

CENTRO ESTADUAL DE EDUCAÇÃO TECNOLÓGICA “PAULA SOUZA”

FACULDADE DE TECNOLOGIA DE BEBEDOURO

TECNOLOGIA EM BIG DATA NO AGRONEGÓCIO

**PREVISÃO DE PESO DE GADO POR
SIMILARIDADE ENTRE IMAGENS**

AUTOR: JULIO CESAR HONÓRIO DA SILVA

ORIENTADOR: PROF. DR. RENAN GUILHERME NESPOLO

BEBEDOURO

2025

JULIO CESAR HONÓRIO DA SILVA

**PREVISÃO DE PESO DE GADO POR
SIMILARIDADE ENTRE IMAGENS**

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

"Nossos maiores sucessos não estão em nunca cair, mas em nos levantarmos cada vez que caímos."

Confúcio

Agradecimentos

Com todo o meu carinho e profunda gratidão, expresso meus agradecimentos a:

Minha filha, Nétely Kateryne, por sempre acreditar em mim e me apoiar incondicionalmente. Seu amor, paciência e incentivo foram pilares fundamentais que sustentaram minha caminhada até aqui. Sou eternamente grato(a) por sua presença constante e inspiradora.

Ao meu orientador, Prof. Renan, pela orientação dedicada, pelo apoio constante e pelas valiosas contribuições ao longo desta jornada. Seu conhecimento, disponibilidade e comprometimento foram essenciais para a concretização deste trabalho.

Aos meus amigos Guilherme e Paulo, por estarem ao meu lado em todos os momentos. Suas palavras de encorajamento, compreensão e companheirismo fizeram toda a diferença nos momentos mais desafiadores.

E a todos que, de alguma forma, contribuíram direta ou indiretamente para a realização deste projeto, deixo aqui meu mais sincero agradecimento.

SILVA, J. C. H. da. **Previsão de peso de gado por similaridade entre imagens**. Trabalho de Graduação (Monografia). Centro Estadual de Educação Tecnológica “Paula Souza”. Faculdade de Tecnologia de Bebedouro. 47 p. 2025.

RESUMO

A determinação do peso de bovinos é essencial para o manejo nutricional adequado, definição da quantidade ideal de ração, controle sanitário e negociações comerciais na pecuária de corte. No entanto, o processo tradicional de pesagem, que envolve o deslocamento dos animais até o curral e sua contenção em balanças, pode gerar estresse significativo, comprometendo o desempenho e o bem-estar dos animais. Diante desse cenário, este trabalho propõe a utilização de um algoritmo capaz de estimar o peso de bovinos por meio da análise de imagens, utilizando técnicas de aprendizagem máquina. O objetivo principal é reduzir a necessidade de manejo físico, promovendo maior conforto aos animais e aumentando a eficiência no processo produtivo. Além disso, são realizadas análises comparativas com outros métodos para validar a eficácia da abordagem proposta. A adoção de soluções tecnológicas como contribuição para uma pecuária voltada ao bem-estar animal.

Palavras-chave: bovinos, pesagem, bem-estar animal, aprendizagem máquina, previsão de peso.

SILVA, J. C. H. da. **Previsão de peso de gado por similaridade entre imagens**. Trabalho de Graduação (Monografia). Centro Estadual de Educação Tecnológica “Paula Souza”. Faculdade de Tecnologia de Bebedouro. 47 p. 2025.

ABSTRACT

Accurately determining cattle weight is essential for proper nutritional management, figuring out the ideal amount of feed, health control, and commercial negotiations in beef cattle farming. However, the traditional weighing process, which involves moving animals to the corral and restraining them on scales, can bring significant stress, compromising animal performance and welfare. Considering what was stated, this work proposes the adoption of an algorithm capable of estimating beef cattle weight through image analysis, using machine learning techniques. The main objective is to reduce the need for physical handling, promoting greater comfort for the animals and increasing efficiency in the production process. In addition, comparative analyses are performed with other methods to validate the effectiveness of the proposed approach. The adoption of technological solutions as a contribution to livestock farming focused on the animal welfare.

Keywords: *beef cattle, weight, animal welfare, machine learning, weight prediction.*

SUMÁRIO

1	INTRODUÇÃO	15
1.1	JUSTIFICATIVA.....	15
1.2	OBJETIVOS	15
2	FUNDAMENTAÇÃO TEÓRICA.....	16
2.1	PESAGEM ANIMAL.....	16
2.2	A RELEVÂNCIA DA PESAGEM.....	18
2.3	BALANÇAS INTELIGENTES	20
2.4	APRENDIZAGEM BASEADA EM INSTÂNCIAS (IBL)	20
2.5	K-NN (K-NEAREST NEIGHBORS).....	22
2.6	VALIDAÇÃO CRUZADA (K-FOLD CROSS-VALIDATION).....	23
2.7	MAE (MEAN ABSOLUTE ERROR).....	24
2.8	RMSE (ROOT MEAN SQUARE ERROR)	25
3	MATERIAIS E MÉTODOS	26
3.1	DATASET	26
3.2	DESENVOLVIMENTO E AVALIAÇÃO	32
3.3	PRÉ-PROCESSAMENTO DAS IMAGENS	33
3.4	TREINAMENTO DO MODELO K-NN	34
3.5	AVALIAÇÃO DE DESEMPENHO COM O MAE E O RMSE	35
4	RESULTADOS	36
4.1	ANALISANDO OS DATASET	43
5	CONCLUSÃO	45
	REFERÊNCIAS	46

LISTA DE FIGURAS

FIGURA 1 - BALANÇA MECÂNICA.....	17
FIGURA 2 - BALANÇA DIGITAL.....	17
FIGURA 3 - BOVINOS GANHANDO PESO.	19
FIGURA 4 - EVOLUÇÃO MARGEM LUCRO.....	19
FIGURA 5 - NOVAS TECNOLOGIAS DE PESAGEM	20
FIGURA 6 - AMOSTRA DE IMAGEM LATERAL DE UM ANIMAL, EXTRAÍDA DO DATASET B2.	27
FIGURA 7 - AMOSTRA DA SILHUETA RGB DO DATASET B2, REFERENTE À POSIÇÃO LATERAL, COM TRATAMENTO DE SEGMENTAÇÃO APLICADO PELO AUTOR DO DATASET.....	28
FIGURA 8 - AMOSTRA DE IMAGEM TRASEIRA DE UM ANIMAL, EXTRAÍDA DO DATASET B2.	28
FIGURA 9 - AMOSTRA DA SILHUETA RGB DO DATASET B2, REFERENTE À POSIÇÃO TRASEIRA, COM TRATAMENTO DE SEGMENTAÇÃO APLICADO PELO AUTOR DO DATASET.....	29
FIGURA 10 - AMOSTRA DE IMAGEM LATERAL DE UM ANIMAL, EXTRAÍDA DO DATASET B3.	29
FIGURA 11 - AMOSTRA DA SILHUETA RGB DO DATASET B3, REFERENTE À POSIÇÃO LATERAL, COM TRATAMENTO DE SEGMENTAÇÃO APLICADO PELO AUTOR DO DATASET.....	30
FIGURA 12 - AMOSTRA DE IMAGEM LATERAL DE UM ANIMAL, EXTRAÍDA DO DATASET B4.	30
FIGURA 13 - AMOSTRA DA SILHUETA RGB DO DATASET B4, REFERENTE À POSIÇÃO LATERAL, COM TRATAMENTO DE SEGMENTAÇÃO APLICADO PELO AUTOR DO DATASET.....	31
FIGURA 14 - AMOSTRA DE IMAGEM TRASEIRA DE UM ANIMAL, EXTRAÍDA DO DATASET B2.	31

FIGURA 15 -AMOSTRA DA SILHUETA RGB DO DATASET B2, REFERENTE À POSIÇÃO TRASEIRA, COM TRATAMENTO DE SEGMENTAÇÃO APLICADO PELO AUTOR DO DATASET.....	32
--	-----------

