

CENTRO ESTADUAL DE EDUCAÇÃO TECNOLÓGICA “PAULA SOUZA”

FACULDADE DE TECNOLOGIA DE BEBEDOURO

TECNOLOGIA EM BIG DATA NO AGRONEGÓCIO

**PREVISÃO DE MEDIDA DE PESO BOVINO UTILIZANDO
ARQUITETURA RESNET50**

AUTOR: CARLOS HENRIQUE DA SILVA BARBOSA

ORIENTADOR: RENAN GUILERME NESPOLO

BEBEDOURO

2025

CARLOS HENRIQUE DA SILVA BARBOSA

Previsão de Medida de Peso Bovino Utilizando Arquitetura ResNet50

Monografia apresentada à Faculdade de Tecnologia
de Bebedouro, como parte dos requisitos para a
obtenção do título de Tecnólogo em Big Data no
Agronegócio

Orientador: **prof. Dr. Renan Guilherme Nespolo**

BEBEDOURO

2025

Eu falhei muitas e muitas vezes na vida. E é exatamente por isso que eu obtive sucesso.

MICHAEL JORDAN

Agradecimentos

Agradeço primeiramente com todo o meu carinho e gratidão a:

Meus pais, João e Maria, que sempre acreditaram em mim e me apoiaram incondicionalmente. Sua paciência, amor e incentivo foram fundamentais para que eu chegasse até aqui.

Meu orientador, Renan, por sua orientação, apoio e valiosas contribuições ao longo desta jornada. Seu conhecimento e dedicação foram essenciais para a realização deste trabalho.

Meus amigos, Paulo e Alexandre, por estarem ao meu lado em cada etapa desta caminhada, oferecendo apoio, compreensão e muitas vezes uma palavra de encorajamento quando eu mais precisava e a todos que contribuíram, direta ou indiretamente, para a conclusão deste projeto, meu sincero agradecimento.

BARBOSA, C. H. **Revolução da pecuária: Algoritmo prevê peso do bovino**. Trabalho de Graduação (Monografia). Centro Estadual de Educação Tecnológica “Paula Souza”. Faculdade de Tecnologia de Bebedouro. 48p. 2025.

RESUMO

No Brasil, o mercado da pecuária é uma das principais atividades econômicas do país, enfrentando um enorme desafio devido ao aumento populacional o que levou a um crescimento na demanda por alimentos. Nesse contexto, a indústria da pecuária está sempre em busca de inovações, otimização dos processos e melhoria nas operações de forma ágil, produtiva e lucrativa, sem comprometer a qualidade do produto. Normalmente, os produtores têm que transportar os animais até outro local para realizar a pesagem em balança tendo o contato direto com o animal, essa etapa gera desconforto e estresse ao animal, afetando o bem-estar e consequentemente a qualidade da carne. Um grande fator que contribui para a perda de peso, é o estresse animal devido ao manejo direto gerando perda de peso afetando na qualidade da carne e no lucro do produto. Com os avanços da computação e da inteligência artificial, surge a possibilidade de aplicar novos métodos de aprendizado de máquina para reduzir o manejo direto, garantindo o bem-estar animal e aumentando a produção. O principal propósito deste estudo é desenvolver um modelo de redes neurais profundas, juntamente com um algoritmo em *Python*, utilizando a arquitetura *Resnet50*, para fazer uma previsão precisa do peso do gado, utilizando imagens e técnicas de aprendizado de máquina. Essa estratégia visa eliminar o contato direto com o animal durante a pesagem, contribuindo em pesquisas futuras nessa área.

Palavras-chave: Visão Computacional; Pecuária; Aprendizado de Máquina; Redes Neurais Profundas; Peso;

BARBOSA, C. H. **Revolução da pecuária: Algoritmo prevê peso do bovino**. Trabalho de Graduação (Monografia). Centro Estadual de Educação Tecnológica “Paula Souza”. Faculdade de Tecnologia de Bebedouro. 48p. 2025.

ABSTRACT

In Brazil, the livestock market is one of the country's main economic activities, facing a huge challenge due to the increase in population, which has led to an increase in the demand for food. In this context, the livestock industry is always looking to innovate, optimize processes and improve operations in an agile, productive and profitable way, without compromising product quality. Normally, producers have to transport the animals to another location to weigh them on scales and have direct contact with the animal. This step generates discomfort and stress for the animal, affecting its well-being and consequently the quality of the meat. A major factor contributing to weight loss is animal stress due to direct handling, which leads to weight loss, affecting meat quality and product profit. With advances in computing and artificial intelligence, there is the possibility of applying new machine learning methods to reduce direct handling, guaranteeing animal welfare and increasing production. The main purpose of this study is to develop a deep neural network model, together with an algorithm in Python, using the Resnet50 architecture, to make an accurate prediction of cattle weight, using images and machine learning techniques. This strategy aims to eliminate direct contact with the animal during weighing, contributing to future research in this area.

Keywords: Computer Vision. Livestock; Machine Learning; Deep Neural Networks; Weight.

SUMÁRIO

1	INTRODUÇÃO	14
2	FUNDAMENTAÇÃO TEÓRICA.....	15
2.1	PECUÁRIA	15
2.2	ESTRESSE ANIMAL	17
2.3	IMPORTÂNCIA DA PESAGEM NA PECUÁRIA	17
2.4	REDES NEURAIS PROFUNDAS	17
2.4.1	MAE (MEAN ABSOLUTE ERROR)	18
2.4.2	<i>K-FOLD (K-FOLD CROSS-VALIDATION)</i>	19
2.4.3	DEEP LEARNING	20
2.4.4	MAX POOLING	20
2.4.5	FUNÇÃO RELU (RECTIFIED LINEAR UNIT).....	21
2.5	RESNET50	21
3	Trabalhos Relacionados.....	22
4	Desenvolvimento	25
4.1	CONJUNTO DE DADOS	25
4.2	PRÉ-PROCESSAMENTO	26
4.3	Implementação.....	27
5	RESULTADOS E DISCUSSÕES	31
6	CONCLUSÃO.....	45
	REFERÊNCIAS	46

LISTA DE FIGURAS

Figura 1 -	Perfil da cadeia produtiva da pecuária de corte brasileira em 2015.	15
Figura 2 -	Cadeia produtiva da carne bovina: qualidade desde o melhoramento genético.	16
Figura 3 -	Residual learning: Residual block.	22
Figura 4 -	Imagem do animal do <i>Dataset</i> B2 na posição lateral (<i>filename:96.0_s_170_2.0_M</i>).	26
Figura 5 -	Ilustração das camadas da rede neural.	30
Figura 6 -	Fluxograma do algoritmo.	30
Figura 7 -	Imagem aleatória do <i>Dataset</i> B2 utilizando o filtro Cinza com o animal na posição lateral.	37
Figura 8 -	Imagem aleatória do <i>Dataset</i> B2 utilizando filtro RGB com o animal na posição lateral.	37
Figura 9 -	Imagem aleatória do <i>Dataset</i> B3 utilizando filtro Cinza na posição frontal.	38
Figura 10 -	Imagem aleatória do <i>Dataset</i> B3 utilizando filtro RGB com o animal na posição frontal.....	39
Figura 11 -	Imagem aleatória do <i>Dataset</i> B4 utilizando filtro Cinza com o animal na.... posição frontal.....	39
Figura 12 -	Imagem aleatória do <i>Dataset</i> B4 utilizando filtro RGB com o animal na posição lateral.	40
Figura 13 -	Imagem aleatória do <i>Dataset</i> B3 utilizando filtro RGB com o animal na posição lateral.	40

