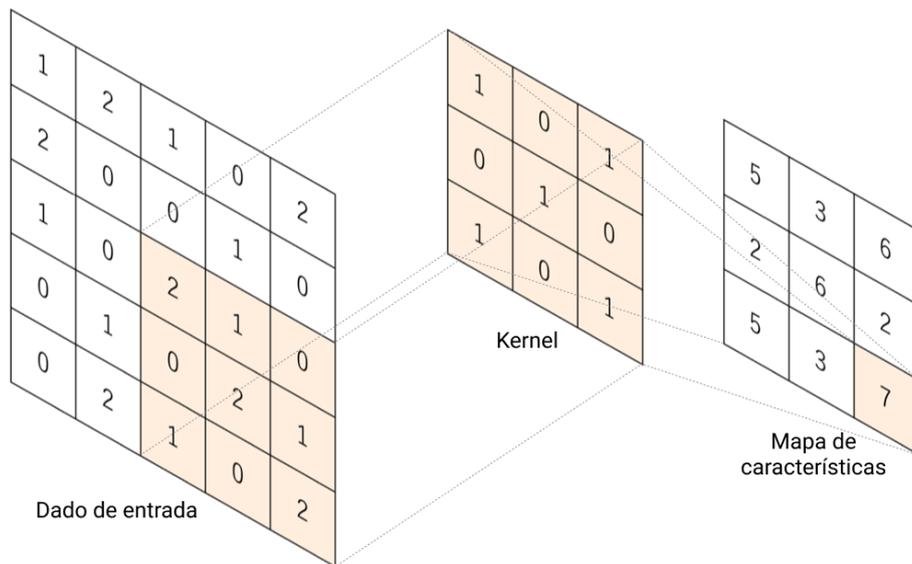
A camada de convolução representa o diferencial das CNNs, visto que auxilia na extração de características aplicando a função de convolução. Esta função é uma operação linear entre um *kernel* (k), ou filtro de convolução, e os dados de entrada. O *kernel* é aplicado sobre cada posição dos dados de entrada e realiza a soma para obter o valor resultante, o qual é utilizado para a formação dos mapas de características (*feature maps*) (YAMASHITA *et al.*, 2018). A equação que demonstra tal operação pode ser vista abaixo na Equação 2.

$$Y_{ij} = f \left(\sum_{i=1}^k \sum_{j=1}^k (X_{ij} * K) + b \right) \quad (2)$$

onde Y representa o valor de saída da convolução, X o valor de entrada, K o *kernel* da convolução, k as dimensões do *kernel*, b o *bias* e f a função de ativação.

O *kernel* de convolução, como pode ser observado no exemplo da Figura 4, reduz a dimensão dos dados durante a formação dos mapas de características (ZHANG, Q. *et al.*, 2019). Isso é útil para a redução de parâmetros de treinamento, pois quando são utilizadas imagens com resolução elevada são gerados vários parâmetros de treinamento para a rede. Por outro lado, se a convolução for aplicada repetidamente, a cada aplicação será reduzida a dimensão dos dados. Para contornar isso, pode ser aplicada uma margem de zeros ao redor dos dados de entrada (YAMASHITA *et al.*, 2018), como pode ser visto na Figura 5, em que o mapa de características terá as mesmas dimensões dos dados de entrada.

Figura 4 – *Kernel* 3x3 aplicado a uma entrada 5x5 produzindo um mapa de características 3x3



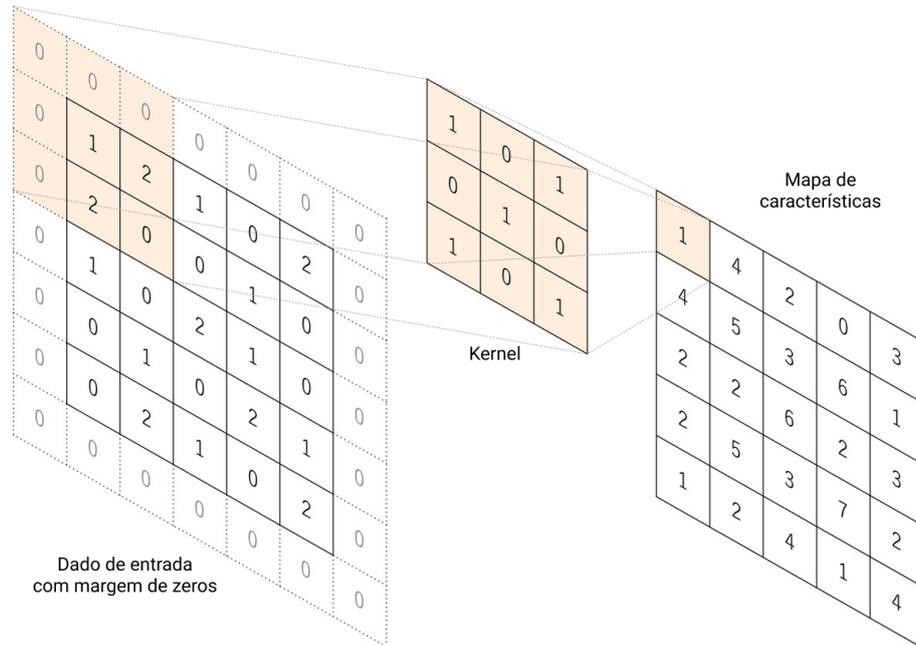
Fonte: Adaptado de Yamashita *et al.* (2018).

Após a aplicação da convolução, faz-se necessária a aplicação de uma função de ativação aos dados obtidos. Essas funções introduzem uma não linearidade à rede e auxiliam na captura de relações não lineares dos dados (ZHANG, Q. *et al.*, 2019). Elas possuem uma função importante ao definir se o neurônio será ativado ou não, passando ou não os dados para a próxima camada. Entre as funções típicas utilizadas para ativação constam: tangente hiperbólica, sigmoid e ReLU (*Rectified Linear Units*) (GU *et al.*, 2018).

2.2.2.2 Camada de Pooling

As camadas de convolução são normalmente seguidas por uma camada de *pooling*, também chamada de *subsampling*. Isto pode ser observado na LeNet-5 nas camadas S2

Figura 5 – *Kernel* 3x3 aplicado a uma entrada 5x5 com margem de zeros produzindo um mapa de características 5x5



Fonte: Adaptado de Yamashita *et al.* (2018).

e S4 (Figura 3). O papel delas em uma rede convolucional é reduzir a dimensão dos parâmetros dos mapas de características e, realizando isso, o modelo se torna menos sujeito a pequenas distorções, reduzindo também os parâmetros que são aprendidos pelo modelo (YAMASHITA *et al.*, 2018; ZHANG, Q. *et al.*, 2019).

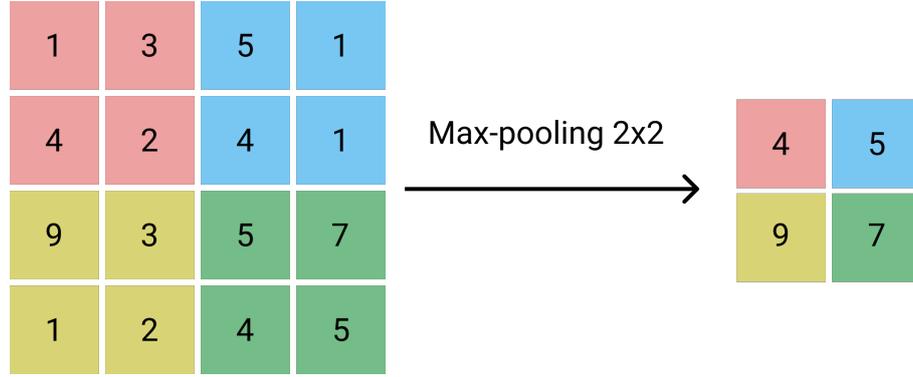
Existem diferentes tipos de *pooling*, sendo os mais comuns o *max-pooling* e *mean-pooling*. *Max-pooling* objetiva extrair o maior valor relativo a uma área do dado que está sendo processado; já o *mean-pooling*, como o nome sugere, extrai a média da área em que este é aplicado (TIAN *et al.*, 2021; ALBAWI; MOHAMMED; AL-ZAWI, 2017; CHEN *et al.*, 2022). O tamanho mais comum para a aplicação de *pooling* é 2x2 com um deslocamento de 2, produzindo uma redução nas dimensões de duas casas.