LISTA DE TABELAS

TABELA 1 -10-FOLD-VALIDATION DO DATASET IMAGES B2 UTILIZANDO AS IMAGENS COM O TRATAMENTO TONS DE CINZA COM O ANIMAL NA POSIÇÃO LATERAL.	37
TABELA 2 -10-FOLD-VALIDATION DO DATASET ANNOTATION B2 UTILIZANDO AS IMAGENS DA SILHUETA COM O TRATAMENTO RGB COM O ANIMAL NA POSIÇÃO LATERAL.	37
TABELA 3 -10-FOLD-VALIDATION DO DATASET IMAGES B2 UTILIZANDO AS IMAGENS COM O TRATAMENTO TONS DE CINZA COM O ANIMAL NA POSIÇÃO TRASEIRA.	38
TABELA 4 -10-FOLD-VALIDATION DO DATASET ANNOTATION B2 UTILIZANDO AS IMAGENS DA SILHUETA COM O TRATAMENTO RGB COM O ANIMAL NA POSIÇÃO TRASEIRA.	38
TABELA 5 -10-FOLD-VALIDATION DO DATASET IMAGES B3 UTILIZANDO AS IMAGENS COM O TRATAMENTO TONS DE CINZA COM O ANIMAL NA POSIÇÃO LATERAL.	39
TABELA 6 -10-FOLD-VALIDATION DO DATASET ANNOTATION B3 UTILIZANDO AS IMAGENS DA SILHUETA COM O TRATAMENTO RGB COM O ANIMAL NA POSIÇÃO LATERAL.	40
TABELA 7 -10-FOLD-VALIDATION DO DATASET IMAGES B4 UTILIZANDO AS IMAGENS COM O TRATAMENTO TONS DE CINZA COM O ANIMAL NA POSIÇÃO LATERAL.	41
TABELA 8 -10-FOLD-VALIDATION DO DATASET ANNOTATION B4 UTILIZANDO AS IMAGENS DA SILHUETA COM O TRATAMENTO RGB COM O ANIMAL NA POSIÇÃO LATERAL.	41
TABELA 9 -10-FOLD-VALIDATION DO DATASET IMAGES B4 UTILIZANDO AS IMAGENS COM O TRATAMENTO TONS DE CINZA COM O ANIMAL NA POSIÇÃO TRASEIRA	42

TABELA 10 -10-FOLD-VALIDATION DO DATASET ANNOTATION B4 UTILIZANDO AS IMAGENS DA SILHUETA COM O TRATAMENTO RGB COM O ANIMAL NA POSIÇÃO TRASEIRA.	42
---	-----------

LISTA DE GRÁFICOS

GRÁFICO 1 - COMPARAÇÃO MAE ENTRE OS DATASETS (POSIÇÃO LATERAL).....44

GRÁFICO 2 - COMPARAÇÃO RMSE ENTRE OS DATASETS (POSIÇÃO LATERAL).....44

LISTA DE EQUAÇÕES

EQUAÇÃO (1) VETOR DE ATRIBUTOS.....	22
EQUAÇÃO (2) DISTÂNCIA EUCLIDIANA.....	22
EQUAÇÃO (3) MAE (MEAN ABSOLUTE ERROR)	24
EQUAÇÃO (4) RMSE (ROOT MEAN SQUARE ERROR).....	25

LISTA DE SIGLAS

CV - Cross-Validation (Validação Cruzada).

GS - Gray Scale (Escala de Cinza).

IA - Artificial Intelligence (Inteligência Artificial).

IBL - Instance-Based Learning (Aprendizado Baseado em Instâncias).

k-Fold - k-Fold Cross-Validation (Validação Cruzada k-Fold).

K-NN - k-Nearest Neighbors (k-Vizinhos Mais Próximos).

MAE - Mean Absolute Error (Erro Médio Absoluto).

ML - Machine Learning (Aprendizado de Máquina).

MSE - Mean Squared Error (Erro Médio Quadrático).

RGB - Red, Green, Blue (Vermelho, Verde, Azul).

RMSE - Root Mean Square Error (Erro Quadrático Médio da Raiz).

1 INTRODUÇÃO

Levar os animais ao curral para realizar manejos e pesagens pode provocar ao gado de corte um estado de estresse, interferindo em seu ganho de peso e desenvolvimento. Sabendo disso, hoje no mercado da pecuária é muito importante saber o peso atual dos animais, pois as negociações do gado de corte são feitas com base no seu peso. Além disso, o peso do animal é um fator importante para que seja desenvolvida uma nutrição saudável e rica em nutrientes em sua ração, bem como de definir a quantidade diária ideal de ração para se ter o desempenho e obter o resultado desejável (Facundes, 2023).

1.1 JUSTIFICATIVA

A pesagem dos bovinos é uma atividade muito estressante para os animais, devido ao fato de serem transportados para outro local e terem que passar dentro da balança. Logo, é de extrema importância buscar métodos para realizar a pesagem dos animais, necessitando de pouco manejo e usando imagens dos animais você tem uma melhor qualidade de vida animal. Os animais, como o gado, sofrem uma carga de estresse devido à reação natural do animal, causado pela fome, medo, dor, barulho, entre outras situações agressivas que altera o metabolismo animal, prejudicando a qualidade final do produto (Mendonça *et al.*, 2016).

1.2 OBJETIVOS

Diante da importância da pesagem na gestão da produção de bovinos é crucial ter eficiência e rentabilidade nas operações pecuárias. Através da pesagem regular dos animais, é possível monitorar o desempenho individual e coletivo do rebanho, bem como identificar possíveis problemas de saúde. Além disso, a pesagem contribui para a gestão da nutrição do gado, permitindo ajustes nos programas de alimentação de acordo com as necessidades. Por meio desse estudo minucioso, temos como objetivo aprofundar a compreensão sobre os impactos da pesagem na produção de bovinos, fornecendo informações valiosas para os produtores rurais (Orsini; Bondan, 2006).

Nesse contexto, investir em técnicas que priorizam o bem-estar animal é uma estratégia inteligente para garantir a rentabilidade da produção pecuária. A adoção de técnicas inovadoras garantirá benefícios na cadeia produtiva, contribuindo para uma pecuária mais responsável e eficaz. As principais contribuições do presente trabalho são:

1. Previsão do peso bovino por meio das similaridades entre imagens utilizando o algoritmo de regressão k -NN;

2. Comparar os resultados gerados utilizando diferentes perspectivas do boi: lateral e traseira;
3. Comparar os resultados gerados utilizando diferentes fontes de dados: imagem do animal e silhueta do animal;
4. Validar o método utilizando *k-Fold Cross-Validation*.

O presente trabalho está segmentado em: Introdução, Fundamentação Teórica, Materiais e Métodos, Resultados Esperados, Conclusões e, 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 A Pesagem Animal; 2.2 A Relevância da Pesagem; 2.3 Balanças Inteligentes e 2.4 O Algoritmo de Aprendizagem Máquinas.

2.1 PESAGEM ANIMAL

Atualmente, a mensuração do peso de bovinos é predominantemente realizada por meio de balanças eletrônicas, as quais asseguram maior rapidez e precisão no processo. Além da aferição do peso corporal, esses dispositivos permitem o registro de informações complementares essenciais para a gestão zootécnica, como datas de vacinação e outros dados sanitários e produtivos.

Como alternativa a esse método, pode-se empregar a medição manual por meio de fita métrica, uma técnica de menor custo e, em determinadas situações, de boa precisão. Este procedimento consiste na medição da circunferência torácica do animal, sendo o peso corporal estimado a partir da multiplicação do valor obtido por um fator constante, usualmente 2,8, expressando o peso em quilogramas (COIMMA, 2025).

Adicionalmente, destaca-se a utilização da arroba como unidade de medida tradicional no setor pecuário. Nesse contexto, o peso vivo do animal é aferido antes do abate, enquanto, posteriormente, no frigorífico, procede-se à pesagem da carcaça. O rendimento da carcaça é então determinado pela razão entre o peso da carcaça e o peso vivo, cujo resultado é multiplicado por 100, expressando-se o rendimento em termos percentuais (COIMMA, 2025).