Lista de Tabelas

Tabela 1 -	Diferenças entre o presente estudo e os trabalhos comparados.....	24
Tabela 2 -	10-Fold-Validation do <i>Dataset</i> B2 utilizando o tratamento RGB com o animal na posição frontal.....	31
Tabela 3 -	10-Fold-Validation do <i>Dataset</i> B2 utilizando o tratamento RGB com o animal na posição lateral.	31
Tabela 4 -	10-Fold-Validation do <i>Dataset</i> B2 utilizando o tratamento Cinza com o animal na posição frontal.....	32
Tabela 5 -	10-Fold-Validation do <i>Dataset</i> B2 utilizando o tratamento Cinza com o animal na posição lateral.	32
Tabela 6 -	10-Fold-Validation do <i>Dataset</i> B3 utilizando o tratamento RGB com o animal na posição frontal.....	33
Tabela 7 -	10-Fold-Validation do <i>Dataset</i> B3 utilizando o tratamento RGB com o animal na posição lateral.	33
Tabela 8 -	10-Fold-Validation do <i>Dataset</i> B3 utilizando o tratamento Cinza com o animal na posição frontal.....	34
Tabela 9 -	10-Fold-Validation do <i>Dataset</i> B3 utilizando o tratamento Cinza com o animal na posição lateral.	34
Tabela 10 -	10-Fold-Validation do <i>Dataset</i> B4 utilizando o tratamento RGB com o animal na posição frontal.....	35
Tabela 11 -	10-Fold-Validation do <i>Dataset</i> B4 utilizando o tratamento RGB com o animal na posição lateral.	35
Tabela 12 -	10-Fold-Validation do <i>Dataset</i> B4 utilizando o tratamento Cinza com o animal na posição frontal.....	36
Tabela 13 -	10-Fold-Validation do <i>Dataset</i> B4 utilizando o tratamento Cinza com o animal na posição lateral.	36

Lista de Gráficos

Gráfico 1 -	Gráfico da média MAE em kg em filtro Cinza na posição frontal.	41
Gráfico 2 -	Gráfico da média MAE em kg em filtro Cinza na posição lateral.	41
Gráfico 3 -	Gráfico da média MAE em kg em filtro RGB na posição frontal.....	42
Gráfico 4 -	Gráfico da média MAE em kg em filtro RGB na posição lateral.	43
Gráfico 5 -	Comparação de Resultados obtido por <i>k-Fold</i> MAE em quilogramas para imagens em Tons de Cinza.....	44
Gráfico 6 -	Comparação de Resultados obtido por <i>k-Fold</i> MAE em quilogramas para imagens com filtros vermelho(R) ou verde (G).....	44

Lista de Quadros

Quadro 1 -	Etapas do processo de execução do algoritmo em Python v3.13.1.....	27
Quadro 2 -	Arquitetura da rede neural convolucional.	28

LISTA DE EQUAÇÕES

EQUAÇÃO(1) ERRO ABSOLUTO MÉDIO (MAE)	19
EQUAÇÃO(2) FUNÇÃO ReLU.....	21
EQUAÇÃO(3) FUNÇÃO DE ATIVAÇÃO RESIDUAL	22

Lista de Siglas

GS – *Gray Scale* (Escala Cinza)

RGB – *Red, Green, Blue* (Vermelho, Verde e Azul).

k-NN - *k-Fold Cross-Validation* (Validação Cruzada *k-Fold*)

MAE - *Mean Absoluto Error*

CNN – *Convolution Neural Networks*

IA – *Inteligência Artificial*

1 INTRODUÇÃO

O mercado da pecuária é representado como uma das atividades mais importantes do Brasil, e com a alta demanda do mercado as empresas deste ramo procuram métodos e possibilidades inovadoras de atender às necessidades e melhorar suas operações de forma ágil, produtiva e lucrativa sem afetar a qualidade na hora da negociação do seu produto. Os principais fatores que influenciam sua produção e qualidade é o manejo do animal e seu peso, em vista que, a grande parte da produção de gado se destina a bovinocultura de corte (SENAR, 2018).

Com o aumento da população mundial, houve um aumento no consumo e procura de alimentos, a pecuária se tornou um ramo que necessita de muita mão de obra em suas operações. A etapa de pesagem dos bovinos é um dos fatores que mais gera desconforto e estresse para o animal, este processo é realizado em contato direto com o animal sendo transportado para outro ambiente e conduzido até uma balança, para se obter o seu peso para a negociação do produto, os fatores que mais influenciam na qualidade da carne bovina é o bem-estar do gado e o seu peso, portanto é de suma importância evitar o estresse do bovino (ALVARENGA, 2022).

Com o avanço constante da tecnologia é viável implementar novos processos reduzindo o manejo direto com o animal garantindo o bem-estar animal e agilidade na produção. Neste presente trabalho tem como objetivo principal construir um modelo de redes neurais profundas para que realize uma previsão do peso do gado através de imagens de forma digital e automatizada utilizando estudos e métodos de aprendizado de máquina para execução desta tarefa sem que haja manejo direto com o animal, e realizando uma contribuição para estudos futuros deste ramo. As principais contribuições do presente trabalho são:

Objetivo 1: Construir um modelo de redes profundas de previsão de peso do bovino, utilizando arquitetura ResNet50.

Objetivo 2: comparação de filtros nas imagens (Tons Cinza x Tons RGB).

Objetivo 3: comparação de imagens de posições diferentes do gado (lateral x frontal).

O presente trabalho está segmentado em: 1 Introdução; 2 Fundamentação Teórica; 3 Materiais e Métodos; 4 Resultados Esperados; 5 Conclusões; ao final as Referências.

2 FUNDAMENTAÇÃO TEÓRICA


Na presente seção são apresentados todos os fundamentos relativos ao presente estudo. A seção está separada nos seguintes tópicos: 2.1 Pecuária; 2.2 Estresse animal; 2.3 Importância da paisagem na pecuária; e 2.4 Redes neurais profundas.

2.1 PECUÁRIA

A pecuária se tornou uma das atividades econômicas de maior relevância econômica no Brasil. Devido ao crescimento da população mundial o aumento no consumo de alimentos de origem animal, para atender a demanda do mercado o setor da pecuária terá que aumentar a sua produção sem impactar na qualidade da carne bovina e sustentabilidade. (SENAR, 2018)

De acordo com a Embrapa (2017), o Brasil é um dos principais agentes de toda produção mundial no ramo da bovinocultura para carne de corte, sendo um forte competidor no mercado internacional pela alta produtividade e qualidade do produto brasileiro. Em 2015, foi constatado que o Brasil tem a posse do maior rebanho bovino com 209 milhões de cabeças de gado, o segundo maior consumidor sendo 38,6 kg/habitante/ano, o segundo maior exportador (1,9 milhões de toneladas por carcaça) de toda carne bovina no mercado mundial e com abate acima de 39 milhões de cabeças. O Brasil é um grande consumidor interno de carne bovina, tem um enorme parque industrial com a capacidade de abate de quase 200 mil bovinos por dia, com um faturamento de 6 bilhões de reais e com o produto interno bruto (PIB) sendo 30% do PIB do Agronegócio com a movimentação mais de 400 bilhões de reais, na Figura 1 são demonstrados os principais tópicos do processo de produção da pecuária de corte brasileira em 2015.

Figura 1 - Perfil da cadeia produtiva da pecuária de corte brasileira em 2015.



Fonte: Embrapa Gado de Corte 2017.

Tendo em vista que a pecuária é um ramo muito importante e lucrativo, o mercado está cada vez mais preocupado com a origem e qualidade na negociação do produto, muitos fatores são cruciais na hora da compra, aspectos como as condições do animal, por exemplo, a higiene, saúde, bem-estar, local de confinamento ou pasto; e éticas do animal, são fatores que afetam o preço. Na Figura 2 é representada a cadeia produtiva da carne bovina com qualidade e melhoramento genético. O bem-estar e o lucro têm uma forte relação, o animal quando é submetido a estresse ou medo afeta tanto a produção quanto a qualidade do produto, sendo amplamente reconhecido o produtor atender.

Figura 2 - Cadeia produtiva da carne bovina: qualidade desde o melhoramento genético.



Fonte: Embrapa Gado de Corte 2017.

2.2 ESTRESSE ANIMAL

O estresse é um mecanismo de defesa de um indivíduo causado devido a um estímulo por um agente estressor, para os animais os agentes ocorrem durante o processo de produção, sendo no transporte, manejo direto (MELO et al, 2016).