A Figura 6 mostra um exemplo de aplicação de *max-pooling*, com um filtro 2x2 em um mapa de características 4x4. O filtro é aplicado em cada um das seções, identificadas por diferentes cores, realizando a separação do maior elemento e gerando um novo dado com uma dimensão menor.

2.2.2.3 Camada Densa

A camada densa, ou completamente conectada, recebe este nome por causa de seu funcionamento. Esta camada tipicamente recebe os mapas de características, visto que após serem processados pela camada de convolução ou *pooling*, os mapas são convertidos de duas dimensões (2D) para uma dimensão (1D). Neste processo cada valor é conectado a todos os neurônios da camada densa e cada uma das conexões gera um parâmetro treinável (YAMASHITA *et al.*, 2018; ZHANG, Q. *et al.*, 2019).

Figura 6 – Aplicação de *max-pooling* em um mapa de característica 4x4 reduzindo-o para 2x2



Fonte: Elaborado pelo autor (2022).

A grande desvantagem desta camada é o grande número de parâmetros treináveis gerados por ela, pois estes possuem um elevado custo computacional durante o treinamento devido ao seu volume. Uma técnica utilizada para contornar tal deficiência é a utilização de uma camada de *dropout*, que desativa aleatoriamente alguns neurônios durante a etapa de treinamento ajudando, inclusive, a evitar o problema de *overfitting*. Assim como as camadas de convolução, as camadas densas são seguidas por uma função de ativação não linear, como por exemplo, a função ReLU (ALBAWI; MOHAMMED; AL-ZAWI, 2017).

2.2.2.4 Métodos de Avaliação dos Modelos

A avaliação dos modelos de predição ocorre após o processo de treinamento e validação, ou seja, na etapa de teste. Nesta etapa, são submetidas ao modelo gerado pelas redes neurais dados não utilizados anteriormente de modo que se possa aferir o desempenho. As métricas de avaliação utilizadas para problemas de regressão são diferentes das utilizadas para classificação, pois não é possível realizar a contagem dos erros visto que o resultado é um valor contínuo. Para avaliar um modelo de regressão é necessário analisar a diferença entre o valor real e o valor esperado. Neste estudo, foram utilizadas as métricas *Root Mean Square Error* (RMSE) e *Mean Absolute Percentage Error* (MAPE).

A métrica RMSE pode ser vista na Equação 3. Nela é calculada a soma do quadrado das diferenças entre o valor real e o valor predito do peso do animal, dividido pelo número de amostras do conjunto. Na prática esta métrica possibilita indicar o erro médio em quilos. A métrica MAPE (Equação 4) representa a média absoluta da porcentagem de erro dos dados retornados pelo modelo.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4)$$

Em ambas equações, n representa o número de observações do conjunto de teste, y_i é o valor real do peso e \hat{y}_i é o valor predito do peso pelo modelo.

3 Trabalhos Correlatos

Em buscas realizadas na literatura foram encontrados diversos trabalhos que tratam sobre a estimativa do peso de animais. Em sua grande maioria se utilizam de câmeras 3D devido a maior quantidade de informações fornecidas por elas. O método mais comum para o tratamento das informações obtidas dos animais foram modelos de múltiplas regressões lineares, devido à alta correlação das características físicas dos animais com o seu peso. Trabalhos recentes também apresentam técnicas envolvendo redes neurais convolucionais, ou variações desta arquitetura, onde é possível realizar o tratamento da imagem por completo sem a necessidade de extração de características. As buscas foram realizadas nos portais *ScienceDirect*[®], *IEEE Xplore*[®], Periódicos CAPES[®] e *Scopus*[®], utilizando combinações das seguintes palavras-chave: "cattle", "weight", "prediction", "estimation", "machine learning", "deep learning", "regression", "computer vision".

- No trabalho de Cominotte *et al.* (2020), os autores apresentaram um estudo para acompanhamento de ganho diário de peso e a predição de peso de gado da raça Nellore desde o desmame (8 meses de idade) até o fim do confinamento (25 meses de idade). Para tal, foram capturadas 234 imagens no decorrer dos 17 meses utilizando uma câmera 3D Kinect[®] modelo 1473, sendo que o peso de cada animal foi obtido através de uma balança mecânica. As imagens passaram por um pré-processamento na ferramenta Matlab[®] e, posteriormente, por três etapas de processamento: (a) estimativa da distância do chão até a câmera; (b) segmentação dos animais; e (c) extração das características. Das imagens processadas, foram extraídas 25 características sendo elas: área do dorso do animal, volume, comprimento, 11 medidas de largura e 11 medidas de altura ambas obtidas de diferentes partes do dorso do animal. O estudo então propõem um comparativo entre 4 modelos de ML aos quais são submetidas as características obtidas das imagens, sendo eles: Múltiplas Regressões Lineares, *Least Absolute Shrinkage and Selection Operator* (LASSO), *Partial Least Squares* (PLS) e um modelo de RNA. As métricas de avaliação dos modelos foram RMSE e R^2 . O modelo que obteve o melhor resultado foi o de RNA com uma média de 9.23kg de RMSE e 0.87 de R^2 para a predição do peso dos animais.
- No estudo Miller *et al.* (2019) foi proposta uma solução para a predição do peso de animais de diferentes raças fazendo uso de imagens 3D. A ideia apresentada consiste na extração, em tempo real, de 60 características dos animais, sendo: 5 medidas de largura, 6 medidas de comprimento, 5 medidas de alturas e 2 diagonais, além disso, também são calculadas 20 relações, 11 áreas e 11 volumes. Adicionalmente, na coleta de características foram anotados o sexo e a raça do animal. O estudo apresenta uma análise de relevância de cada característica obtida em relação ao peso, sendo que a altura da cernelha (parte frontal do animal, próximo ao pescoço) apresentou maior relevância. Para a predição do peso foi utilizado um modelo de RNA com aprendizado supervisionado e as métricas de avaliação formam R^2 e *RMSE*. Os resultados obtidos foram R^2 de 0.7 e *RMSE* de 42kg.
- A solução proposta por Martins *et al.* (2020) pode ser comparada a do estudo de Miller *et al.* (2019). Foram utilizadas câmeras 3D Microsoft Kinect[®] V2 Model 1473 para a captura das imagens sincronizadas com a ferramenta Matlab[®]. A pesagem dos animais para realização do controle e elaboração do conjunto de dados foi realizada a cada 28 dias durante 5 meses às 6 horas da manhã, antes que os animais se alimentassem. As imagens foram processadas utilizando Matlab[®] que, para imagens

do dorso do animal, extraiu as seguintes características: largura do tórax, largura do abdômen, largura e comprimento da dorsal. Com a junção destas variáveis com a área região da dorsal do animal foi possível obter uma equação que faz a estimativa do peso do animal com um R^2 de 0.96 e $RMSE$ de 26.89kg.