Dessa maneira, é fundamental ressaltar a importância de um controle rigoroso e preciso das pesagens no manejo e criação dos bovinos, uma vez que isso influencia diretamente no desenvolvimento e rendimento da criação. Com base em dados científicos e pesquisas de campo, expandiremos o conhecimento sobre esse assunto, demonstrando as melhores práticas e suas consequências positivas na produção de bovinos. Nesse sentido, esperamos proporcionar subsídios para que os produtores possam utilizar estratégias eficientes de pesagem e, assim, otimizar a saúde, o crescimento e o aproveitamento do gado, bem como os lucros e a sustentabilidade do negócio.


Portanto, este estudo pretende ir além do básico, explorando a relação entre pesagem e produção de bovinos de forma abrangente e embasada, visando à melhoria contínua e ao sucesso das atividades pecuária (Rodrigues, 2023; Silva, 2022).

Figura 1 - Balança Mecânica.



Fonte: O. FILIZOLA (2018).

Figura 2 - Balança Digital.



Fonte: TOLEDO DO BRASIL (2021).

2.2 A RELEVÂNCIA DA PESAGEM

A relevância da pesagem na gestão da produção de bovinos é fundamental e possui uma influência direta sobre o desempenho e a saúde do rebanho ao longo do tempo. Através do monitoramento regular do peso dos animais, é possível avaliar o ganho de peso de forma eficiente, identificando variações significativas que podem estar relacionadas a problemas de saúde e implementando estratégias precisas para otimizar a nutrição e o manejo (COIMMA, 2025).

A fase de engorda dos bois de corte no Brasil ainda acontece, na maioria das vezes, no pasto. Por isso, se a ideia é abater o animal mais cedo, com boa cobertura de gordura e carne de qualidade, é importante dar uma força na alimentação de preferência, durante toda a vida do boi (Transição de dietas, 2020) .

Antes de decidir qual suplemento usar, é bom dar uma olhada na quantidade e na qualidade do pasto disponível. Mesmo assim, geralmente os animais recebem um suplemento entre 6 e 10 gramas por quilo de peso vivo, o que ajuda a garantir um bom ganho de peso, chegando até 1 kg por dia (Serviço Nacional de Aprendizagem Rural, 2018).

Além disso, é importante ressaltar que a pesagem é um indicador-chave para a tomada de decisões no contexto da produção pecuária. Ela garante a sustentabilidade e eficiência das operações, possibilitando uma gestão mais precisa e embasada. Dessa maneira, a pesquisa e compreensão aprofundada desse tema se tornam ainda mais essenciais para a melhoria contínua das práticas de gestão do rebanho bovino, pois proporciona uma visão ampla e detalhada do desenvolvimento e crescimento dos animais, contribuindo para produção pecuária mais sustentável e lucrativo (CEPEA, 2025).

Segundo Malafaia et al. (2021), a elevação da demanda mundial por alimentos tem impulsionado o crescimento do agronegócio. Nesse contexto, países que possuem economias favorecidas por abundantes recursos naturais e que dispõem de cadeias agroexportadoras estruturadas de forma eficiente vêm se consolidando no cenário do comércio internacional, atuando de maneira estratégica para suprir as necessidades alimentares globais.

No contexto brasileiro, a pecuária de corte bovina destaca-se como uma das principais atividades do setor agropecuário, desempenhando um papel estratégico tanto no abastecimento interno quanto na geração de excedentes exportáveis. Entretanto, apesar do seu expressivo

potencial produtivo, a cadeia da carne bovina enfrenta desafios significativos relacionados à sustentabilidade ambiental, social e econômica. Questões como o uso responsável dos recursos naturais, a mitigação das emissões de gases de efeito estufa, o bem-estar animal e a rastreabilidade produtiva são aspectos cada vez mais exigidos pelos mercados consumidores e organismos internacionais (Malafaia *et al.*, 2021).

Figura 3 - Bovinos no processo de ganho de peso.



Fonte: (Bosch - pesquisafapesp, 2019).

Figura 4 - Evolução da Margem de Lucro.




Fonte: (Athenagro, dados Cepea, IEA, 2022).

2.3 BALANÇAS INTELIGENTES

A balança para animais é super importante na fazenda, e ter a oportunidade de levá-la até o gado para acompanhar como eles estão ganhando peso e se mantendo saudáveis, será de grande valor para o pecuarista. Usar a tecnologia de aprendizado de máquinas para pesar os animais está ficando cada vez mais popular, porque consegue-se automatizar o processo e fornecer dados precisos na hora. Isso ajuda a avaliar melhor como os animais estão se saindo e a tomar decisões mais assertivas. Além disso, as balanças inteligentes também ajudam a economizar dinheiro e aumentar a produtividade na fazenda (Jones, 2019).

Figura 5 - Novas tecnologias de pesagem
Novas tecnologias de pesagem ▲



Fonte: (Alexandre Affonso - pesquisafapesp, 2019)

Pecuaristas brasileiros estão começando a usar novas tecnologias para pesar o gado, uma tarefa importante, mas nem sempre fácil. Saber o peso dos animais ajuda a tomar decisões sobre venda, reprodução e saúde. Ainda assim, muitas fazendas usam o "olhômetro" ou pesam os bois só uma ou duas vezes por ano, geralmente na vacinação. Isso porque o método tradicional, com balança no curral, dá trabalho, estressa o animal e custa caro (Jones, 2019).

2.4 APRENDIZAGEM BASEADA EM INSTÂNCIAS (IBL)

O método de Aprendizagem Baseada em Instâncias (Instance-Based Learning - IBL) segue uma abordagem de uma simples armazenagem dos exemplos de treinamento sem realizar

uma generalização imediata. A generalização, nesse caso, é adiada até o momento em que uma nova instância precisa ser classificada ou avaliada. Quando isso ocorre, a nova instância é comparada com os exemplos previamente armazenados, analisando-se a sua relação com esses exemplos para, então, atribuir um valor ou uma categoria à função-alvo correspondente (Mitchell, 2013).

Devido à sua natureza, os métodos baseados em instâncias são frequentemente chamados de métodos de aprendizado "preguiçosos" (lazy learning), uma vez que postergam o processamento e a construção de modelos até o momento da previsão.

Uma das principais vantagens desse tipo de abordagem, conhecida como aprendizado tardio ou aprendizado lento, é a sua capacidade de realizar estimativas localizadas da função-alvo, ajustando-se especificamente a cada nova instância, ao invés de criar uma única generalização para todo o espaço de dados. Apesar das diversas vantagens, os métodos de aprendizado baseados em instâncias apresentam algumas limitações importantes que devem ser consideradas durante sua aplicação.

Uma das principais desvantagens dessas abordagens está relacionada ao alto custo computacional no momento da classificação de novas instâncias. Isso ocorre porque, diferentemente de outros métodos de aprendizado que realizam a maior parte do processamento durante a fase de treinamento, os algoritmos baseados em instâncias adiam grande parte da computação para o momento da predição. Como resultado, a consulta de uma nova instância pode exigir a análise e comparação com um grande número de exemplos armazenados, o que pode se tornar inviável em aplicações com grandes volumes de dados ou quando são necessárias respostas em tempo real (Mitchell, 2013).

Diante desse desafio, uma questão prática relevante é a adoção de técnicas de indexação eficiente dos exemplos de treinamento, com o objetivo de reduzir o tempo de busca e a quantidade de cálculos necessários durante o processo de classificação.

2.5 K-NN (K-NEAREST NEIGHBORS)

O método mais básico dentro da categoria de aprendizado baseado em instâncias é o algoritmo conhecido como k-Vizinhos mais próximos (k-Nearest Neighbors - k-NN). Este algoritmo parte do pressuposto de que todas as instâncias podem ser representadas como pontos em um espaço n-dimensional, onde cada dimensão corresponde a um atributo da instância. A definição de "vizinhos mais próximos" no k-NN é baseada, geralmente, na distância Euclidiana padrão, que mede a similaridade entre os pontos (Mitchell, 2013).

O algoritmo *k*-Nearest Neighbors (*k*-NN), ou *k*-vizinhos mais próximos, é um método de aprendizado supervisionado, amplamente utilizado tanto para tarefas de classificação quanto de regressão. Sua principal característica é utilizar a proximidade (distância) entre os dados para realizar previsões, partindo do princípio de que exemplos semelhantes tendem a estar próximos no espaço de características. Embora o k-NN possa ser aplicado tanto em regressão quanto em classificação, seu uso mais comum é em problemas de classificação, onde a decisão é baseada em uma votação majoritária entre os *k* vizinhos mais próximos do exemplo a ser classificado (IBM, 2025).