O gado estressado causa o aumento da temperatura corporal, aumento da frequência respiratória, glicose acelerada com queda no pH, rápida desnaturação proteica e perda de massa muscular reduzindo o peso, além de apresentar uma coloração mais escura na sua carne com os níveis inadequados de pH causando impacto negativo na qualidade e na vida útil do produto. (MELO et al., 2016).

Na produção de bovinos para corte o bem-estar do animal por muito tempo foi um fator que havia sido deixado de lado, já que não havia impactos nos lucros, mas com decorrer de estudos foi descoberto que aqueles animais que têm níveis de estresse excessivo reduz a qualidade e torna o produto menos concorrido no mercado. Uma alternativa para reduzir o estresse pode ser implementada boas práticas de gestão, treinamentos de funcionários e melhoria no processo produtivo reduzindo o manejo direto do animal evitando o estresse, possíveis acidentes durante a produção e uma melhor qualidade da carne bovina. (ALVARENGA, 2022).

2.3 IMPORTÂNCIA DA PESAGEM NA PECUÁRIA

A criação de gado para corte, tem como um índice significativo o monitoramento do peso, pois fornece informações cruciais sobre o desempenho e desenvolvimento no processo produtivo, através da pesagem o produtor pode monitorar o ganho de peso do bovino para avaliar a saúde, ajuste do consumo de alimentos ou suplementação e estabelecer uma estratégia para a produção desde a primeira até a última fase. (SENAR, 2018).

2.4 REDES NEURAIIS PROFUNDAS

O conceito de redes neurais surge da necessidade de criar sistemas inspirados em uma estrutura semelhante ao cérebro humano. O cérebro é uma estrutura altamente complexa, não linear e paralelo, sendo capaz de reconhecer padrões, aprender, ter percepção e realizar certos cálculos mais rapidamente do que qualquer computador digital conhecido. Dessa forma, as

redes neurais sendo uma arquitetura de computação funcionam por meio de algoritmo de aprendizado realizando treinamentos de modelos capaz de operar semelhante ao cérebro humano. (HAYKIN, 2001)

De acordo com Haykin (2001) o elemento fundamental de uma rede neural é o neurônio, que é um fator crucial para realizar o processamento de informação para o funcionamento da rede neural. Os neurônios consistem nos nós de camadas de entrada, sinapses, um somador, um termo de polarização e uma função de ativação.

As Redes Neurais Convolucionais, do inglês Convolutional Neural Networks (CNNs), é uma classe de redes neurais profundas sendo um modelo poderoso para classificação de imagens na parte de visão computacional e processamento de imagens, podendo desempenhar uma forte tendência para ser estudada e implementada na aplicação de tecnologias de inteligência artificial (IA) na bovinocultura e outras áreas.

No ambiente da pecuária, as CNN podem ser usadas para identificação e classificação de características físicas do gado como raça, peso, idade e condição de saúde. Por exemplo, utilizando fotografias do animal, também pode ser treinada para identificar anomalias físicas nos animais, como ferimentos e doenças visíveis ou analisar comportamento durante as etapas do pastoreio para estratégias de bem-estar do animal.

Em resumo, a CNN é uma poderosa ferramenta capaz de resolver problemas complexos e fazer análise de dados para a pecuária, propondo estudos futuros, novas perspectivas, automatização no processo e possibilidades para a melhoria da eficiência, saúde e bem-estar do gado.

2.4.1 MAE (MEAN ABSOLUTE ERROR)

A métrica utilizada neste presente estudo foi a técnica de MAE (*Mean Absolute Error*) traduzindo “Erro Médio Absoluto”. O MAE é muito utilizado para validação de modelos, a técnica é calculada pela média da diferença absoluta entre os valores previstos pelo modelo e os valores observados utilizando o mesmo peso, podendo proporcionar uma melhor interpretação da precisão do modelo. Desta forma o modelo que obtiver o menor índice do MAE significa que o modelo tem maior capacidade de prever o valor da saída, com uma probabilidade alta de acerto. (CHAI, T.; DRAXLER, R. R. 2014).

Durante o treinamento, a fórmula matemática do MAE por *fold* é representado na

Equação (1):

$$MAE_{(fold)} = \frac{1}{n} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (1)$$

Em resumo, segundo CHAI e DRAXLER (2014), a métrica MAE é crucial para avaliação e aprimorar modelos preditivos, por ser um modelo robusto em situações de alta variabilidade tem o resultado mais estável evitando outliers e sendo intuitivo contribuindo para um melhor entendimento para a comparação, validação e melhoria de modelo treinado.

2.4.2 K-FOLD (K-FOLD CROSS-VALIDATION)

O uso da técnica *k-Fold Cross-Validation* é utilizada em estatística e ciência de dados para avaliar a performance de modelos preditivos. Essa abordagem divide o conjunto de dados em ‘K’ subconjuntos ou “*folds*”, permitindo que o modelo utilize 80% dos dados para treinamento e 20% de dados para validação. O principal objetivo dessa técnica é garantir que o modelo não apenas se ajuste bem aos dados de treinamento, mas também tenha um desempenho satisfatório em dados não vistos, minimizando o risco de *overfitting*. (MURPHY, 2012).

Em suma, o *k-Fold Cross-Validation* se inicia com a divisão do *Dataset*. Em seguida, o modelo é treinado K vezes (neste estudo é 10 devido ao grande volume de dados no *Dataset*), cada vez utilizando K-1 *folds* para treinamento e o *fold* restante para teste. Esse ciclo se repete até que cada *fold* tenha sido utilizado uma vez como conjunto de teste. Ao final do processo, a performance do modelo é avaliada através do Erro Médio Absoluto (MAE) obtidas em cada *fold* fornecendo uma estimativa mais confiável da capacidade de generalização do modelo.

2.4.3 DEEP LEARNING

O *Deep learning* (Aprendizado Profundo) é uma subárea do *Machine Learning* (Aprendizado de Máquina) que emprega redes neurais complexas para modelar e extrair padrões complexos a partir de grandes volumes de dados. Inspirado pelo funcionamento do cérebro humano, ele é baseado em redes neurais com várias "camadas" (daí o termo *deep*, ou "profundo"). Cada camada processa uma parte dos dados e transmite o resultado para a próxima, permitindo que a rede aprenda características cada vez mais sofisticadas. (CHARNIAK, 2019)

No contexto deste trabalho, as técnicas de *Deep Learning*, especificamente Redes Neurais Convolucionais (CNNs), são aplicadas em soluções de regressão, é um método estatístico e de aprendizado de máquina usado para modelar e analisar a relação entre uma ou mais variáveis independentes (*inputs*) e uma variável pendente (*output*). O objetivo principal é prever ou estimar o valor da variável dependente com base nos valores das variáveis independentes.

Dentre os treinamentos conhecidos para aprendizado de máquina, neste presente trabalho utiliza o aprendizado supervisionado, que é um dos métodos de aprendizado usados no aprendizado de máquina, a principal característica do supervisionado são dados rotulados e já identificados para resposta correta, com isso o algoritmo tem uma alta taxa de acerto no aprendizado. (PEREIRA, 2018).

2.4.4 MAX POOLING

O *Max Pooling* é uma técnica amplamente utilizada em CNN para reduzir as dimensões espaciais das imagens de entrada, diminuindo a quantidade de parâmetros e o custo computacional do modelo, ao mesmo tempo que preserva as características mais relevantes da imagem.

Esse processo funciona por meio da aplicação de uma janela (geralmente de 2x2 ou 3x3 pixels) que percorre a imagem e, em cada região, seleciona o valor máximo presente. Ao fazer isso, o *Max Pooling* reduz a resolução da imagem, mantendo os padrões mais importantes, como bordas e texturas, e eliminando informações menos significativas.

Além de contribuir para a redução da complexidade da rede, o *Max Pooling* também torna a rede mais robusta a pequenas variações e deslocamentos na imagem, o que é especialmente útil em aplicações com imagens reais, como no presente estudo com bovinos.