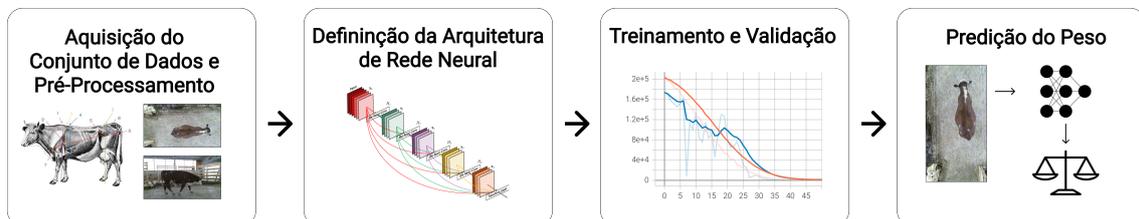
- Em Gjergji *et al.* (2020) são utilizadas diferentes combinações de *Recurrent Attention Model* (RAM) e CNNs para a predição de peso de animais da raça Nellore e Angus. Para realizar a estimativa do peso, foram coletadas imagens dos animais com câmeras posicionadas acima do bebedouro dos mesmos. Diferente de Cominotte *et al.* (2020), neste trabalho não são extraídas as características das imagens e sim a imagem inteira é submetida aos modelos de RNA. O modelo que obteve o melhor resultado fez uso da arquitetura EfficientNetB1, que é uma variação de implementação de CNN que possui otimizações em sua profundidade, largura e resolução de entrada. Este modelo atingiu um *Mean Absolute Error* (MAE) de 23.19kg.
- Dohmen, Catal e Liu (2021b) propõem uma forma de estimar o peso de novilhas em duas etapas. Primeiramente, produzindo uma segmentação do animal e posteriormente a predição do peso. Para este estudo, foram coletadas imagens 2D da parte superior e lateral de 63 novilhas com idade entre 0 até 356 dias. Estas imagens foram primeiramente processadas por uma Mask-RCNN que faz a segmentação dos animais e remoção do fundo. Na sequência, as imagens segmentadas foram submetidas a um modelo de CNN para estimar o peso. As métricas de avaliação utilizadas foram R^2 , MAPE e RMSE. Os resultados obtidos por este estudo foram promissores, apresentando um R^2 de 0.97, MAPE de 11% e RMSE de 19.57kg para a visão superior e um R^2 de 0.91, MAPE de 10% e RMSE de 26.68kg para a visão lateral.
- Jianlong Zhang *et al.* (2021) tratam da estimativa do peso e dimensões de porcos. Este estudo faz uso de imagens em 3 dimensões obtidas com uma câmera Intel RealSense® D435. Para efetuar a predição do peso são utilizados como base 4 modelos de classificação sendo eles: DenseNet201, ResNet152 V2, Xception, and MobileNet V2. Cada um destes modelos passou por um processo de ajustes (*fine tuning*) para ter uma saída de regressão ao invés de classificação. O estudo apresentou resultados expressivos, sendo que a arquitetura Xception obteve o melhor resultado, com um R^2 de 0.997, um RMSE de 1.53kg e um MAE de 1.16kg para a estimativa do peso. Além disso, também foram obtidos bons resultados para a estimativa das medidas do animal.
- Uma abordagem utilizando câmeras termográficas é apresentada pelos autores Stajanko *et al.* (2022). A câmera utilizada foi a AGEMA 570 (Flir Systems™) que captura imagens com resolução de 320x240 pixels. A coleta dos dados foi realizada em um local com paredes de concreto, que habilitam uma diferença de temperatura entre o animal e o ambiente ao seu redor, destacando-o mais na imagem. A extração das características das imagens foi efetuada da seguinte forma: (a) foram aplicadas duas máscaras nas imagens, uma delas para localizar a cauda do animal e outra a pata dianteira; (b) na sequência foram determinadas duas áreas de interesse (do inglês *Region of Interest* - ROI) envolvendo o quadril e a cernelha do animal; (c) das ROIs foram extraídas medidas para a altura do quadril e a altura da cernelha. As alturas obtidas foram submetidas a modelos de regressão, o primeiro utilizando apenas a altura do quadril, o segundo utilizando apenas a altura da cernelha e o terceiro utilizando as duas medidas juntas. O melhor resultado foi obtido pelo terceiro modelo apresentando um R^2 de 0.798.

- Por fim, em Song *et al.* (2018), como apresentado previamente, o método proposto para a extração das características foi por meio de uma modelagem do dorso dos animais (Figura 2). Para que isso fosse possível, foram utilizadas câmeras 3D para capturar as imagens dos animais que foram processadas utilizando o Matlab[®]. Ao total foram extraídas três características: altura do quadril, largura do quadril e comprimento da dorsal. Ao realizar a captura das imagens foi anotado também a idade do animal, número de gestações e DIM. Todas as medidas e características foram submetidas a modelos de múltiplas regressões lineares. O modelo que se destacou foi o que utilizou apenas largura do quadril, DIM e número de gestações apresentando um *RMSE* de 41.2kg e um *MAPE* de 5.2%.

4 Método Proposto

O método proposto por este trabalho fundamenta-se na análise de informações não estruturadas na forma de imagens com o intuito de estimar o peso de gado de corte. De modo geral, o método é composto por quatro etapas, apresentadas na Figura 7. A primeira etapa representa a obtenção do conjunto de dados e, a partir disso, o pré-processamento visando tornar cada imagem adequada para a etapa seguinte. Na sequência, a segunda etapa tem o intuito de definir determinada arquitetura de rede neural capaz de atingir o objetivo central do trabalho. A terceira etapa é responsável pela realização do treinamento e validação da rede neural definida na etapa anterior e, assim como gerar o modelo de predição. Por fim, a quarta e última etapa, permite que o modelo realize a predição a partir de determinada imagem de um animal.

Figura 7 – Fluxo dos processos utilizados no método proposto



Fonte: Elaborado pelo autor (2022).

4.1 Etapa 1: Aquisição do Conjunto de Dados e Pré-Processamento

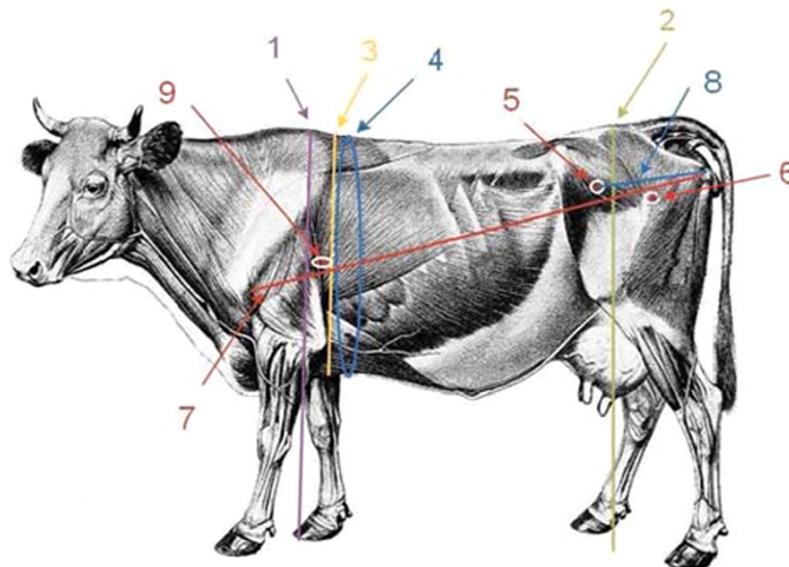
Esta etapa é responsável por um conjunto de passos visando garantir as corretas condições para que o método produza resultados adequados quanto à estimativa do peso de gado de corte. Para tal, torna-se necessário a coleta do conjunto de dados, assim como o seu pré-processamento.

4.1.1 Conjunto de Dados

O conjunto de dados utilizado para a realização deste trabalho foi obtido durante a etapa de revisão da bibliografia. Ele é apresentado em Ruchay *et al.* (2020) na proposta da extração das características de gado de corte por meio de um modelo 3D do animal. Estes dados foram coletados em agosto de 2019 em uma fazenda Russa. Imagens 2D e 3D da vista lateral e superior de 103 animais da raça *Hereford* foram coletadas. Como o objetivo era a extração automática das características dos animais, foram extraídas manualmente

10 características para comparativo com os dados obtidos pelas medições a partir das imagens. Exemplos dessas características podem ser vistas na Figura 8, sendo: peso, altura da cernelha, altura do quadril, profundidade do peitoral, perímetro do peitoral, largura do ílio, largura do ligamento do quadril, comprimento do corpo, comprimento do quadril e profundidade do peitoral.

Figura 8 – Altura da cernelha (1), altura do quadril (2), profundidade do peitoral (3), perímetro do peitoral (4), largura do ílio (5), largura do ligamento do quadril (6), comprimento do corpo (7), comprimento do quadril (8) e profundidade do peitoral (9)



Fonte: Ruchay *et al.* (2020).