De forma mais precisa, considere uma instância arbitrária x , descrita por um vetor de atributos, apresentado pela equação 1:

$$x = (a_{1(x)}, a_{2(x)}, \dots, a_{n(x)}), \quad (1)$$

no qual $a_r(x)$ representa o valor do r -ésimo atributo da instância x e n é o número total de atributos.

Assim, a distância Euclidiana entre duas instâncias quaisquer x_i e x_j é dada pela equação 2:

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n (a_{r(x_i)} - a_{r(x_j)})^2}, \quad (2)$$

no qual $d(x_i, x_j)$ é dada pela distância entre as instâncias x_i e x_j , $(a_{r(x_i)} - a_{r(x_j)})^2$, a diferença ao quadrado entre o valor do atributo r em x_i e x_j .

Ou seja, a distância é calculada somando-se o quadrado das diferenças entre os valores

correspondentes de cada atributo das duas instâncias, seguido da extração da raiz quadrada. Essa medida permite ao algoritmo determinar quais instâncias de treinamento estão mais próximas da nova instância de consulta, baseando-se na similaridade entre os seus atributos. Vale destacar que, embora a distância Euclidiana seja a métrica mais comum, o k -NN pode ser implementado utilizando outras métricas de distância, como a distância de *Manhattan*, distância de *Minkowski*, entre outras, dependendo das características do problema e dos dados (Mitchell, 2013).

Além da simplicidade, o k -NN apresenta como vantagens a robustez a ruídos (quando bem parametrizado) e a eficiência em problemas com fronteiras de decisão complexas. No entanto, o desempenho do algoritmo pode ser sensível à escolha do valor de k , à escala dos dados e à presença de *outliers*.

2.6 VALIDAÇÃO CRUZADA (K-FOLD CROSS-VALIDATION)

Uma prática comum na construção de modelos preditivos é a divisão dos dados em dois subconjuntos: aproximadamente 80% para o treinamento do modelo e 20% para a validação. Contudo, quando o número de casos disponíveis para o treinamento é reduzido, essa abordagem apresenta limitações significativas. O principal problema é que o modelo pode não dispor de dados suficientes para um aprendizado eficiente, além de comprometer a precisão na estimativa do desempenho futuro, uma vez que o conjunto de validação também será pequeno.

Diante desse cenário, uma solução amplamente adotada é a validação cruzada (*Cross-Validation* - CV). Essa técnica consiste em dividir o conjunto de dados de treinamento em k subconjuntos (denominados *Folds*). Em seguida, o modelo é treinado k vezes, cada vez utilizando $k-1$ *Folds* para o treinamento e o *Fold* restante para a validação, de forma alternada, até que todos os *Folds* tenham sido utilizados como conjunto de validação uma vez. Ao final desse processo, calcula-se a média dos erros obtidos em cada rodada, utilizando esse valor como uma estimativa representativa do erro de teste do modelo (Murphy, 2014).

É importante destacar que, durante a validação cruzada, cada amostra do conjunto de dados é utilizada exatamente uma vez para validação e $(k-1)$ vezes para treinamento, o que contribui para uma avaliação mais robusta do desempenho do modelo. Um dos valores mais

utilizados para k é 5, configurando o método conhecido como validação cruzada com 5 *Folds* (Hyndman, 2014).

A escolha do valor de k na validação cruzada, especialmente em algoritmos como o k -Nearest Neighbors (k -NN), representa um exemplo típico de um problema mais amplo conhecido como seleção de modelo. Nessa etapa, o objetivo é determinar o modelo ou os parâmetros que proporcionam o melhor equilíbrio entre complexidade e capacidade de generalização (Hastie; Tibshirani; Friedman, 2009).

Por fim, ressalta-se que a validação cruzada é uma das metodologias mais utilizadas para esse tipo de avaliação, sendo uma ferramenta fundamental para aumentar a confiabilidade das análises, embora outras abordagens também possam ser consideradas conforme o contexto da pesquisa.

2.7 MAE (MEAN ABSOLUTE ERROR)

A métrica do Erro Médio Absoluto (MAE - *Mean Absolute Error*) constitui um indicador estatístico que mensura a média das discrepâncias absolutas entre os valores preditos por um modelo e os valores efetivamente observados. Após a construção do modelo, o MAE é amplamente empregado para aferir a exatidão das previsões, uma vez que sua formulação baseada na média das diferenças absolutas, fornece uma medida de erro de fácil interpretação, expressa nas mesmas unidades da variável de interesse. Matematicamente, seja $\hat{y}_i$ o valor estimado pelo modelo para a i -ésima observação e y_i o valor real correspondente, em um conjunto de N amostras. O MAE é então definido na equação 3:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|. \quad (3)$$

Em comparação com métricas que elevam o erro ao quadrado como o Erro Quadrático Médio (MSE), o MAE apresenta menor sensibilidade a outliers, preservando, entretanto, a capacidade de capturar variações nas falhas de previsão de forma intuitiva. Essa característica torna o MAE particularmente adequado em estudos nos quais se deseja avaliar o desempenho do modelo sem supervalorizar grandes discrepâncias (Hodson, 2022).

No contexto do monitoramento do peso animal, a adoção do MAE possibilita a quantificação direta do desvio médio das previsões em relação aos indicadores fisiológicos ou comportamentais observados, contribuindo para a identificação de eventuais deficiências nos algoritmos e orientando o refinamento das metodologias preditivas. Dessa forma, o MAE ajudará na validação e no aprimoramento dos modelos destinados e na comparação dos resultados gerados utilizando diferentes fontes de dados.

2.8 RMSE (ROOT MEAN SQUARE ERROR)

O Root Mean Square Error (RMSE), ou Raiz do Erro Quadrático Médio, é uma métrica amplamente utilizada para avaliar a precisão de modelos de regressão. Essa métrica mede a magnitude média dos erros entre os valores previstos pelo modelo e os valores reais observados. O RMSE é calculado a partir da raiz quadrada da média dos quadrados das diferenças entre os valores previstos e os valores reais (Géron, 2019).

Segundo Géron (2019), o RMSE é especialmente útil quando se deseja penalizar erros maiores de forma mais severa, já que os erros individuais são elevados ao quadrado antes da média ser calculada. Essa característica torna o RMSE uma métrica sensível a outliers, refletindo com maior intensidade a presença de grandes desvios entre as previsões e os valores observados. Matematicamente, seja o n é o número total das amostras, y_i representa os valores reais e $\hat{y}_i$ o valor representa os valores previstos pelo modelo. O RMSE é então definido na equação 3:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

Na prática, quanto menor o valor do RMSE, melhor o desempenho do modelo de regressão, indicando que as previsões estão, em média, mais próximas dos valores reais. Esta métrica é frequentemente utilizada para comparar diferentes modelos preditivos, como por exemplo, ao ajustar o parâmetro k no algoritmo k-Nearest Neighbors (k-NN) para regressão.

3 MATERIAIS E MÉTODOS

O presente estudo tem como objetivo inferir o peso diário de bovinos a partir de imagens digitais captadas por uma câmera tridimensional(3D), capazes de prever o peso do gado (Jones, 2019). Para a etapa de treinamento e posterior inferência do algoritmo preditivo, foram utilizadas imagens capturadas dos animais em duas posições distintas: lateral e traseira.

As imagens foram adquiridas em condições controladas, visando garantir a padronização dos ângulos de captura e a qualidade das informações visuais necessárias para o processamento computacional. Essas imagens serviram como base para o treinamento do modelo de aprendizado de máquina utilizado, além de serem empregadas durante os testes de validação para avaliar o desempenho da predição de peso.

3.1 DATASET

A obtenção dos dados utilizados neste estudo foi realizada com base em um trabalho recente que teve como foco a inferência do peso de bovinos por meio de imagens, considerando-se, como variáveis de interesse, as medidas de comprimento corporal e circunferência torácica dos animais (Roomy; Abu; Tonmoy, 2023).