Essa técnica foi utilizada após as camadas convolucionais para garantir a extração eficiente das características relevantes e facilitar a generalização do modelo durante o treinamento.

2.4.5 FUNÇÃO RELU (RECTIFIED LINEAR UNIT)

A função de ativação *ReLU* (Rectified Linear Unit) é uma das funções mais utilizadas em redes neurais profundas, especialmente em modelos que envolvem processamento de imagens. Sua principal função é introduzir não linearidade à rede, permitindo que ela aprenda relações mais complexas entre os dados de entrada e a saída desejada, em representação matemática é representado na equação (2):

$$f(x) = \max(0, x) \quad (2)$$


Ou seja, ela retorna zero para valores negativos e o próprio valor para valores positivos. Essa simplicidade matemática oferece diversas vantagens, como uma computação mais rápida e uma redução no problema do desvanecimento do gradiente, comum em funções como sigmoide ou tangente hiperbólica. No presente estudo, a função *ReLU* foi aplicada nas camadas convolucionais da rede *Resnet50*, desempenhando um papel essencial na ativação dos neurônios responsáveis por detectar padrões visuais nas imagens dos bovinos. Sua aplicação contribuiu para a eficiência do aprendizado e para a convergência mais rápida do modelo (ESTEVEZ, 2022).

2.5 RESNET50

A arquitetura *Resnet50* (KOONCE, 2021) se destaca por seus blocos residuais e alta capacidade de aprendizado em redes neurais profundas. Sendo essencial para solucionar problemas de degradação de desempenho em redes muito profundas. A partir de imagens reais de bovinos para prever o peso dos animais em ambientes rurais é possível reforçar a rigidez e escalabilidade da arquitetura em extrair informações mesmo em ambientes com muito ruídos e não controlados. (KOONCE, 2021).

A arquitetura *ResNet* é baseado em aprendizado residual, no qual é apresentado um exemplo dos blocos residuais é apresentado na figura 3:

Figura 3 - Residual learning: Residual block.



Fonte: Adaptada de (HE *et al.*, 2016).

no qual net representa a entrada da função de ativação $f(net)$ a função de ativação de net , ReLU é dada pela equação (2). Desse modo a função de ativação de saída do bloco residual é apresentada na equação (3):

$$f(net) = f(net) + net. \quad (3)$$

3 TRABALHOS RELACIONADOS

A criação de gado é um assunto bastante estudado. Alguns trabalhos abordaram a identificação do gado, o que é uma tarefa de classificação. Somente em 2020 Gjergji *et al.* (2020) buscou estimar o peso animal, o que é no campo de aprendizado de máquina um problema de regressão.

Como já citado, em 2020 Gjergji *et al.* (2020) apresentaram um trabalho para acompanhar o peso do gado de corte. Explorando o desempenho de vários modelos de aprendizagem profunda na tarefa de regressão para prever o peso do gado. O estudo utilizou imagens coloridas e analisou redes neurais convolucionais, redes RNN/CNN, Modelos de Atenção Recorrente e Modelos de Atenção Recorrente com Redes Neurais Convolucionais. A

métrica utilizada pelo MAE. O modelo que apresentou os melhores resultados no estudo foi a EfficientNetB1.

De acordo com Ali (2022), a métrica utilizada foi *Mean Squared Error* (MSE), avaliando o algoritmo *k*-Nearest Neighbor (KNN) em tarefas de regressão. O MSE permite quantificar a precisão das previsões comparando valores estimados com valores reais, esta métrica foi extremamente importante para avaliar o impacto de normalização no min-max.

Segundo Ricartes Da Silva (2025), adotou o algoritmo DWNN (*Distance Weighted Nearest Neighbors*) para solucionar problema em aprendizado supervisionado em tarefa de regressão realizando aproximação da diferença recebendo os dados e melhorando sua classificação, houve um aumento na precisão do resultado reduzindo a taxa de erro em 10% podendo ser utilizado em dispositivos com pouca memória.

Em Barbosa et al. (2025) foi apresentado um estudo sobre previsão de peso por imagens. O método utilizou redes convolucionais com algoritmo usando *TensorFlow* e Keras para prever peso do gado, utilizando a métrica *mean absolute error* (MAE) com o algoritmo *k-Fold* para realizar o treinamento do conjunto de dados, dividindo em *k* partes. O menor o valor do MAE indica a precisão do algoritmo e menor taxa de erro podendo comprovar o seu satisfatório resultado.

Os estudos apresentados anteriormente abordam técnicas de regressão baseadas em distâncias Ali (2022) e Ricartes da Silva (2025). Gjergji (2020) abordou técnicas de *deep learning* utilizando vários filtros por imagens (RGB) e Barbosa (2025), foi o único que trabalha que abordou o problema utilizando um único filtro por imagem. Entretanto sem adotar um modelo Robusto de CNN, como a ResNet50. O que levanta uma hipótese na qual, caso um modelo robusto de rede neural seja adotado para o problema de regressão no contexto de previsão do peso animal, utilizando um único filtro por imagem, poderíamos alcançar um resultado melhor, com menor processamento. Na tabela 1 é apresentado as principais diferenças entre os estudos comparados e a nossa abordagem.

Tabela 1 - Diferenças entre o presente estudo e os trabalhos comparados.

Método	Baseado em redes neurais	Arquitetura ResNet 50	Previsão do peso do gado.	Problema de Regressão	Único filtro p/ Imagem
Gjergji et al. (2020)	X		X	X	
Ali (2022),				X	
Barbosa et al. (2025)	X		X	X	
Da Silva et al. (2025)				X	X
Presente estudo.	X	X	X	X	X

Fonte: Elaborado pelo autor.

4 DESENVOLVIMENTO

Na presente seção são apresentadas todas as etapas de desenvolvimento do presente trabalho, desde as escolhas de equipamentos até os algoritmos utilizados. Esta seção está segmentada nos seguintes tópicos: 3.1 Conjunto de Dados; 3.2 Pré-processamento; e 3.3 Implementação e Avaliação.

4.1 CONJUNTO DE DADOS

A aquisição deste *Dataset* é de um estudo onde desenvolveram um sistema para prever de peso de gado a partir de imagens nos ângulos (lateral e frontal) e de medidas do comprimento corporal e tamanho do tórax com visão computacional que funciona por meio de smartphones de baixo custo. (Acme AI Ltd. et al., 2023).

O conjunto de dados possui 15.000 imagens, distribuídas em seu diretório em: 4.397 imagens tratadas e segmentadas em formato RGB, categorizadas em: 2.454 imagens do bovino na posição lateral e 1.943 imagens do bovino na posição frontal. 6.972 imagens reais do animal em ambiente rural, categorizadas em: 4.927 imagens do bovino na posição lateral; e 2.450 imagens do bovino na posição frontal. Neste estudo, foi utilizado 4.403 imagens reais dividido em 2 *Datasets*: *Dataset* B2, contendo imagens de 514 animais nas posições lateral e frontal; e *Dataset* B4, contendo imagens de 3.889 animais nas posições lateral e frontal.

Este conjunto de dados, tem as imagens divididas em 2 diretórios, onde uma são apenas imagens reais do gado em ambiente rural e outra são cópia dessas imagens, porém são segmentadas e tratadas em tons RGB pelo autor do *Dataset* (Acme AI Ltd. et al., 2023).

As imagens possuem metadados em seu nome, esse nome do arquivo contém dados importantes do animal na fotografia como observamos na figura 4 abaixo.

Figura 4 - Imagem do animal do Dataset B2 na posição lateral (filename: 96.0_s_170_2.0_M).



Fonte: (Acme AI Ltd. et al., 2023).

Esses metadados possuem significados para categorizar os dados relevantes do animal, a definição é 96 é o número identificador “ID” da imagem no *Dataset*; S representa a posição do animal, a sigla S é para posição lateral (do inglês “Side”), ou R para posição frontal (do inglês Rear); 170 é o peso do animal na imagem; e M é o sexo do animal, M para macho (Male) ou F para fêmea (Female).