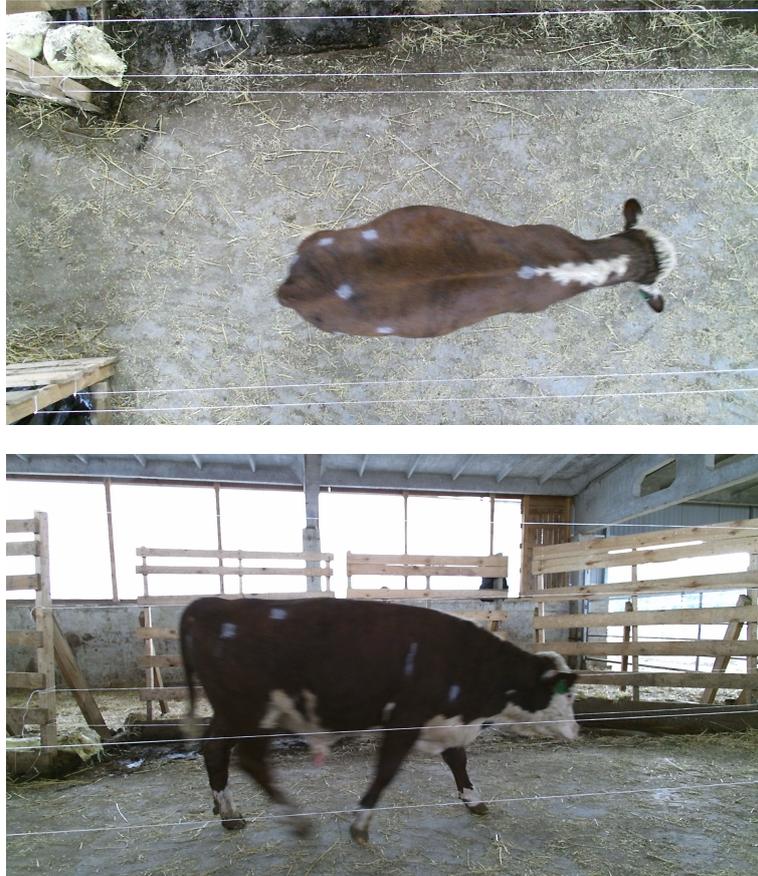
O valor de cada uma das 10 características para cada um dos 103 animais foi disponibilizado, juntamente com as imagens, da vista superior e lateral, com identificadores para estabelecer a relação das características com as imagens correspondentes. As primeiras 5 entradas do conjunto de dados podem ser vistas na Tabela 1 e um exemplo das imagens disponibilizadas pode ser visto na Figura 9.

Tabela 1 – Cinco primeiras entradas do conjunto de dados utilizado no estudo

	P	AC	AQ	PP	LP	LI	LLQ	C	CQ	CP
N	[kg]	[cm]								
1	415	117	122	62	40	43	42	145	43	172
2	407	116	121	60	30	42	44	127	37	171
3	448	114	121	60	43	41	40	128	41	176
4	443	118	123	63	46	44	44	150	46	176
5	410	124	127	66	41	42	44	140	45	178

Fonte: Ruchay *et al.* (2020).

Figura 9 – Imagens capturadas da visão superior e da visão lateral



Fonte: Ruchay *et al.* (2020).

4.1.2 Pré-processamento

Apesar do conjunto de dados utilizado neste trabalho disponibilizar características previamente extraídas, somente as imagens foram consideradas, visto que a proposta reside na utilização de imagens dos animais para a estimativa de peso. Neste sentido, o pré-processamento das imagens que servem de conjunto de entrada para o modelo neural pode ser considerado simples. A resolução das imagens é de 1920x1080, porém, em função das arquiteturas de redes neurais utilizadas para os experimentos, estas foram redimensionadas. Neste trabalho duas arquitetura serão utilizados (Etapa 2). Para a primeira arquitetura, considerada a principal, a resolução das imagens foi alterada para 224x224, enquanto que para a segunda arquitetura (utilizada para a realização de comparações com a arquitetura principal definida na Seção 4.2) as imagens foram redimensionadas para 455x256.

4.2 Etapa 2: Definição da Arquitetura de Rede Neural

Para esta etapa torna-se requerida a definição de uma arquitetura de rede neural visando produzir o modelo de predição. Neste sentido, a arquitetura escolhida foi a *Dense Convolutional Network (DenseNet)*, originalmente treinada com o conjunto de dados *ImageNet*, que é muito utilizado como métrica de desempenho para modelos de

estado da arte, devido à grande variedade de classes e amostras disponibilizadas. Como o modelo *DenseNet* é um modelo de classificação, foram realizadas algumas modificações em suas camadas finais para se obter uma saída de regressão, ou seja, uma saída numérica indicando a estimativa do peso de determinado animal. Para a implementação foi utilizada a biblioteca Tensorflow[®] disponível para a linguagem de programação Python[®]. A biblioteca disponibiliza uma variedade de funcionalidades como camadas convolucionais e densas, funções de ativação, funções de custo e também modelos com estruturas já implementadas como a *DenseNet*. Além disso, a biblioteca Tensorflow[®] disponibiliza uma API (*Application Programming Interface*) que possibilita o treinamento da rede com o uso de GPUs (*Graphics Processing Units*) tornando o processo mais eficiente.

4.2.1 Estrutura e Funcionamento da Rede Neural

Como mencionado, a estrutura utilizada como base para o desenvolvimento da arquitetura de rede neural foi a *DenseNet*. Esta arquitetura foi apresentada em 2017 com um funcionamento diferente do convencional, visto que a rede é separada em blocos densos. Nesses blocos existem camadas de convolução em que cada camada está conectada a todas as camadas subsequentes, fazendo com que o número de conexões seja maior do que o convencional de uma rede convolucional. A equação que descreve o número de conexões C de um bloco denso de comprimento L pode ser vista na Equação 5.

$$C = \frac{L(L+1)}{2} \quad (5)$$

Para compreender melhor como são processadas as imagens em uma *DenseNet*, considera-se uma imagem x_0 que passa por uma rede convolucional com L camadas. Cada uma dessas camadas faz uso de uma transformação não linear $H_l(\cdot)$, onde l é o índice da camada. Essa transformação não linear pode ser representada por operações de *BatchNormalization* (BN), ReLU, *Pooling* ou convolução. Segundo Huang *et al.* (2017), para aumentar o fluxo de informações entre as camadas, a conexão direta de cada camada para as camadas subsequentes é implementada na *DenseNet*. A Figura 10 ilustra essas conexões.

A equação que descreve o processo ilustrado pela Figura 10 para uma camada l pode ser vista na Equação 6.

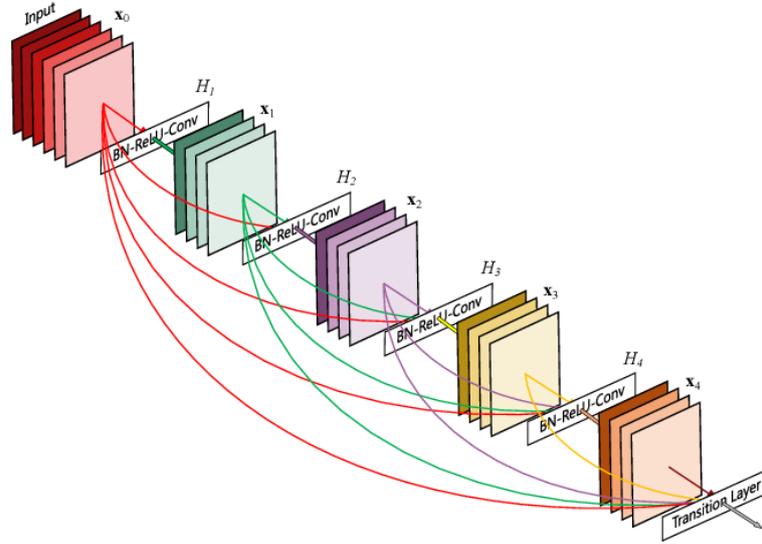
$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (6)$$

onde x_l são os mapas de características da camada l e $[x_0, x_1, \dots, x_{l-1}]$ representam a concatenação dos mapas de características das camadas anteriores.

Conforme consta na Seção 2, um elemento importante para a utilização de camadas convolucionais é a redução das dimensões das características dos dados. Porém, como a saída de cada camada é utilizada como entrada para a próxima, esta redução não pode acontecer. Por isso, dentro de cada bloco denso nas convoluções com *kernel* 3x3 é aplicada uma margem de zeros ao redor da imagem para evitar a redução das características, como exemplificado pela Figura 5.

A *DenseNet* treinada com o conjunto de dados *ImageNet* foi estruturada com 4 blocos densos. A conexão entre cada um deles é realizada por uma camada de transição, que contém uma camada de *BatchNormalization* e uma camada convolucional com *kernel*

Figura 10 – Bloco denso com 5 camadas onde cada camada recebe mapas de características de todas as camadas anteriores a ela



Fonte: Huang *et al.* (2017).

1x1, seguida por uma camada de *mean-pooling* 2x2. Na Figura 11 podem ser vistas 4 variações do modelo treinado no conjunto de dados *ImageNet*. O modelo base para este trabalho foi o *DenseNet-201*.