O conjunto de dados é composto por um total de 15.000 imagens, organizadas da seguinte forma: 7.500 imagens reais, distribuídas. 5.050 imagens capturadas na posição lateral dos animais; 2.450 imagens capturadas na posição traseira. 7.500 imagens processadas no formato RGB, representando a silhueta dos animais, 5.050 imagens na posição lateral; 2.450 imagens na posição traseira (Acme AI | Company, 2023).

No total, foram utilizados dados de 5.050 animais, distribuídos em três conjuntos de dados (*Datasets*), denominados B2, B3 e B4, com as seguintes características: o *Dataset* B2, contém imagens de 510 animais, capturadas nas posições lateral e traseira; o *Dataset* B3, inclui imagens de 2.600 animais, exclusivamente na posição lateral, e; o *Dataset* B4, reúne imagens de 1.940 animais, também nas posições lateral e traseira (Roomy; Abu; Tonmoy, 2023).

Cada um desses *Datasets* apresenta uma estrutura organizada em duas pastas principais, correspondentes às posições de captura das imagens: Rear (traseira) e Side (lateral). Dentro de cada uma dessas pastas, encontram-se duas subpastas adicionais:

- *Images*: Que contém as imagens reais dos animais, registradas em formato colorido, refletindo as condições originais de captura.
- *Annotations*: Contém os filtros de silhueta RGB, esses filtros funcionam como máscaras de segmentação, nas quais cada região da imagem é destacada de acordo com a sua relevância para o estudo. A principal finalidade dessas anotações é evidenciar a silhueta do animal, permitindo que os modelos de aprendizagem de máquinas consigam identificar e separar com precisão o objeto de interesse do fundo.

A utilização dessa estrutura de dados é fundamental para o desenvolvimento de modelos de visão computacional, facilitando tarefas como segmentação de imagens, classificação de posição e extração de características morfológicas. Além disso, essa organização contribui diretamente para o aprimoramento do processo de treinamento e validação de algoritmos, especialmente na construção de soluções voltadas para a estimativa de peso e o monitoramento automático de animais.


É importante destacar que esse processo de tratamento foi realizado pelo próprio autor do *Dataset* (Acme AI | Company, 2023). Nas figuras 6, 7, 8, 9, 10, 11, 12, 13, 14 e 15 são apresentadas algumas amostras do *Dataset* utilizadas no presente estudo.

Figura 6 - Amostra de imagem lateral de um animal, extraída do Dataset B2.




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

Figura 7 - Amostra da silhueta RGB do *Dataset B2*, referente à posição lateral, com tratamento de segmentação aplicado pelo autor do Dataset.




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

Figura 8 - Amostra de imagem traseira de um animal, extraída do Dataset B2.



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

Figura 9 - Amostra da silhueta RGB do *Dataset B2*, referente à posição traseira, com tratamento de segmentação aplicado pelo autor do Dataset.




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

Figura 10 - Amostra de imagem lateral de um animal, extraída do Dataset B3.



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

Figura 11 - Amostra da silhueta RGB do *Dataset B3*, referente à posição lateral, com tratamento de segmentação aplicado pelo autor do Dataset.




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

Figura 12 - Amostra de imagem lateral de um animal, extraída do Dataset B4.




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

Figura 13 - Amostra da silhueta RGB do *Dataset B4*, referente à posição lateral, com tratamento de segmentação aplicado pelo autor do Dataset.




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

Figura 14 - Amostra de imagem traseira de um animal, extraída do Dataset B4.



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

Figura 15 - Amostra da silhueta RGB do *Dataset B4*, referente à posição traseira, com tratamento de segmentação aplicado pelo autor do Dataset.



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

3.2 DESENVOLVIMENTO E AVALIAÇÃO

O pré-processamento das imagens consistiu em converter as fotografias dos bovinos para escala de cinza, redimensioná-las para o tamanho padrão de 28x28 pixels, e posteriormente transformar cada imagem em um vetor unidimensional contendo 784 características (uma para cada pixel). Os rótulos de saída, representando o peso dos animais, foram extraídos diretamente dos nomes dos arquivos de imagem. Por fim, as imagens e seus respectivos pesos foram consolidados em uma matriz de dados para posterior aplicação do algoritmo k-Nearest Neighbors (k-NN) para regressão.

3.3 PRÉ-PROCESSAMENTO DAS IMAGENS

Nesta etapa, o objetivo principal foi transformar as imagens de bovinos em um formato adequado para o treinamento do modelo de regressão baseado em k-Nearest Neighbors (k-NN).

Inicialmente, todas as imagens foram carregadas a partir de um diretório específico contendo imagens dos animais. Essas imagens originais, com diferentes resoluções e formatos, passaram por um processo de conversão para escala de cinza (preto e branco). A conversão foi necessária para reduzir a dimensionalidade dos dados, eliminando informações de cor consideradas irrelevantes para a tarefa de predição de peso.

Após a conversão, as imagens foram redimensionadas para um tamanho fixo de 28x28 pixels, padronizando assim a resolução e garantindo que todas as amostras possuíssem a mesma quantidade de atributos. Essa escolha teve como base a necessidade de minimizar o custo computacional e, ao mesmo tempo, manter informações visuais suficientes para a tarefa de regressão.

Cada imagem foi então transformada em um vetor unidimensional contendo 784 características (28×28 pixels), esse formato vetorial é exigido pela maioria dos algoritmos de aprendizado supervisionado, incluindo o *k*-NN *Regressor* utilizado neste estudo. O valor do peso real de cada bovino, considerado como a variável dependente, foi extraído diretamente do nome dos arquivos de imagem, seguindo uma convenção estabelecida no *Dataset* original. Cada nome de arquivo continha, em uma de suas seções, a informação referente ao peso do animal.

Por fim, as imagens processadas e os respectivos rótulos foram consolidados em uma única matriz de dados, onde cada linha representava um exemplo de treinamento contendo os valores dos pixels (*features*) e o peso correspondente (*target*). Esse processo de pré-processamento garantiu a uniformidade e a qualidade dos dados utilizados nas etapas subsequentes de treinamento e validação do modelo de regressão.

3.4 TREINAMENTO DO MODELO K-NN

Após o pré-processamento das imagens, o conjunto de dados foi submetido ao processo de treinamento utilizando o algoritmo *k-Nearest Neighbors* (k-NN), aplicado na modalidade de regressão. O objetivo principal dessa etapa foi construir um modelo capaz de estimar o peso dos bovinos com base nas características extraídas das imagens, representadas por vetores de pixels. O algoritmo *k*-NN baseia-se no princípio de que exemplos próximos no espaço das características tendem a possuir respostas similares. No contexto deste trabalho, isso significa que bovinos com representações visuais semelhantes, em termos de pixelização da imagem, tendem a ter pesos semelhantes. Para cada imagem de teste, o *k*-NN calcula a distância euclidiana entre o exemplo de entrada e todas as amostras presentes no conjunto de treinamento. Em seguida, seleciona os K vizinhos mais próximos e determina a previsão de saída por meio da média aritmética dos pesos desses vizinhos (Raschka, 2018).

O valor de K (número de vizinhos) foi determinado empiricamente, buscando um equilíbrio entre baixa variância e baixo viés. Após testes preliminares, o valor de $K = 7$ foi escolhido, por ter apresentado melhor desempenho médio nas validações cruzadas. Além disso, para validar a eficácia do modelo, foi utilizada a técnica de validação cruzada *k-Fold*, com $k = 10$, que consistiu em dividir o conjunto de dados em 10 subconjuntos aproximadamente iguais, utilizando nove partes para treinamento e uma para teste, de forma rotativa. Esse processo garantiu uma avaliação mais robusta e menos suscetível a sobre ajuste (*overfitting*).

Durante cada iteração da validação cruzada, o modelo *k*-NN foi treinado utilizando o conjunto de treinamento específico daquela rodada, e posteriormente aplicado sobre os dados de teste para gerar as previsões de peso.

3.5 AVALIAÇÃO DE DESEMPENHO COM O MAE E O RMSE

A avaliação do desempenho preditivo do modelo foi realizada por meio de duas métricas estatísticas amplamente utilizadas em problemas de regressão: o *Root Mean Square Error* (RMSE) e o *Mean Absolute Error* (MAE).