4.2 PRÉ-PROCESSAMENTO

O pré-processamento dos exemplos que foram utilizados na arquitetura ResNet50(imagens), é uma etapa fundamental para garantir que os dados estejam em um formato adequado antes de serem passados para a Rede Neural. Para o presente estudo as imagens tratadas de dois modos diferentes. As imagens sempre convertidas para uma única camada. Desse modo as imagens do animal como a figura 4 foram convertidas para tons de cinza GS, como apresentado na Figura 7. As imagens da variedade *Annotation* (silhuetas) foram convertidas para o filtro verde do RGB, no *Dataset* B2, e para o filtro vermelho do RGB, no *Dataset* B4. Para todos os *Datasets* as imagens foram redimensionadas para de 224x224 pixels, como apresentadas na Figuras 7.

4.3 IMPLEMENTAÇÃO

Neste presente trabalho, foi implementada uma rede neural na linguagem Python versão 3.13.1, utilizando a bibliotecas *PyTorch* e o modelo *Resnet50*, estes são os principais agentes que fornecem as ferramentas necessárias com um alto poder computacional para criação de modelos de aprendizado de máquina com visão computacional.

A etapa de definição da arquitetura é muito importante no algoritmo pois é ela que ajusta e confere que os dados estejam no formato esperado para serem enviados para a rede neural convolucional, abaixo na tabela 1 está descrevendo todas as etapas e passo a passo da execução do algoritmo usado no treinamento, contendo o uso de bibliotecas, configurações de parâmetros até o resultado.

Quadro 1 - Etapas do processo de execução do algoritmo em Python v3.13.1

Etapas	Descrição do processo
1	Foi utilizado a biblioteca <i>PyTorch</i> (<i>torch</i> , <i>torch.nn</i> , <i>torch.optim</i> , <i>torchvision.transforms</i> , <i>torchvision.models</i> , <i>torch.utils.data</i>), <i>matplotlib</i> , <i>kfold</i> , <i>pandas</i> , <i>os</i> , <i>re</i> , <i>Random</i> e <i>PIL</i> para a manipulação de dados e de arquivos, definir e treinar modelos de <i>deep learning</i> em visão computacional, operações matemáticas, otimizadores, transformação das imagens e visualização dos resultados exibindo imagens aleatórias do treinamento.
2	A configuração foi definida em <i>batch_size</i> (lote) como 16, as <i>epochs</i> (épocas) em 10 sendo um bom valor para evitar <i>overfitting</i> , o <i>learning_rate</i> está em 0,001 ideal para o otimizador Adam, o <i>results_file</i> é o nome da planilha onde será salvo os pesos do treinamento e <i>Dataset_path</i> e <i>new_image_path</i> são diretórios onde estão as imagens do treinamento e nova imagem a ser analisada.
3	A função <i>parse_filename</i> é onde será extraído a imagem com seus metadados no nome do arquivo.
4	Em <i>CattleDataset</i> realizando a leitura das imagens do <i>Dataset_path</i> filtrando para imagens em <i>jpg</i> e aplica o filtro podendo ser RGB (Vermelho, Verde e Azul) ou cinza
5	O redimensionamento das imagens para 224x224 sendo o tamanho padrão para entrada do <i>Resnet50</i> e normalizando em 0,5 usando a equação (3): $X_{\text{(normalizado)}} = \frac{x - \mu}{\sigma}$ E aplicando o filtro (RGB ou Cinza) para o treinamento.
6	A definição do modelo de CNN na classe <i>CattleWeightPredictor</i> usando <i>Resnet50</i> pré-treinada ' <i>self.model = models.resnet50(pretrained=True)</i> ' e inicializando o modelo.

Etapas	Descrição do processo
7	Outra parte de configuração onde é para carregar pesos anteriores, caso seja a primeira vez da execução do treinamento, o algoritmo irá criar um arquivo em <i>model_path</i> onde irá salvar o modelo treinado em um arquivo na extensão <i>pth</i> para garantir o aprendizado na próxima execução e fazendo a verificação se já existe o modelo treinado e define o <i>optimizer_path</i> sendo o otimizador do modelo.
8	A função de treino é definida extraindo a imagem e o peso calculando o <i>loss</i> (L1), <i>backpropagation</i> e otimização. A fórmula para calcular o <i>loss</i> (L1) é a equação (4): $l_{L1} = \frac{1}{N} \sum_{i=1}^N \hat{y}_i - y_i $ E a função de validação do <i>fold</i> calculando o MAE para o <i>fold</i>, salvando os resultados das imagens em <i>results_file</i> no formato de Excel e faz uma verificação se existe a planilha se houver faz uma limpeza na planilha anterior e sobrescreve pelos resultados atuais e exibe os resultados e média do MAE do <i>fold</i> treinado via terminal para avaliação do modelo.
9	A validação cruzada <i>k-Fold</i> divide os dados em treino e validação treinando por <i>epochs</i> avaliando o modelo e salvando os resultados.
10	É feito o cálculo do MAE de todos os 10 <i>folds</i> treinados para avaliação do modelo, sendo representado pela equação (5): $MAE_{(geral)} = \frac{1}{K} \sum_{k=1}^K \hat{y}_i - y_i $
11	É salvo os pesos finais do modelo e o otimizador para próximos treinos.
12	A função <i>mostrar_exemplos</i> é para exibir imagens aleatórias que foram treinadas com as informações (ID da imagem, peso real, peso previsto, posição e sexo).
13	Informa a quantidade de imagens analisadas no conjunto de dados e executa a função de <i>predict_new_image</i> sendo necessário para prever o peso do bovino em uma imagem de outro diretório onde essa imagem não possui metadados e é carregado o modelo treinado para realizar previsão do peso sendo informada no terminal.

Fonte: Elaborado pelo autor.

As definições das camadas na arquitetura estão sendo representadas na tabela 2 abaixo:

Quadro 2 - Arquitetura da rede neural convolucional.


Camada	Descrição
1	Camada onde é a entrada do dado que é a imagem, recebe a imagem em canal RGB ou em tons cinza na dimensão 224x224 iniciando o processo de aprendizagem.
2	Camada onde realiza o processamento de características. Uma camada convolucional consiste em um conjunto de filtros (<i>kernels</i>) que passam sobre a imagem de entrada. Cada filtro detecta um tipo de característica (por exemplo,

Camada	Descrição
	bordas, texturas, padrões simples) em diferentes locais da imagem, sendo usada para operações de normalização e função de ativação (ReLU).
3	Camada de " <i>pooling</i> " (agregação), dividindo o mapa de características em pequenas dimensões, tornando a rede mais robusta a pequenas variações mantendo características importantes.
4 - 7	Os 4 Blocos Residuais são os “corações” da arquitetura <i>Resnet</i> . Um bloco residual é uma pequena sub-rede com uma conexão que permite que a entrada seja adicionada diretamente à saída de algumas camadas, contornando algumas transformações. Sendo capaz de resolver problemas de "degradação" em redes muito profundas, onde adicionar mais camadas não melhora o desempenho e pode até piorar devido à dificuldade de otimização. A conexão facilita o fluxo de gradientes durante o treinamento, permitindo que a rede aprenda identidades ou refine características existentes, tornando possível treinar redes com centenas de camadas. A <i>Resnet50</i> tem quatro camadas de blocos, com diferentes profundidades e tamanhos de filtros.
8	Camada de <i>pooling</i> final que opera sobre todos os mapas de características da última CNN. Invés de calcular o máximo de dimensões, ela calcula a média reduzindo e resultando em um vetor de características para cada imagem. É uma alternativa popular ao <i>Flatten</i> (achatar) antes das camadas densas, pois ajuda a reduzir o número de parâmetros e a evitar <i>overfitting</i> .
9	A Camadas Densas (<i>Fully Connected</i> , “FC”) é uma camada de rede neural "tradicional" onde cada neurônio nesta camada está conectado a todos os neurônios da camada anterior. Recebendo um vetor de informações da camada anterior <i>Global Average Pooling</i> sendo capaz de aprender combinações complexas das características extraídas pelas CNN e de <i>pooling</i> . É a partir desta camada onde a rede começa a tomada de decisões com base nas características aprendidas. A representação de neurônios artificiais são círculos “azul” nesta camada ilustra que cada círculo é uma unidade de processamento que recebe entradas de todos os neurônios da camada anterior, realiza uma soma ponderada dessas entradas, e aplica uma função de ativação.
10	A camada de saída é a camada final da rede, produzindo e retornando o resultado da rede.