Figura 11 – Quatro variações do modelo *Densenet* que foram aplicadas no conjunto de dados *ImageNet* para obter uma métrica de desempenho da rede

Layers	Output Size	DenseNet-121 ($k = 32$)	DenseNet-169 ($k = 32$)	DenseNet-201 ($k = 32$)	DenseNet-161 ($k = 48$)
Convolution	112×112	7×7 conv, stride 2			
Pooling	56×56	3×3 max pool, stride 2			
Dense Block (1)	56×56	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	56×56	1×1 conv			
	28×28	2×2 average pool, stride 2			
Dense Block (2)	28×28	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	28×28	1×1 conv			
	14×14	2×2 average pool, stride 2			
Dense Block (3)	14×14	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 36$
Transition Layer (3)	14×14	1×1 conv			
	7×7	2×2 average pool, stride 2			
Dense Block (4)	7×7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$
Classification Layer	1×1	7×7 global average pool			
		1000D fully-connected, softmax			

Fonte: Huang *et al.* (2017).

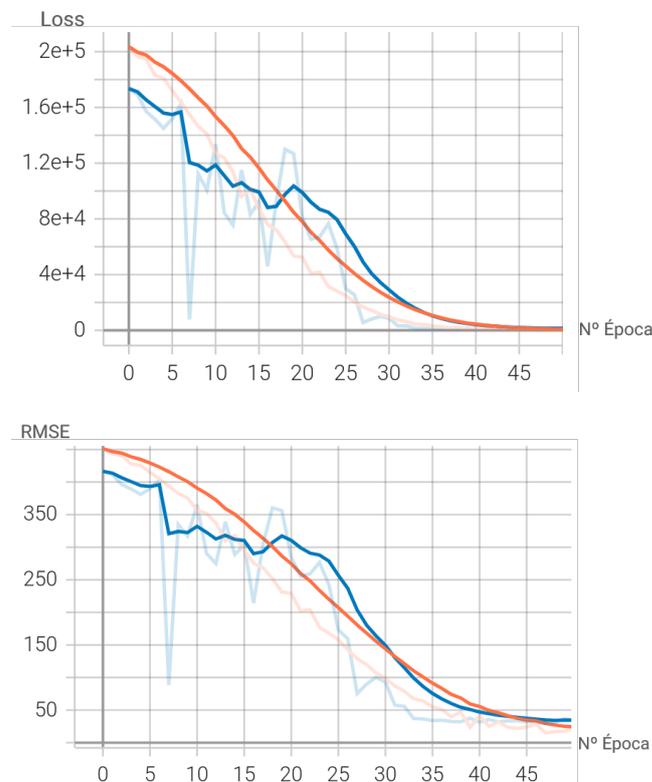
4.3 Etapa 3: Treinamento e Validação

A etapa de treinamento e validação é uma das mais importantes de todo o desenvolvimento do método proposto. Durante o processo de treinamento a rede ajusta os pesos das conexões entre as camadas de forma a alcançar um resultado mais próximo ao esperado. Para que a avaliação do modelo seja considerada correta, o conjunto de dados foi separado em duas partes, sendo uma para o treinamento e outra para os testes da rede. Durante o treinamento, para realizar os cálculos de erro e ajustes da rede, é necessário separar uma porção do conjunto de treinamento. Logo, de maneira iterativa, a cada época ocorre a separação do conjunto de treinamento em 2 (duas) partes, uma para o treinamento e outra para a validação.

O conjunto de dados foi separado em porções de 90% e 10%. Da parte de 90%, 20% foi utilizado para validação durante o treinamento e os 80% restantes foram utilizados para o treinamento. A parte de 10% foi utilizada apenas para a fase de teste.

O processo de treinamento foi relativamente rápido, levando em torno de 15 minutos para o modelo convergir. O modelo foi treinado por um total de 50 épocas e duas métricas de avaliação foram utilizadas durante esta etapa. O histórico de treinamento do modelo pode ser visto na Figura 12, onde a linha laranja representa o treinamento e a azul representa a validação.

Figura 12 – Imagem superior representando o *loss* por época do modelo baseado em MSE e a imagem inferior representando o RMSE calculado para cada época do treinamento



Fonte: Elaborado pelo autor (2022).

4.4 Etapa 4: Predição do Peso

Após a etapa de treinamento e validação produz-se, como resultado do processo, um modelo de predição de peso de gado. O modelo deve ser avaliado através de uma etapa de teste em que novas instâncias, ou seja, imagens não utilizadas na produção do modelo são utilizadas para verificar se o mesmo consegue realizar adequadamente a tarefa de predição. Conforme mencionado na seção anterior o conjunto de teste é representado por 10% do conjunto total. Nesta etapa, também são utilizadas duas métricas com o intuito de verificar o comportamento final do modelo, isto é, o resultado quanto ao erro em quilos e percentual.

Uma vez que o modelo tenha sido testado, este pode então ser utilizado por diferentes aplicações de modo que, considerando determinada imagem de entrada, seja provida como saída o peso estimado de determinado animal.

5 Resultados Experimentais

5.1 Experimentos Realizados

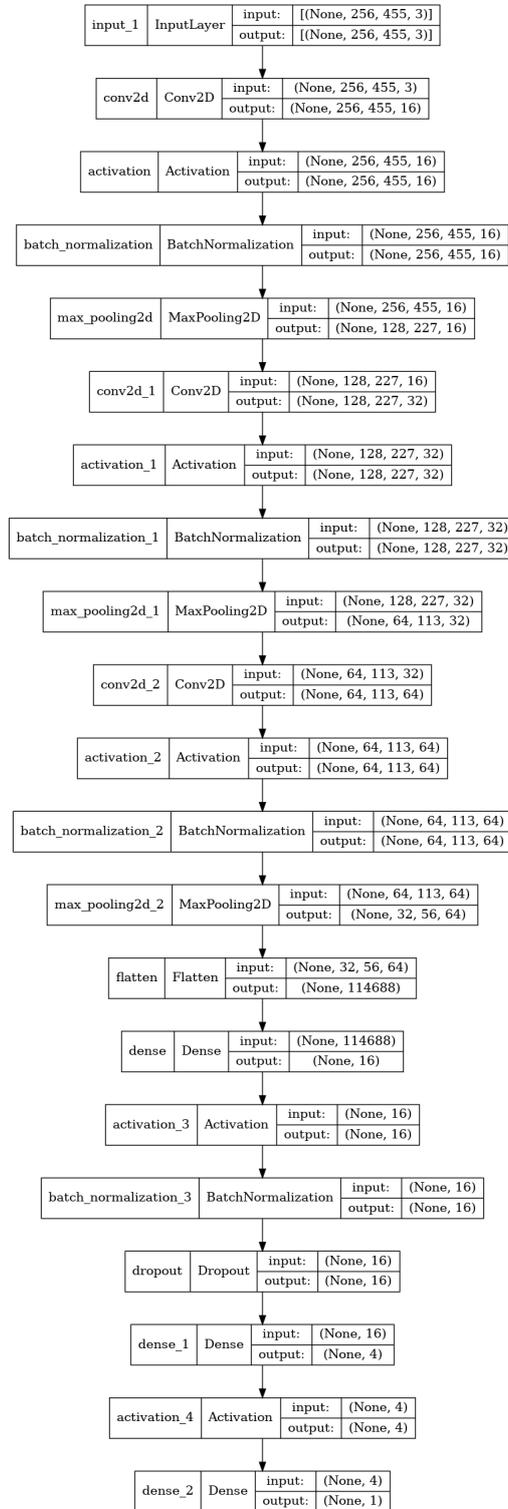
Inicialmente, para a realização dos testes das CNNs aplicadas na estimativa do peso de gado, foi utilizada uma arquitetura de rede neural sequencial simples. Esse modelo foi implementado com 3 camadas convolucionais, cada uma delas seguidas por uma camada de ativação, uma camada de *BatchNormalization* e *max-pooling* (Figura 13).

Na sequência, utilizou-se também uma arquitetura *DenseNet*, todavia, com algumas alterações. Originalmente as variações da rede *DenseNet* apresentadas na Figura 11 tratam de um problema de classificação. Pode ser visto que as últimas duas camadas da rede, camada de *mean-pooling 7x7* e a camada densa com 1000 nodos, são utilizadas para tarefas de classificação do conjunto de dados *ImageNet* que possui 1000 classes. Como o presente trabalho trata de um problema de regressão, essas duas camadas foram substituídas por uma camada de *global average pooling 2D* e uma camada densa com um único nodo, visto que a saída esperada do modelo é apenas o valor do peso do animal. Após estas alterações a estrutura final do modelo ficou conforme apresentado na Figura 14.