O RMSE (Raiz do Erro Quadrático Médio) representa a raiz quadrada da média dos erros quadráticos entre os valores previstos pelo modelo e os valores reais observados. Essa métrica penaliza mais fortemente os grandes erros, pois os desvios são elevados ao quadrado antes da média ser calculada. Como consequência, o RMSE é particularmente sensível a *outliers*, evidenciando variações de maior magnitude nas previsões (James *et al.*, 2013).

Por outro lado, o MAE (Erro Absoluto Médio) calcula a média das diferenças absolutas entre os valores previstos e os valores reais. Diferentemente do RMSE, o MAE atribui o mesmo peso a todos os erros, independentemente de sua magnitude. Isso o torna uma métrica mais robusta em relação a *outliers*, fornecendo uma visão mais equilibrada do erro médio cometido pelo modelo (Kuhn; Johnson, 2013).

Durante o processo de validação cruzada *k-Fold*, com $k = 10$, o modelo foi treinado e testado em diferentes subconjuntos dos dados. A cada iteração, foram calculados tanto o RMSE quanto o MAE, permitindo uma análise comparativa do desempenho do modelo sob diferentes perspectivas, a obtenção dessas duas métricas proporcionou uma avaliação mais completa, pois enquanto o RMSE destacou os casos em que houve maiores desvios nas previsões, o MAE forneceu uma visão geral dos erros médios, sem influência desproporcional de valores extremos.

Os resultados obtidos demonstraram que o modelo *k*-NN apresentou desempenho consistente nas diferentes partições da validação cruzada, com valores de RMSE e MAE dentro de limites aceitáveis, considerando a complexidade do problema e as características do conjunto de dados. Essa análise combinada das métricas confirma que o modelo, mesmo utilizando uma abordagem simples e com uma base de características visuais extraídas de imagens de baixa resolução, foi capaz de fornecer estimativas razoáveis para o peso dos bovinos.

4 RESULTADOS

Este estudo utilizou os conjuntos de dados B2, B3 e B4, compostos por imagens de bovinos em diferentes posições e formatos de tratamento. As imagens foram processadas em duas principais formas: tons de cinza (GS), e silhuetas obtidas por meio de filtros RGB, sendo considerada apenas uma das componentes de cor (vermelho, verde ou azul) em cada experimento. Para avaliação do desempenho dos modelos, a métrica utilizada foi a Mean Absolute Error (MAE), com os valores de saída normalizados entre 0 e 1, além da sua conversão para a unidade de quilogramas, permitindo melhor interpretação dos resultados em termos reais de peso animal.

A validação dos modelos foi realizada com a técnica de Validação Cruzada 10-Fold, onde cada conjunto de dados foi dividido em 10 partes (Folds). O treinamento foi feito em 9 Folds e os testes em 1 Fold, repetindo o processo até que todas as amostras fossem usadas como teste.

Os experimentos com o Dataset B2 incluíram comparações entre imagens da traseira e laterais, analisando a diferença de desempenho entre as imagens em tons de cinza e as silhuetas filtradas na cor verde (G). Da mesma forma, com os conjuntos B3 e B4, foram realizadas análises semelhantes, comparando os diferentes tipos de tratamento de imagem e suas influências nas previsões de peso.

As Tabelas 1, 2, 3 e 4 correspondem aos resultados gerados utilizando o Dataset B2 apresentam os valores de MAE e, em alguns casos, também de RMSE, destacando as diferenças de desempenho entre os tipos de imagem, as posições de captura (traseira ou lateral) e os filtros aplicados.

Tabela 1 - 10-Fold-Validation do Dataset images B2 utilizando as imagens com o tratamento Tons de Cinza com o animal na posição lateral.

<i>Fold</i>	MAE (kg)	RMSE (kg)
<i>Fold 1</i>	29,5527	43,2167
<i>Fold 2</i>	35,8003	46,2827
<i>Fold 3</i>	26,3903	31,0209
<i>Fold 4</i>	34,0409	44,1742
<i>Fold 5</i>	32,1960	43,6675
<i>Fold 6</i>	32,7545	44,2527
<i>Fold 7</i>	25,8609	32,5582
<i>Fold 8</i>	42,3351	62,9432
<i>Fold 9</i>	35,6934	45,2183
<i>Fold 10</i>	29,7878	42,4026
Erro médio	32,4412	43,5737

Fonte: Elaborado pelo autor

Tabela 2 - 10-Fold-Validation do Dataset annotation B2 utilizando as imagens da silhueta com o tratamento RGB com o animal na posição lateral.

<i>Fold</i>	MAE (kg)	RMSE (kg)
<i>Fold 1</i>	29,6880	38,4411
<i>Fold 2</i>	31,6506	44,3445
<i>Fold 3</i>	28,0784	41,8788
<i>Fold 4</i>	34,6951	45,8429
<i>Fold 5</i>	35,5632	48,3699
<i>Fold 6</i>	29,0124	42,3231
<i>Fold 7</i>	40,9928	62,0867
<i>Fold 8</i>	28,8163	38,7790
<i>Fold 9</i>	30,0053	38,0392
<i>Fold 10</i>	35,5775	45,6114
Erro médio	32,4080	44,5717

Fonte: Elaborado pelo autor

Tabela 3 - 10-Fold-Validation do Dataset images B2 utilizando as imagens com o tratamento Tons de Cinza com o animal na posição traseira.

<i>Fold</i>	MAE (kg)	RMSE (kg)
<i>Fold 1</i>	36,3885	46,1272
<i>Fold 2</i>	32,4919	41,5738
<i>Fold 3</i>	31,6862	40,5907
<i>Fold 4</i>	25,7447	34,2885
<i>Fold 5</i>	32,5739	39,4086
<i>Fold 6</i>	37,7611	62,5845
<i>Fold 7</i>	34,4143	46,1365
<i>Fold 8</i>	30,3404	43,0329
<i>Fold 9</i>	33,6577	42,8744
<i>Fold 10</i>	36,7674	50,6405
Erro médio	33.1826	44,7258

Fonte: Elaborado pelo autor

Tabela 4 - 10-Fold-Validation do Dataset annotation B2 utilizando as imagens da silhueta com o tratamento RGB com o animal na posição traseira.

<i>Fold</i>	MAE (kg)	RMSE (kg)
<i>Fold 1</i>	30,6203	45,2444
<i>Fold 2</i>	38,2923	59,8477
<i>Fold 3</i>	29,3618	39,5984
<i>Fold 4</i>	26,8706	39,2235
<i>Fold 5</i>	31,5222	41,7123
<i>Fold 6</i>	36,0623	44,2052
<i>Fold 7</i>	27,2587	34,8382
<i>Fold 8</i>	35,0017	48,2836
<i>Fold 9</i>	27,8912	37,5634
<i>Fold 10</i>	31,5874	41,5938
Erro médio	31,4469	43,2110

Fonte: Elaborado pelo autor.

Ao analisar os resultados obtidos para o conjunto de dados B2, considerando especificamente as imagens com o animal na posição lateral, foi possível observar diferenças discretas entre os dois tipos de tratamento de imagem aplicados. Nas imagens processadas em tons de cinza (GS), o modelo obteve um MAE médio de 32,4412 kg e um RMSE médio de 43,5737 kg. Esses valores indicam um desempenho estável, com erro absoluto médio e erro quadrático médio dentro de uma faixa aceitável para a tarefa de predição de peso de bovinos.

Por outro lado, ao utilizar as imagens de silhueta obtidas por meio do filtro RGB (cor verde), também na posição lateral, o modelo apresentou um MAE médio de 32,4080 kg e um RMSE médio de 44,5717 kg. Embora o MAE seja levemente inferior ao obtido com as imagens em tons de cinza, o RMSE apresentou um valor um pouco mais elevado, indicando uma maior sensibilidade a erros maiores durante a predição. Essa comparação revela que, apesar da redução de informações visuais nas imagens de silhueta, o desempenho do modelo k -NN permaneceu bastante próximo ao alcançado com as imagens em tons de cinza. Isso demonstra que o método de aprendizado por instância foi capaz de extrair padrões relevantes mesmo em condições de menor riqueza de detalhes, o que pode ser considerado um aspecto positivo para aplicações em cenários com restrições de processamento ou armazenamento de imagens.