Fonte: Elaborado pelo autor.

Na figura 5 abaixo, mostra de forma simplificada a estrutura da rede neural convolucional utilizada no presente estudo, sendo composta por 11 camadas e 3 neurônios.

Figura 5 - Ilustração das camadas da rede neural.



Fonte: Elaborado pelo autor.

Na figura 6, é a representação do fluxograma das etapas de teste do presente estudo são apresentadas, as etapas desde o início até o final da sua execução:

Figura 6 - Fluxograma do algoritmo.



Fonte: Elaborado pelo autor.

5 RESULTADOS E DISCUSSÕES

Neste presente estudo, foi utilizado um conjunto de dados com imagens dos bovinos denominados B2, B3 e B4, as imagens são de silhuetas lateral e frontal, para treinamentos com filtros RGB e Tons de Cinza (GS) (Acme AI Ltd. et al., 2023). A métrica utilizada sendo a MAE, seção 2.4.1 no final retorna o MAE médio de todos os *Folds*. Todos os treinamentos utilizam como validação o *10-Fold-Validation*, apresentando na seção 2.4.2, dividindo o conjunto de dados em 10 partes (*folds*), fazendo o treinamento com 9 partes e 1 parte para teste onde não é mostrado. Abaixo são apresentados a tabela de resultados referentes aos treinamentos nos *Dataset* B2, B3 e B4, nos Tons escala cinza (GS), apresentados nas Tabelas 6, 7, 10, 11, 14 e 15; e filtro RGB cada um com ambas silhuetas0, apresentados nas Tabelas 4,5,8,9,12 e 13.

Tabela 2 - 10-Fold-Validation do *Dataset* B2 utilizando o tratamento RGB com o animal na posição frontal.

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 1	0.0226	9.49
Fold 2	0.0094	3.93
Fold 3	0.0160	6.79
Fold 4	0.0208	8.73
Fold 5	0.0109	4.56
Fold 6	0.0197	8.27
Fold 7	0.0181	7.58
Fold 8	0.0132	5.55
Fold 9	0.0109	4.59
Fold 10	0.0122	5.13
Erro médio	0.0154	6.46

Fonte: Elaborada pelo autor.

Tabela 3 - 10-Fold-Validation do *Dataset* B2 utilizando o tratamento RGB com o animal na posição lateral.

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 1	0.0210	4.90
Fold 2	0.0176	4.09
Fold 3	0.0111	2.60
Fold 4	0.0151	3.53
Fold 5	0.0125	2.91
Fold 6	0.0145	3.39

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 7	0.0075	1.74
Fold 8	0.0204	4.74
Fold 9	0.0115	2.68
Fold 10	0.0150	3.49
Erro médio	0.0146	3.41

Fonte: Elaborada pelo autor.

Tabela 4 - 10-Fold-Validation do *Dataset* B2 utilizando o tratamento Cinza com o animal na posição frontal.

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 1	0.0088	3.71
Fold 2	0.0102	4.30
Fold 3	0.0101	4.26
Fold 4	0.0084	3.54
Fold 5	0.0082	3.44
Fold 6	0.0061	2.55
Fold 7	0.0127	5.33
Fold 8	0.0113	4.77
Fold 9	0.0044	1.83
Fold 10	0.0065	2.73
Erro médio	0.0087	3.65

Fonte: Elaborada pelo autor.

Tabela 5 - 10-Fold-Validation do *Dataset* B2 utilizando o tratamento Cinza com o animal na posição lateral.

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 1	0.0060	1.39
Fold 2	0.0082	1.92
Fold 3	0.0098	2.29
Fold 4	0.0134	3.12
Fold 5	0.0074	1.73
Fold 6	0.0061	1.42
Fold 7	0.0120	2.80
Fold 8	0.0138	3.20
Fold 9	0.0098	2.27
Fold 10	0.0103	2.40
Erro médio	0.0097	2.25

Fonte: Elaborada pelo autor.

Tabela 6 - 10-Fold-Validation do *Dataset* B3 utilizando o tratamento RGB com o animal na posição frontal.

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 1	0.0172	10.06
Fold 2	0.0214	12.53
Fold 3	0.0167	9.76
Fold 4	0.0151	8.83
Fold 5	0.0192	11.26
Fold 6	0.0109	6.38
Fold 7	0.0117	6.82
Fold 8	0.0119	6.95
Fold 9	0.0098	5.75
Fold 10	0.0094	5.47
Erro médio	0.0143	8.38

Fonte: Elaborada pelo autor.

Tabela 7 - 10-Fold-Validation do *Dataset* B3 utilizando o tratamento RGB com o animal na posição lateral.

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 1	0.0162	9.51
Fold 2	0.0144	8.44
Fold 3	0.0127	7.44
Fold 4	0.0131	7.68
Fold 5	0.0095	5.57
Fold 6	0.0106	6.21
Fold 7	0.0094	5.49
Fold 8	0.0079	4.62
Fold 9	0.0066	3.88
Fold 10	0.0080	4.71
Erro médio	0.0109	6.35

Fonte: Elaborada pelo autor.

Tabela 8 - 10-Fold-Validation do *Dataset B3* utilizando o tratamento Cinza com o animal na posição frontal.

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 1	0.0617	36.07
Fold 2	0.0611	35.76
Fold 3	0.0590	34.50
Fold 4	0.0643	37.60
Fold 5	0.0612	35.82
Fold 6	0.0519	30.36
Fold 7	0.0410	23.97
Fold 8	0.0407	23.84
Fold 9	0.0248	14.51
Fold 10	0.0231	13.49
Erro médio	0.0489	28.59

Fonte: Elaborada pelo autor.

Tabela 9 - 10-Fold-Validation do *Dataset B3* utilizando o tratamento Cinza com o animal na posição lateral.

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 1	0.0660	38.59
Fold 2	0.0597	34.94
Fold 3	0.0621	36.33
Fold 4	0.0561	32.83
Fold 5	0.0582	34.04
Fold 6	0.0489	28.62
Fold 7	0.0431	25.22
Fold 8	0.0290	16.98
Fold 9	0.0286	16.98
Fold 10	0.0325	18.99
Erro médio	0.0484	28.33

Fonte: Elaborada pelo autor.

Tabela 10 - 10-Fold-Validation do *Dataset B4* utilizando o tratamento RGB com o animal na posição frontal.

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 1	0.0865	20.59
Fold 2	0.0652	15.53
Fold 3	0.0454	10.80
Fold 4	0.0469	11.17
Fold 5	0.0388	9.23
Fold 6	0.0315	7.50
Fold 7	0.0335	7.98
Fold 8	0.0311	7.41
Fold 9	0.0255	6.06
Fold 10	0.0232	5.53
Erro médio	0.0428	10.18

Fonte: Elaborada pelo autor.

Tabela 11 - 10-Fold-Validation do *Dataset B4* utilizando o tratamento RGB com o animal na posição lateral.

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 1	0.1183	28.16
Fold 2	0.1207	28.73
Fold 3	0.1164	27.70
Fold 4	0.0897	21.34
Fold 5	0.0613	14.59
Fold 6	0.0603	14.34
Fold 7	0.0413	9.83
Fold 8	0.0463	11.02
Fold 9	0.0363	8.65
Fold 10	0.0349	8.31
Erro médio	0.0726	17.27

Fonte: Elaborada pelo autor.

Tabela 12 - 10-Fold-Validation do Dataset B4 utilizando o tratamento Cinza com o animal na posição frontal.