Como o conjunto de dados obtido continha poucas amostras para treinamento, foram realizados diferentes testes de *data augmentation* como tentativas de aprimoramento no desempenho dos modelos propostos. As duas estruturas supracitadas foram submetidas a 3 testes. O primeiro foi o processo de treinamento com o conjunto de dados sem nenhuma alteração. O segundo teste realizado foi aplicando um espelhamento no eixo x nas imagens do conjunto de dados, dobrando o número de imagens de 103 para 206. Por fim, o terceiro teste foi aplicando um espelhamento randômico entre eixo x e eixo y seguido por rotações aleatórias de -54° a $+54^\circ$. Isto foi realizado 3 vezes para cada imagem, totalizando 4 variações da mesma imagem e um total de 412 imagens.

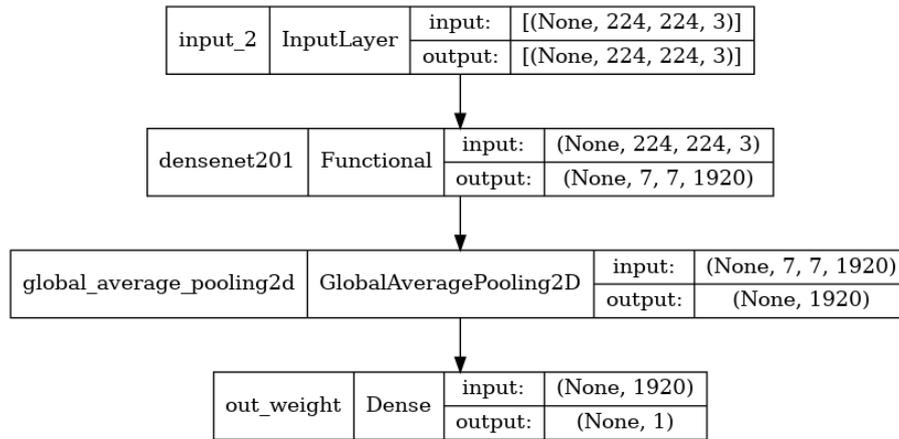
Por fim, menciona-se que o ambiente de desenvolvimento do modelo foi composto por um processador AMD Ryzen™ 7 3700X com 8 núcleos de processamento e 16 threads acompanhado por 16GB de memória RAM 3200 Hz. Visto que o treinamento de redes convolucionais realiza uma quantidade extensa de cálculos, porém de complexidade baixa, utilizou-se uma GPU para realizar os processamentos em paralelo, o que resultou em um melhor desempenho. A GPU utilizada foi uma NVIDIA GeForce RTX™2060 com 6GB de memória GDDR6 e 1920 núcleos CUDA. Como mencionado anteriormente, o treinamento levou por volta de 15 minutos devido ao uso da GPU para esse processo.

Figura 13 – Representação da estrutura do modelo sequencial desenvolvido para a estimativa do peso de gado de corte



Fonte: Elaborado pelo autor (2022).

Figura 14 – Representação da estrutura da arquitetura da *DenseNet* para a estimativa do peso de gado de corte



Fonte: Elaborado pelo autor (2022).

5.2 Resultados dos Testes

Como apresentado anteriormente, foram realizados três testes para cada arquitetura de rede neural, sequencial e *DenseNet*. Para cada teste, (i) sem alterações no conjunto de dados; (ii) com espelhamento horizontal; e (iii) com espelhamentos e rotações, foram aplicadas as métricas RMSE e MAPE (subseção 2.2.2.4).

A Tabela 2 apresenta todos os resultados obtidos nos testes realizados com as variações das técnicas de *data augmentation*. Analisando os resultados é possível perceber que o desempenho do modelo de *DenseNet* foi superior ao do modelo sequencial na maioria dos testes, tendo um desempenho inferior apenas no RMSE do teste (iii). O melhor resultado para a *DenseNet* foi atingido quando aplicado o espelhamento horizontal no conjunto de dados, alcançando um *RMSE* de $\pm 35,67\text{kg}$ e um *MAPE* de 6,1%. Para o modelo sequencial o melhor valor alcançado de *RMSE* foi no conjunto de dados sem alterações chegando a $\pm 57,50\text{kg}$. Já para o *MAPE*, o melhor valor de 10,2% foi atingido quando aplicadas rotações e espelhamento aleatório no conjunto de dados.

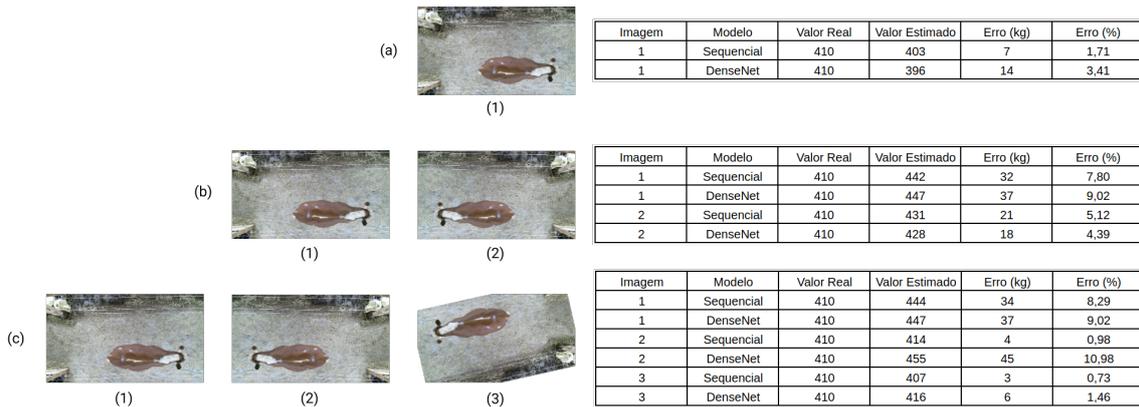
Tabela 2 – Resultados das métricas RMSE e MAPE para os testes realizados a partir de diferentes estratégias de *data augmentation* no conjunto de dados

Modelo	Sequencial	DenseNet
Sem alterações - RMSE	$\pm 57,50\text{kg}$	$\pm 49,41\text{kg}$
Espelhamento horizontal - RMSE	$\pm 77,50\text{kg}$	$\pm 35,67\text{kg}$
Espelhamentos e rotações - RMSE	$\pm 61,34\text{kg}$	$\pm 61,73\text{kg}$
Sem alterações - MAPE	10,8%	8,9%
Espelhamento horizontal - MAPE	11,9%	6,1%
Espelhamentos e rotações - MAPE	10,2%	10%

Fonte: Elaborado pelo autor (2022).

A título de exemplificação a Figura 15 apresenta as variações de uma imagem em cada uma das situações de teste com os respectivos erros e o pesos preditos. A parte identificada por (a) se refere ao conjunto de dados sem alterações. Na parte (b) é apresentado um exemplo do conjunto de dados com espelhamento horizontal e a parte (c) demonstra o teste com espelhamentos e rotação.

Figura 15 – Comparação entre valores preditos pelos dois modelos nos três testes realizados com o conjunto de dados



Fonte: Elaborado pelo autor (2022).

Pode-se reparar na Figura 15 que o modelo sequencial obteve um desempenho superior ao da *DenseNet* na maioria dos casos. No entanto esta análise é feita sobre uma baixa quantidade de dados, por isso não pode ser considerada como absoluta. O modelo sequencial atinge, para alguns casos, resultados excelentes, contudo, em outros, gera um erro expressivo afetando o resultado geral da avaliação. O mesmo acontece com a *DenseNet* na figura. Um exemplo pode ser visto na parte (c) da Figura 15 onde a *DenseNet* comete um erro maior do que 10% e quando aplicada a métrica RMSE resulta em um impacto considerável sobre a avaliação global dos resultados.

6 Considerações Finais e Trabalhos Futuros

Considerando a grande representatividade da pecuária para o Brasil, técnicas computacionais são cada vez mais pesquisadas e implementadas visando soluções para problemas relevantes que afetam o agronegócio. Entre estes problemas encontra-se a estimativa de peso de gado de corte com abordagens não intrusivas, prezando pelo bem-estar dos animais e, conseqüentemente, uma maior produtividade, visto que métodos tradicionais de aferição do peso impactam na rotina diária desses animais. Neste sentido, este trabalho propõe um método baseado em redes neurais convolucionais voltado à estimativa do peso de gado, visando facilitar o processo de monitoramento do peso dos animais em fazendas.