Além disso, a proximidade dos resultados entre os dois tipos de pré-processamento reforça a robustez da abordagem adotada, evidenciando que o k -NN, aliado ao processo de validação cruzada 10-Fold, manteve uma boa capacidade de generalização, independentemente da forma de representação visual utilizada.

Tabela 5 - 10-Fold-Validation do Dataset images B3 utilizando as imagens com o tratamento Tons de Cinza com o animal na posição lateral.

<i>Fold</i>	MAE (kg)	RMSE (kg)
<i>Fold 1</i>	33,8825	44,5839
<i>Fold 2</i>	37,6178	48,3644
<i>Fold 3</i>	38,4066	50,2130
<i>Fold 4</i>	33,0779	42,4555
<i>Fold 5</i>	34,2367	45,9517
<i>Fold 6</i>	38,5958	52,3125
<i>Fold 7</i>	36,3555	49,7061
<i>Fold 8</i>	36,5363	53,0133
<i>Fold 9</i>	36,8153	53,2946
<i>Fold 10</i>	34,3803	43,8065
Erro médio	35,9905	48,3702

Fonte: Elaborado pelo autor.

Tabela 6 - 10-Fold-Validation do Dataset annotation B3 utilizando as imagens da silhueta com o tratamento RGB com o animal na posição lateral.

<i>Fold</i>	MAE (kg)	RMSE (kg)
<i>Fold 1</i>	32,5230	41,6296
<i>Fold 2</i>	35,0398	45,3263
<i>Fold 3</i>	32,3762	41,6899
<i>Fold 4</i>	34,0283	45,6967
<i>Fold 5</i>	38,1339	55,3542
<i>Fold 6</i>	35,2318	46,4769
<i>Fold 7</i>	32,7986	41,1873
<i>Fold 8</i>	36,1195	49,5194
<i>Fold 9</i>	35,2961	45,6640
<i>Fold 10</i>	32,8157	42,8003
Erro médio	34,4363	45.5345

Fonte: Elaborado pelo autor.

Os resultados obtidos para o Dataset B3, apresentados nas Tabelas 5,6, considerando as imagens laterais, mostram que o tratamento em tons de cinza resultou em um MAE médio de 35,9905 kg e um RMSE de 48,3702 kg. Já as imagens de silhueta com filtro RGB (cor verde) apresentaram um MAE de 34,4363 kg e um RMSE de 45,5347 kg.

O modelo k -NN apresentou um desempenho levemente melhor com as imagens de silhueta, principalmente em relação ao RMSE, que foi menor, indicando uma redução nos erros de maior magnitude. Esse resultado sugere que, para o Dataset B3 na posição lateral, o uso de silhuetas filtradas pode ser uma alternativa viável ao tratamento em tons de cinza, com desempenho semelhante ou até superior em alguns casos.

Em um panorama amplo, os resultados demonstram a capacidade do modelo em realizar previsões com bom nível de acurácia, mesmo com diferentes tipos de pré-processamento das imagens.

Tabela 7 - 10-Fold-Validation do *Dataset* images B4 utilizando as imagens com o tratamento Tons de Cinza com o animal na posição lateral.

<i>Fold</i>	MAE (kg)	RMSE (kg)
<i>Fold 1</i>	30,5215	37,4211
<i>Fold 2</i>	28,0295	34,1384
<i>Fold 3</i>	31,5684	40,3595
<i>Fold 4</i>	28,2694	34,1988
<i>Fold 5</i>	31,9582	40,6102
<i>Fold 6</i>	30,0815	38,8914
<i>Fold 7</i>	27,3906	34,6914
<i>Fold 8</i>	29,2511	36,3724
<i>Fold 9</i>	27,1597	34,8206
<i>Fold 10</i>	29,2988	37,4348
Erro médio	29,3529	36,8939

Fonte: Elaborado pelo autor.

Tabela 8 - 10-Fold-Validation do *Dataset* annotation B4 utilizando as imagens da silhueta com o tratamento RGB com o animal na posição lateral.

<i>Fold</i>	MAE (kg)	RMSE (kg)
<i>Fold 1</i>	26,3158	33,3429
<i>Fold 2</i>	26,8242	34,8786
<i>Fold 3</i>	27,0960	34,4960
<i>Fold 4</i>	28,0708	34,7159
<i>Fold 5</i>	25,3847	31,4580
<i>Fold 6</i>	27,2183	35,6361
<i>Fold 7</i>	29,0895	37,1066
<i>Fold 8</i>	26,7216	34,7517
<i>Fold 9</i>	27,9859	35,3181
<i>Fold 10</i>	26,0853	32,4470
Erro médio	27,0792	34,4470

Fonte: Elaborado pelo autor.

Tabela 9 - 10-Fold-Validation do Dataset images B4 utilizando as imagens com o tratamento Tons de Cinza com o animal na posição traseira

<i>Fold</i>	MAE (kg)	RMSE (kg)
<i>Fold 1</i>	27,0740	34,0186
<i>Fold 2</i>	29,2539	37,5574
<i>Fold 3</i>	28,9376	36,1245
<i>Fold 4</i>	28,1170	35,1060
<i>Fold 5</i>	30,6040	38,3941
<i>Fold 6</i>	31,8102	41,1769
<i>Fold 7</i>	31,3188	40,6352
<i>Fold 8</i>	32,6368	39,4502
<i>Fold 9</i>	27,3523	34,2370
<i>Fold 10</i>	27,8825	34,5297
Erro médio	29,4987	37,1230

Fonte: Elaborado pelo autor.

Tabela 10 - 10-Fold-Validation do Dataset annotation B4 utilizando as imagens da silhueta com o tratamento RGB com o animal na posição traseira.

Fold	MAE (kg)	RMSE (kg)
Fold 1	26,9451	34,1351
Fold 2	27,2614	33,9151
Fold 3	28,2263	34,6944
Fold 4	28,3720	36,3206
Fold 5	26,3987	33,2271
Fold 6	24,2614	31,3379
Fold 7	27,5030	34,4330
Fold 8	29,1808	38,2506
Fold 9	28,4343	37,5509
Fold 10	26,9272	34,4289
Erro médio	27,3510	34,8294

No caso do Dataset B4, apresentados pelas Tabelas 7,8,9 e 10, considerando as imagens laterais, o modelo apresentou um MAE médio de 29,3529 kg e um RMSE de 36,8939 kg ao utilizar o tratamento em tons de cinza. Já com as imagens de silhueta filtradas na cor verde

(RGB), os resultados foram um MAE de 27,0792 kg e um RMSE de 34,4470 kg. Estes dados indicam que, para o Dataset B4, o uso de silhuetas proporcionou uma leve melhoria no desempenho do modelo, com redução tanto no MAE quanto no RMSE, em comparação com as imagens em tons de cinza. Essa diferença sugere que, nesta configuração, o pré-processamento por silhueta com filtro RGB foi mais eficaz para a tarefa de predição de peso.

De modo geral, os resultados com o B4 reforçam a capacidade do modelo kNN, aliado à validação cruzada 10-Fold, em realizar previsões com baixa margem de erro, mesmo quando se utilizam imagens com menos informações visuais.

4.1 ANALISANDO OS DATASET

Ao comparar os resultados obtidos para os três conjuntos de dados (B2, B3 e B4) com o animal na posição lateral, observam-se diferenças relevantes no desempenho do modelo kNN em função do tipo de tratamento de imagem e do Dataset utilizado. De maneira geral, o Dataset B4 apresentou os menores valores de erro, com destaque para o MAE médio de 27,0792 kg e o RMSE de 34,4470 kg quando utilizadas as imagens de silhueta com filtro RGB (cor verde). Esse resultado indica uma maior precisão nas predições para o B4, em comparação aos demais conjuntos.


O Dataset B2 apresentou valores intermediários, com MAE médio em torno de 32,44 kg (tons de cinza) e 32,40 kg (silhueta RGB), mostrando desempenho semelhante entre os dois tipos de imagem.