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 1	0.1198	28.51
Fold 2	0.1231	29.30
Fold 3	0.1193	28.38
Fold 4	0.1182	28.13
Fold 5	0.1137	27.07
Fold 6	0.0813	19.36
Fold 7	0.0640	15.22
Fold 8	0.0668	15.89
Fold 9	0.0480	11.42
Fold 10	0.0450	10.70
Erro médio	0.0899	21.40

Fonte: Elaborada pelo autor.

Tabela 13 - 10-Fold-Validation do Dataset B4 utilizando o tratamento Cinza com o animal na posição lateral.

Fold	MAE (Normalizado [0,1])	MAE (Quilogramas)
Fold 1	0.1188	28.26
Fold 2	0.1208	28.75
Fold 3	0.1262	30.05
Fold 4	0.1136	27.03
Fold 5	0.0883	21.01
Fold 6	0.0709	16.87
Fold 7	0.0588	13.99
Fold 8	0.0461	10.96
Fold 9	0.0384	9.13
Fold 10	0.0365	8.68
Erro médio	0.0818	19.47

Fonte: Elaborada pelo autor.

Os resultados apresentados, foram gerados após a execução do algoritmo de cada conjunto de dados, durante o treinamento é realizada a divisão das imagens de acordo com o número de *folds* e após o treinamento de cada *fold* é exibido o resultado do treino por *fold* via terminal, onde contém o número do *fold* treinado, o “ID” da imagem, o peso real da imagem (de acordo com o *Dataset*), o peso previsto no algoritmo, a posição (Side para posição lateral e Rear para posição frontal), o sexo do animal informado no *Dataset*, e o erro MAE por peso. A imagem 7 é o exemplo de como é a exibição desse resultado via terminal durante a execução do algoritmo. Quando é finalizado o treino dos 10 *folds*, o algoritmo irá realizar uma busca aleatória nas imagens que analisou durante a sua execução com objetivo de ter uma visualização

intuitiva e simplificada do treinamento do modelo.

Abaixo as Figuras 7, 9, 11 são resultados do treino utilizando filtro cinza (GS) e as Figuras 8, 10, 12 e 13 são resultados com filtro RGB (*Red, Green, Blue*) sendo as Figuras 7, 8, 12 e 13 com o animal na posição lateral e 9, 10 e 11 na posição frontal. As figuras contêm informações que auxilia na visualização de resultados como o “ID” que é o código de identificação do animal, o “Peso Real” que é o peso verdadeiro do animal em Kg, o “Previsto” é a previsão de peso do algoritmo para comparar com o “Peso Real”, a “Posição” é a silhueta que o animal está sendo lateral (Side) ou frontal (Rear) e o “Sexo” sendo representado pela sigla “F” para fêmeas e “M” para Macho.

Figura 7 - Imagem aleatória do *Dataset B2* utilizando o filtro Cinza com o animal na posição lateral.

ID: 52.0, Peso Real: 176.00 kg, Previsto: 175.24 kg
Posição: Side, Sexo: F



Fonte: Elaborada pelo autor.

Figura 8 - Imagem aleatória do *Dataset B2* utilizando filtro RGB com o animal na posição lateral.

ID: 117.0, Peso Real: 151.00 kg, Previsto: 146.84 kg
Posição: Side, Sexo: F



Fonte: Elaborada pelo autor.

Figura 9 - Imagem aleatória do Dataset B3 utilizando filtro Cinza na posição frontal.

ID: 399.0, Peso Real: 219.00 kg, Previsto: 226.49 kg
Posição: Rear, Sexo: F



Fonte: Elaborada pelo autor.

Figura 10 - Imagem aleatória do *Dataset B3* utilizando filtro RGB com o animal na posição frontal.

ID: 199.0, Peso Real: 303.00 kg, Previsto: 309.80 kg
Posição: Rear, Sexo: M



Fonte: Elaborada pelo autor.

Figura 11 - Imagem aleatória do *Dataset B4* utilizando filtro Cinza com o animal na posição frontal.

ID: 477, Peso Real: 222.00 kg, Previsto: 243.95 kg
Posição: Rear, Sexo: F



Fonte: Elaborada pelo autor.

Figura 12 - Imagem aleatória do *Dataset B4* utilizando filtro RGB com o animal na posição lateral.

ID: 346, Peso Real: 187.00 kg, Previsto: 188.23 kg
Posição: Side, Sexo: F



Fonte: Elaborada pelo autor.

Figura 13 - Imagem aleatória do *Dataset B3* utilizando filtro RGB com o animal na posição lateral.

ID: 453.0, Peso Real: 167.00 kg, Previsto: 170.65 kg
Posição: Side, Sexo: F




Fonte: Elaborada pelo autor.

Abaixo os Gráficos 1, 2, 3 e 4 são representados por dados de resultados em cada *Fold*, sendo divididos em filtros e posição, os valores são resultados da média geral do MAE e são categorizados pelo conjunto de dados B2 (Azul), B3 (Vermelho) e B4 (Verde).

No Gráfico 1 representa o treinamento com filtro Cinza e na posição frontal (*Rear*), o conjunto de dados B2 teve como média MAE 3,65, ou seja, a média de erro no peso do animal é de 3,65 kg, já o conjunto B3 tem como pior resultado já que a média MAE é 28,59kg e o B4 com 21,41 kg sendo o segundo melhor conjunto.


Gráfico 1 - Gráfico da média MAE em kg em filtro Cinza na posição frontal.



Fonte: Elaborada pelo autor.

Abaixo no Gráfico 2 utiliza o mesmo filtro cinza, mas o animal está na posição lateral (*Side*), o B3 teve uma pequena queda comparado ao gráfico anterior mas pode-se observar que o conjunto B2 a média reduziu para 2,25 kg e o B4 teve um desempenho superior com a média 6,44 kg ambos mostrando um resultado superior comparado o Gráfico 1.


Gráfico 2 - Gráfico da média MAE em kg em filtro Cinza na posição lateral.



Fonte: Elaborada pelo autor.

Analisando o Gráfico 3 mudando usando o filtro RGB na posição frontal, é possível observar um resultado mais estável entre os conjuntos B2, B3 e B4 já que os resultados estão bem próximos. Contudo mostra a eficiência do filtro RGB comparado ao filtro cinza devido a alta capacidade de extrair dimensões importantes nas imagens, mas com isso tem uma perda em desempenho computacional sendo necessário mais tempo para ter resultado.


Gráfico 3 - Gráfico da média MAE em kg em filtro RGB na posição frontal.



Fonte: Elaborada pelo autor.

Por último, no Gráfico 4 usando o filtro RGB na posição lateral do gado, o conjunto B4 teve uma média alta comparada ao gráfico 3 podendo melhorar sendo treinada mais vezes, mas o B2 e B3 teve um resultado melhor do que o anterior, destacando que a posição lateral é melhor do que na frontal.

Gráfico 4 - Gráfico da média MAE em kg em filtro RGB na posição lateral.




Fonte: Elaborada pelo autor.

Após obter os resultados, são apresentados os resultados por filtro e Datasets nos Gráficos 1,2,3 e 4. Os resultados relativos ao *Dataset* B2 impressionam por chegar muito próximos a zero. Também foram realizado uma comparação com resultados de outro estudo de previsão de peso em bovinos, como apresentados na Seção 3 Trabalhos Relacionados.


As comparações entre esses trabalhos são apresentadas nos Gráficos 5 e 6, demonstrando a diferença entre as outras abordagens e a realizada no presente trabalho:

Gráfico 5 - Comparação de Resultados obtido por *k-Fold* MAE em quilogramas para imagens em Tons de Cinza.



Fonte: Elaborada pelo autor.

Gráfico 6 - Comparação de Resultados obtido por *k-Fold* MAE em quilogramas para imagens com filtros vermelho(R) ou verde (G).



Fonte: Elaborada pelo autor.

6 CONCLUSÃO

O presente estudo demonstrou que é possível aplicar tecnologias avançadas de aprendizado de máquina, para resolver um desafio recorrente na bovinocultura de corte, que é a pesagem dos bovinos sem o manejo direto com o animal, automatizada e precisa. Através do desenvolvimento de um modelo baseado na arquitetura *Resnet50* utilizando imagens do animal. De acordo com os resultados obtidos mostraram a eficiência do modelo proposto, sem a necessidade de pesagem manual, contribuindo para um bem-estar do animal e para trabalhos futuros.