Para viabilizar o método utilizou-se um conjunto de dados de imagens coletadas conforme descrito na subseção 4.1.1. Este conjunto de dados possui 103 imagens e, apesar de ser considerado pequeno, possibilitou a avaliação geral do modelo. Cabe ressaltar que durante a realização do trabalho foram estabelecidos contatos a fim de viabilizar a coleta de dados em uma fazenda. Todavia, devido ao aprofundamento da pandemia da COVID-19,

esta etapa foi prejudicada. Neste sentido, a obtenção do conjunto de dados limitou-se à buscas na *web*. Pelo mesmo motivo não foi realizado nenhum tipo de implantação do método para realização de testes em situações reais.

Mesmo possuindo um conjunto de dados restrito, os resultados obtidos pelo método proposto são promissores na estimativa do peso de gado. Durante a fase de avaliação foram conduzidos três testes, sendo que o primeiro foi efetuado sem alterações nas imagens e, os outros dois, com alterações, através de espelhamentos e rotações nas imagens. Os melhores resultados foram atingidos pela rede neural *DenseNet*, com um RMSE de $\pm 35,67$ kg e um MAPE de 6,1% para a alteração de espelhamento horizontal. Os resultados obtidos neste estudo quando comparados aos trabalhos correlatos continuam relevantes mesmo sendo inferiores em alguns casos, pois em sua grande maioria os modelos do estado da arte utilizam câmeras 3D para a estimativa do peso, e pensando em aplicações reais essas câmeras são de custo mais elevado. Realizando um comparativo com o estudo de Dohmen, Catal e Liu (2021b), que aplica um método similar ao proposto neste trabalho, percebe-se que o resultado é inferior em relação ao RMSE ($\pm 35,67$ kg contra $\pm 19,57$ kg). Todavia, quando a análise é efetuada considerando o MAPE, o estudo citado obteve um erro percentual de 11% e no presente trabalho o erro atingiu 6,1%. Isto se explica visto que, em Dohmen, Catal e Liu (2021b), são consideradas novilhas, ou seja, animais mais leves, enquanto que para este estudo foram considerados animais de maior peso.

Apesar dos resultados obtidos serem promissores considerando as limitações apresentadas, melhorias podem ser realizadas neste sentido. A coleta de imagens de animais com variações de ângulos, por exemplo, traria uma representação mais adequada a situações reais.

Ainda que o objetivo deste trabalho tenha sido atingido, futuras pesquisas e desenvolvimentos podem ser conduzidas. Dentre as possibilidades, cita-se o desenvolvimento de um sistema para acompanhamento do peso de gado em ambiente real. O sistema necessitaria de câmeras instaladas nas fazendas que fizessem a coleta das imagens e o processamento das mesmas, armazenando o valor do peso estimado do animal para monitoramento. Uma adição interessante para o sistema que, possivelmente, melhoraria a capacidade de previsão do modelo de estimativa do peso, seria a aplicação de um modelo de detecção dos animais. Para a detecção poderia ser cortada e enviada apenas a imagem de determinado animal para o modelo neural estimar o peso, assim removendo partes da imagem que não são relevantes. Outra adição importante para o sistema seria uma forma de identificação do animal, possibilitando o acompanhamento individualizado do peso ao longo do tempo.

Referências

- ALBAWI, Saad; MOHAMMED, Tareq Abed; AL-ZAWI, Saad. Understanding of a convolutional neural network. In: IEEE. 2017 International Conference on Engineering and Technology (ICET). [S.l.: s.n.], 2017. P. 1–6.
- AYODELE, Taiwo Oladipupo. Types of machine learning algorithms. **New advances in machine learning**, InTech, v. 3, p. 19–48, 2010.
- BAO, Jun; XIE, Qiuju. Artificial intelligence in animal farming: A systematic literature review. **Journal of Cleaner Production**, v. 331, p. 129956, 2022. ISSN 0959-6526. DOI: <<https://doi.org/10.1016/j.jclepro.2021.129956>>. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0959652621041251>>>.
- BASHEER, I.A; HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. **Journal of Microbiological Methods**, v. 43, n. 1, p. 3–31, 2000. Neural Computing in Microbiology. ISSN 0167-7012. DOI: <[https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)>. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0167701200002013>>>.
- BERCKMANS, Daniel. Precision livestock farming technologies for welfare management in intensive livestock systems. **Revue scientifique et technique (International Office of Epizootics)**, v. 33, p. 189–96, abr. 2014. DOI: <10.20506/rst.33.1.2273>.
- CANAL, Felipe Zago *et al.* A survey on facial emotion recognition techniques: A state-of-the-art literature review. **Information Sciences**, v. 582, p. 593–617, 2022. ISSN 0020-0255. DOI: <<https://doi.org/10.1016/j.ins.2021.10.005>>. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0020025521010136>>>.
- CHEN, Jichi *et al.* Two-dimensional phase lag index image representation of electroencephalography for automated recognition of driver fatigue using convolutional neural network. **Expert Systems with Applications**, v. 191, p. 116339, 2022. ISSN 0957-4174. DOI: <<https://doi.org/10.1016/j.eswa.2021.116339>>. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0957417421016377>>>.
- COMINOTTE, A. *et al.* Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases. **Livestock Science**, v. 232, p. 103904, 2020. ISSN 1871-1413. DOI: <<https://doi.org/10.1016/j.livsci.2019.103904>>. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S1871141319310856>>>.
- COSTA, Joao H.C. *et al.* Key animal welfare issues in commercially raised dairy calves: social environment, nutrition, and painful procedures. **Canadian Journal of Animal Science**, v. 99, n. 4, p. 649–660, 2019. DOI: <10.1139/cjas-2019-0031>. eprint: <<https://doi.org/10.1139/cjas-2019-0031>>. Disponível em: <<<https://doi.org/10.1139/cjas-2019-0031>>>.
- DOHMEN, Roel; CATAL, Cagatay; LIU, Qingzhi. Computer vision-based weight estimation of livestock: a systematic literature review. English. **New Zealand Journal of Agricultural Research**, Royal Society of New Zealand, jan. 2021. ISSN 0028-8233. DOI: <10.1080/00288233.2021.1876107>.

DOHMEN, Roel; CATAL, Cagatay; LIU, Qingzhi. Image-based body mass prediction of heifers using deep neural networks. eng. **Biosystems engineering**, Elsevier Ltd, v. 204, p. 283–293, 2021. ISSN 1537-5110.

DONG, Shi; WANG, Ping; ABBAS, Khushnood. A survey on deep learning and its applications. **Computer Science Review**, v. 40, p. 100379, 2021. ISSN 1574-0137. DOI: <<https://doi.org/10.1016/j.cosrev.2021.100379>>. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S1574013721000198>>>.

EMBRAPA. [S.l.: s.n.], 2020.

<<https://www.embrapa.br/documents/10180/62618376/O+AGRO+NO+BRASIL+E+NO+MUNDO.pdf/41e20155-5cd9-f4ad-7119-945e147396cb>>. Acessado em: 08-02-2022.

ENEVOLDSEN, Carsten; KRISTENSEN, Troels. Estimation of Body Weight from Body Size Measurements and Body Condition Scores in Dairy Cows. **Journal of Dairy Science**, v. 80, n. 9, p. 1988–1995, 1997. ISSN 0022-0302. DOI:

<[https://doi.org/10.3168/jds.S0022-0302\(97\)76142-3](https://doi.org/10.3168/jds.S0022-0302(97)76142-3)>. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0022030297761423>>>.

FONSECA, Patrícia; ALVES, Eduardo; PASSINI, Roberta. Evaluation of covering materials in individual shelters and its effects on physiological responses and performance of dairy calves. **Engenharia Agrícola**, v. 32, p. 1041–1047, dez. 2012. DOI:

<10.1590/S0100-69162012000600005>.

GJERGJI, Mikel *et al.* Deep Learning Techniques for Beef Cattle Body Weight Prediction. In: 2020 International Joint Conference on Neural Networks (IJCNN). [S.l.: s.n.], 2020.

P. 1–8. DOI: <10.1109/IJCNN48605.2020.9207624>.

GU, Jiuxiang *et al.* Recent advances in convolutional neural networks. **Pattern Recognition**, v. 77, p. 354–377, 2018. ISSN 0031-3203. DOI:

<<https://doi.org/10.1016/j.patcog.2017.10.013>>. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0031320317304120>>>.

HANSEN, M.F. *et al.* Automated monitoring of dairy cow body condition, mobility and weight using a single 3D video capture device. **Computers in Industry**, v. 98, p. 14–22, 2018. ISSN 0166-3615. DOI: <<https://doi.org/10.1016/j.compind.2018.02.011>>.

Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S016636151730475X>>>.

HEIDARI, Ali Asghar *et al.* An efficient hybrid multilayer perceptron neural network with grasshopper optimization. **Soft Computing**, Springer, v. 23, n. 17, p. 7941–7958, 2019.

HEINRICHS, A.J.; ERB, H.N. *et al.* Variability in Holstein heifer heart-girth measurements and comparison of prediction equations for live weight. **Preventive Veterinary Medicine**, v. 78, n. 3, p. 333–338, 2007. ISSN 0167-5877. DOI:

<<https://doi.org/10.1016/j.prevetmed.2006.11.002>>. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0167587706002455>>>.

HEINRICHS, A.J.; HEINRICHS, B.S. *et al.* Short communication: Verifying Holstein heifer heart girth to body weight prediction equations. **Journal of Dairy Science**,

v. 100, n. 10, p. 8451–8454, 2017. ISSN 0022-0302. DOI:

<<https://doi.org/10.3168/jds.2016-12496>>. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0022030217307683>>>.

HEINRICH, A.J.; ROGERS, G.W.; COOPER, J.B. Predicting Body Weight and Wither Height in Holstein Heifers Using Body Measurements. **Journal of Dairy Science**, v. 75, n. 12, p. 3576–3581, 1992. ISSN 0022-0302. DOI: <[https://doi.org/10.3168/jds.S0022-0302\(92\)78134-X](https://doi.org/10.3168/jds.S0022-0302(92)78134-X)>. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S002203029278134X>>>.

HUANG, Gao *et al.* Densely connected convolutional networks. In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition. [S.l.: s.n.], 2017. P. 4700–4708.

IBGE. [S.l.: s.n.], 2021. <<https://www.ibge.gov.br/indicadores#variacao-do-pib>>. Acessado em: 14-12-2021.

KASHIHA, Mohammadamin *et al.* Automatic weight estimation of individual pigs using image analysis. **Computers and Electronics in Agriculture**, v. 107, p. 38–44, 2014. ISSN 0168-1699. DOI: <<https://doi.org/10.1016/j.compag.2014.06.003>>. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0168169914001525>>>.

KOTSIANTIS, Sotiris B; ZAHARAKIS, I; PINTELAS, P *et al.* Supervised machine learning: A review of classification techniques. **Emerging artificial intelligence applications in computer engineering**, Amsterdam, v. 160, n. 1, p. 3–24, 2007.

LECUN, Y. *et al.* Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998. DOI: <10.1109/5.726791>.

LORENCIN, Ivan *et al.* Using multi-layer perceptron with Laplacian edge detector for bladder cancer diagnosis. **Artificial Intelligence in Medicine**, v. 102, p. 101746, 2020. ISSN 0933-3657. DOI: <<https://doi.org/10.1016/j.artmed.2019.101746>>. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S093336571930363X>>>.

LOWDER, Sarah K.; SKOET, Jakob; RANEY, Terri. The Number, Size, and Distribution of Farms, Smallholder Farms, and Family Farms Worldwide. **World Development**, v. 87, p. 16–29, 2016. ISSN 0305-750X. DOI: <<https://doi.org/10.1016/j.worlddev.2015.10.041>>. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0305750X15002703>>>.

MARTINS, B.M. *et al.* Estimating body weight, body condition score, and type traits in dairy cows using three dimensional cameras and manual body measurements. **Livestock Science**, v. 236, p. 104054, 2020. ISSN 1871-1413. DOI: <<https://doi.org/10.1016/j.livsci.2020.104054>>. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S187114131930263X>>>.

MILLER, Gemma A. *et al.* Using 3D Imaging and Machine Learning to Predict Liveweight and Carcass Characteristics of Live Finishing Beef Cattle. **Frontiers in Sustainable Food Systems**, v. 3, 2019. ISSN 2571-581X. DOI: <10.3389/fsufs.2019.00030>. Disponível em: <<<https://www.frontiersin.org/article/10.3389/fsufs.2019.00030>>>.

MURSHED, M. G. Sarwar *et al.* Machine Learning at the Network Edge: A Survey. **ACM Comput. Surv.**, Association for Computing Machinery, New York, NY, USA, v. 54, n. 8, out. 2021. ISSN 0360-0300. DOI: <10.1145/3469029>. Disponível em: <<<https://doi.org/10.1145/3469029>>>.

NIR, Oron *et al.* 3D Computer-vision system for automatically estimating heifer height and body mass. **Biosystems Engineering**, v. 173, p. 4–10, 2018. Advances in the Engineering of Sensor-based Monitoring and Management Systems for Precision Livestock Farming. ISSN 1537-5110. DOI: <<https://doi.org/10.1016/j.biosystemseng.2017.11.014>>. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S1537511017308590>>>.

QIAO, Yongliang *et al.* Intelligent perception for cattle monitoring: A review for cattle identification, body condition score evaluation, and weight estimation. **Computers and Electronics in Agriculture**, v. 185, p. 106143, 2021. ISSN 0168-1699. DOI:

<<https://doi.org/10.1016/j.compag.2021.106143>>. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0168169921001617>>>.

RICH, Elaine. Artificial Intelligence and the Humanities. **Computers and the Humanities**, Springer, v. 19, n. 2, p. 117–122, 1985. ISSN 00104817. Disponível em:

<<<http://www.jstor.org/stable/30204398>>>.

RUCHAY, Alexey *et al.* Accurate body measurement of live cattle using three depth cameras and non-rigid 3-D shape recovery. **Computers and Electronics in Agriculture**, v. 179, p. 105821, 2020. ISSN 0168-1699. DOI:

<<https://doi.org/10.1016/j.compag.2020.105821>>. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0168169920321256>>>.

SONG, X. *et al.* Automated body weight prediction of dairy cows using 3-dimensional vision. **Journal of Dairy Science**, v. 101, n. 5, p. 4448–4459, 2018. ISSN 0022-0302. DOI: <<https://doi.org/10.3168/jds.2017-13094>>. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0022030218301693>>>.

STAJNKO, Denis *et al.* Non Invasive Estimating of Cattle Live Weight Using Thermal Imaging, fev. 2022.

TASDEMIR, Sakir; URKMEZ, Abdullah; INAL, Seref. Determination of body measurements on the Holstein cows using digital image analysis and estimation of live weight with regression analysis. **Computers and Electronics in Agriculture**, v. 76, n. 2, p. 189–197, 2011. ISSN 0168-1699. DOI:

<<https://doi.org/10.1016/j.compag.2011.02.001>>. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0168169911000366>>>.

TIAN, Jingjing *et al.* Application of Convolutional Neural Network in Fault Line Selection of Distribution Network. **Journal of Applied Science and Engineering**, Tamkang University Press, v. 25, p. 195–205, 1 jul. 2021. ISSN 1560-6686. DOI:

<10.6180/jase.202202_25(1).0020>. Disponível em:

<<[https://doi.org/10.6180/jase.202202_25\(1\).0020](https://doi.org/10.6180/jase.202202_25(1).0020)>>.

USAMA, Muhammad *et al.* Unsupervised Machine Learning for Networking: Techniques, Applications and Research Challenges. **IEEE Access**, v. 7, p. 65579–65615, 2019. DOI: <10.1109/ACCESS.2019.2916648>.

WEBER, Vanessa Aparecida Moraes *et al.* Cattle weight estimation using active contour models and regression trees Bagging. **Computers and Electronics in Agriculture**, v. 179, p. 105804, 2020. ISSN 0168-1699. DOI:

<<https://doi.org/10.1016/j.compag.2020.105804>>. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S016816992031783X>>>.

YAMASHITA, Rikiya *et al.* Convolutional neural networks: an overview and application in radiology. **Insights into imaging**, Springer, v. 9, n. 4, p. 611–629, 2018.

ZHANG, Jianlong *et al.* Pig Weight and Body Size Estimation Using a Multiple Output Regression Convolutional Neural Network: A Fast and Fully Automatic Method. **Sensors**, v. 21, n. 9, 2021. ISSN 1424-8220. DOI: <10.3390/s21093218>. Disponível em: <<<https://www.mdpi.com/1424-8220/21/9/3218>>>.

ZHANG, Qianru *et al.* Recent advances in convolutional neural network acceleration. **Neurocomputing**, v. 323, p. 37–51, 2019. ISSN 0925-2312. DOI: <<https://doi.org/10.1016/j.neucom.2018.09.038>>. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0925231218311007>>>.