Podendo-se concluir que após o treino, a posição lateral tem melhores resultado do que na posição frontal, o filtro RGB tem ótimos resultados por captar mais informações visuais tendo uma alta previsão e sendo mais estável no treinamento dos *folds*, mas a desvantagem é de desempenho computacional por exigir mais processamento e uso do hardware. A escala cinza é mais estável e tem melhor desempenho computacional, mas fica desbalanceado em relação à média total do *fold*. Ao comparar com outra tecnologia como o *Keras* e *TensorFlow*, o *Resnet* por ser mais robusto e com estrutura complexa da rede neural pode obter uma precisão muito superior e estável do peso do gado.

Conclui-se que após o treino, as imagens em tons de cinza apresentaram melhores resultado comparadas as que utilizando a variedade *Annotation*, além de conter uma etapa a menos de processamento da imagem exigindo menor processamento e uso do *hardware*. A escala cinza é mais estável e tem melhor desempenho computacional, o *Dataset B2* apresentou um erro muito próximo a zero e nunca antes visto nos estudos presentes na literatura. A *Resnet50* apresentou resultados muito superiores as técnicas comparadas.

Em suma, a abordagem deste estudo demonstrou a eficácia na predição do peso do bovino, proporcionando alternativa para realizar a pesagem automatizada combinando o modelo de aprendizado de máquina com visão computacional, esse estudo fornece uma contribuição para trabalhos futuros do ramo e proposta promissora para a indústria da pecuária de corte melhorando a tomada de estratégia e pesagem automatizada do peso bovino.

REFERÊNCIAS

ALI, P. J. M. *“Investigating the Impact of min-max data normalization on the regression performance of K-nearest neighbor with different similarity measurements,”* ARO-The Scientific Journal of Koya University, vol. 10, no. 1, pp. 85–91, 2022.

ALVARENGA, S. R. de. **Bem-estar animal e sua influência na bovinocultura de corte.** 2022. Trabalho de Conclusão de Curso (Graduação em Zootecnia) – Pontifícia Universidade Católica de Goiás, Escola de Ciências Médicas e da Vida, Goiânia, 2022. Disponível em: <<https://repositorio.pucgoias.edu.br/jspui/handle/123456789/4417>>. Acesso em: 28 maio. 2024.

ANDREW, W. et al. **Visual identification of individual Holstein-Friesian cattle via deep metric learning.** Computers and Electronics in Agriculture, v. 185, p. 106133, 2021.

BARBOSA, C.; GOMES, J. L.; ANDRADE, P. E. C.; NESPOLO, R. G. *“Prediction of Cattle Weight Measurement Using Convolutional Neural Networks,”* Interface Tecnológica, vol. 22, no. 1, 2025.

CHAI, T.; DRAXLER, R. R.; **Root mean square error (RMSE) or mean absolute error (MAE)? Arguments against avoiding RMSE in the literature.** University of Maryland, College Park, USA, 30 de Junho 2014. Disponível em: <<https://gmd.copernicus.org/articles/15/5481/2022/>>.

CHARNIAK, E. **Introduction to Deep Learning.** 1. ed. [S.l.: s.n.]: The MIT Press, 2019. ISBN 0262039516; 9780262039512.

ESTEVEES, T. **A desvantagem da função da ReLU.** 2022. Disponível em: <[https://estevestoni.medium.com/a-desvantagem-de-utilizar-relu4478589ef834#:~:text=Rectified%20Linear%20Unit%20\(ReLU\)](https://estevestoni.medium.com/a-desvantagem-de-utilizar-relu4478589ef834#:~:text=Rectified%20Linear%20Unit%20(ReLU))> Acesso em: 22 maio. 2024.

ESTEVEES, T. **A desvantagem da função da ReLU.** 2022. Disponível em: <[https://estevestoni.medium.com/a-desvantagem-de-utilizar-relu4478589ef834#:~:text=Rectified%20Linear%20Unit%20\(ReLU\)](https://estevestoni.medium.com/a-desvantagem-de-utilizar-relu4478589ef834#:~:text=Rectified%20Linear%20Unit%20(ReLU))> Acesso em: 22 maio. 2024.

GJERGJI, M.; DE MORAES WEBER, V.; SILVA, L. O. C.; DA COSTA GOMES, R.; DE ARAÚJO, T. L. A. C.; PISTORI, H.; ALVAREZ, M. “**Deep learning techniques for beef cattle body weight prediction,**” in *2020 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2020, pp. 1–8.

GOMES, R. C; FEIJÓ, G. L. D; CHIARI, L. **Evolução de Qualidade da Pecuária Brasileira: Nota Técnica.** Embrapa Gado de Corte. Campo Grande, 2017. Disponível em: <<https://www.bibliotecaagptea.org.br/zootecnia/bovinocultura/livros/NOTA%20TECNICA%20EMBRAPA%20GADO%20DE%20CORTE.pdf>>

HAYKIN, S. **Redes neurais: princípios e prática.** 2. ed. Bookman Editora, 2001.

He, K.; Zhang, X.; Ren, S.; Sun, J. “**Deep residual learning for image recognition,**” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.[Online]. Available: http://openaccess.thecvf.com/content_cvpr_2016/html/He_Deep_Residual_Learning_CVPR_2016_paper.html

KOONCE, B; **Convolutional Neural Networks with Swift for Tensorflow.** Disponível: Jefferson, MO, USA. 2021;

MELO, A. F. et al. **Fatores que influenciam na qualidade da carne bovina: Revisão.** Publicações em Medicina Veterinária e Zootecnia, v. 10, n. 10, p. 785- 794, 2016.

MITCHELL, T. M. **Machine Learning.** 1. st ed. New York: McGraw-Hill, 1997. Disponível em: <<https://www.cs.cmu.edu/~tom/files/MachineLearningTomMitchell.pdf>>.

MURPHY, K. P. **Machine Learning: A Probabilistic Perspective.** 1. ed. [S.l.: s.n.]: The MIT Press, 2012. (Adaptive Computation and Machine Learning). ISBN 9780262018029.

ORSINI, H. B; FERNANDES, E. **Fisiopatologia do Estresse em Animais Selvagens em Cativeiro e suas Implicações no Comportamento e Bem-estar - revisão de literatura.** Revista do Instituto Ciência Saúde, v. 24, n. 1, p. 7-13, 2006.

PACHECO, C.; PEREIRA, N. **Deep Learning Conceitos e Utilização nas Diversas Áreas do Conhecimento.** Centro Universitário de Anápolis (UniEVANGÉLICA), 2018. Disponível em:<https://www.researchgate.net/profile/Natasha-Pereira-9/publication/334654445_Deep_Learning_Conceitos_e_Utilizacao_nas_Diversas_Areas_do_

Conhecimento/links/5d3869aa299bf1995b470f21/Deep-Learning-Conceitos-e-Utilizacao-nas-Diversas-Areas-do-Conhecimento.pdf>

RICARTES DA SILVA, A. L.; DE JESUS SOUZA, R.; CARDOSO, P. E. A.; NESPOLO, R. G. “**Embedded Machine Learning Solution for Soil Phosphorus and Potassium Sensing,**” Interface Tecnológica, vol. 22, no. 1, 2025.

ROSA, J. P; **Endocrinologia do estresse e Importância no Bem-estar Animal.** Universidade Federal do Rio Grande do Sul, 2003.

SANTOS, E. O. **Metabolismo do Estresse: impactos na saúde e na produção animal.** Universidade Federal do Rio Grande do Sul, 2005.

SENAR, C. **Bovinocultura: manejo e alimentação de bovinos de corte em confinamento.** 232. ed. Brasília, 2018. Disponível em: <<https://www.cnabrazil.org.br/assets/arquivos/232-BOVINOCULTURA.pdf>>.