Já o Dataset B3, apesar de ter apresentado os maiores valores de MAE e RMSE, demonstrou que a utilização das silhuetas também resultou em um desempenho ligeiramente superior ao tratamento em tons de cinza, com redução do erro absoluto e do erro quadrático médio.

A comparação entre os três Datasets indica que o desempenho do modelo pode ser influenciado tanto pela qualidade e quantidade de informações presentes nas imagens quanto pelas características intrínsecas de cada conjunto de dados. Além disso, o fato de que, em alguns casos, as imagens de silhueta apresentaram desempenho igual ou melhor que as imagens em tons de cinza reforça a robustez da abordagem baseada em aprendizado por instância (k - NN), mesmo quando se trabalha com imagens com menor nível de detalhe.


Esses resultados destacam ainda a importância do pré-processamento das imagens e da escolha do conjunto de dados, que podem impactar diretamente a precisão das predições em tarefas de estimativa de peso de bovinos por meio de Visão Computacional. Abaixo nos Gráficos 1 e 2 são apresentados a comparação entre as imagens de silhueta e tons de cinza, sendo o Gráfico 1, utilizando a métrica de avaliação MAE e o Gráfico 2 a métrica RMSE.

Gráfico 1 - Comparação MAE entre os *Datasets* (Posição Lateral).



Fonte: Elaborada pelo autor.

Gráfico 2 - Comparação RMSE entre os *Datasets* (Posição Lateral).



Fonte: Elaborada pelo autor.

5 CONCLUSÃO

O presente trabalho teve como objetivo desenvolver um modelo preditivo capaz de estimar o peso de bovinos a partir de imagens, utilizando o algoritmo k -NN na abordagem de regressão. A metodologia aplicada envolveu desde o pré-processamento das imagens, passando pela transformação dos dados em vetores numéricos, até a etapa de treinamento e validação do modelo, com foco especial na análise de desempenho por meio das métricas RMSE e MAE.

O processo de pré-processamento foi fundamental para adequar as imagens a um formato compatível com o algoritmo, permitindo a redução da dimensionalidade sem perda excessiva de informações relevantes. A utilização da escala de cinza e o redimensionamento das imagens para 28×28 pixels possibilitaram a criação de um conjunto de dados compacto e eficiente. O treinamento do modelo k -NN, aliado à validação cruzada k -Fold, permitiu uma avaliação mais robusta da capacidade preditiva do método. A análise das métricas de desempenho indicou que o modelo foi capaz de realizar previsões com níveis aceitáveis de erro, considerando-se a natureza complexa da variável de interesse (peso dos animais) e as limitações impostas pela representação das imagens em baixa resolução.

A inclusão de duas métricas distintas RMSE e MAE, foi importante para fornecer uma análise mais completa. Enquanto o RMSE evidenciou os casos de maiores desvios nas previsões, o MAE apresentou uma visão geral do erro médio absoluto, minimizando o impacto de valores discrepantes.

Embora os resultados sejam promissores, é importante reconhecer as limitações inerentes ao uso do k -NN, como a sensibilidade à escolha do número de vizinhos (K) e a dependência de uma boa representação das amostras no conjunto de treinamento.

Como perspectivas para trabalhos futuros, recomenda-se a experimentação de métodos mais avançados, como redes neurais convolucionais (CNNs), além da extração de características mais descritivas das imagens, como medidas dos estudos dos componentes ou análise de textura. A ampliação e diversificação do conjunto de dados também pode contribuir para a melhoria da capacidade de generalização do modelo.

Por fim, conclui-se que a aplicação de técnicas de aprendizado de máquina, mesmo com algoritmos mais simples como o k -NN, pode ser uma alternativa viável e acessível para estimar de forma não invasiva o peso de bovinos, trazendo benefícios para a pecuária de precisão e para a tomada de decisão no manejo animal.

REFERÊNCIAS

- ACME AI | COMPANY. 2023. **Dataset**. Disponível em: <https://www.acmeai.tech/company>. Acesso em: 29 jun. 2025.
- CEPEA. PIB do Agronegócio Brasileiro. 2025. **Centro de Estudos Avançados em Economia Aplicada - CEPEA-Esalq/USP**. [Desenvolvimento de Sites]. Disponível em: <https://www.cepea.org.br/br/pib-do-agronegocio-brasileiro.aspx>. Acesso em: 29 jun. 2025.
- COIMMA. Pesagem de bovinos. 2025. **Como é feito o cálculo e os principais métodos!** Disponível em: <https://www.coimma.com.br/blog/post/pesagem-de-bovinos>. Acesso em: 16 jun. 2025.
- FACUNDES, D. Pecuária do Futuro. 2023. **Como evitar o estresse do gado durante a pesagem**. Disponível em: <https://blog.jetbov.com/2023/05/30/como-evitar-o-estresse-do-gado-durante-a-pesagem>. Acesso em: 11 jun. 2025.
- GÉRON, A. **Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow**. [S. l.: s. n.], 2019.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning**. Second Edition. New York: Springer New York, 2009.
- HODSON, T. O. Geoscientific Model Development. **Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not**, [s. l.], v. 15, n. 14, p. 5481–5487, 19 jul. 2022. <https://doi.org/10.5194/gmd-15-5481-2022>.
- HYNDMAN, R. J. **Forecasting: Principles & Practice**. University of Western Australia: OTexts.org, 2014.
- IBM, I. B. **O que é o algoritmo k-nearest neighbors (KNN)**. 2025. Disponível em: <https://www.ibm.com/br-pt/think/topics/knn>. Acesso em: 16 jun. 2025.
- JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An Introduction to Statistical Learning**. New York, NY: Springer New York, 2013. v. 103, (Springer Texts in Statistics). DOI 10.1007/978-1-4614-7138-7. Disponível em: <http://link.springer.com/10.1007/978-1-4614-7138-7>. Acesso em: 29 jun. 2025.
- JONES, F. **O peso do boi**. 2019. **Revista Pesquisa FAPESP**. [Revista]. Disponível em: <https://revistapesquisa.fapesp.br/o-peso-do-boi/>. Acesso em: 11 jun. 2025.
- KUHN, M.; JOHNSON, K. **Applied Predictive Modeling**. New York, NY: Springer New York, 2013. DOI 10.1007/978-1-4614-6849-3. Disponível em: <http://link.springer.com/10.1007/978-1-4614-6849-3>. Acesso em: 29 jun. 2025.
- MALAFAIA, G. C.; MORES, G. D. V.; CASAGRANDA, Y. G.; BARCELLOS, J. O. J.; COSTA, F. P. **The Brazilian beef cattle supply chain in the next decades**. *Livestock Science*, [s. l.], v. 253, p. 104704, nov. 2021. <https://doi.org/10.1016/j.livsci.2021.104704>.

MENDONÇA, F. S.; VAZ, R. Z.; COSTA, O. A. D.; GONÇALVES, G. V. B.; MOREIRA, S. M. **Fatores que afetam o bem-estar de bovinos durante o período pré-abate**. Archivos de Zootecnia, [s. l.], v. 65, n. 250, p. 279–287, 11 jun. 2016. <https://doi.org/10.21071/az.v65i250.500>.

MITCHELL, T. M. **Machine learning**. Nachdr. New York: McGraw-Hill, 2013(McGraw-Hill series in Computer Science).

MURPHY, K. P. **Machine Learning - A Probabilistic Perspective**. Cambridge: MIT Press, 2014(Adaptive Computation and Machine Learning).

O PRESENTE RURAL. 1 out. 2020. **Transição de dietas: o que fazer para minimizar os prejuízos ruminais**. Disponível em: <https://opresenterural.com.br/transicao-de-dietas-o-que-fazer-para-minimizar-os-prejuizos-ruminais/>. Acesso em: 29 jun. 2025.

ORSINI, H.; BONDAN, E. F. **Fisiopatologia do estresse em animais selvagens em cativeiro e suas implicações no comportamento e bem-estar animal** – revisão da literatura. [s. l.], 2006. .

RASCHKA, S. **Machine Learning Lecture Notes**. Madison: University of Wisconsin, 2018.

RODRIGUES, D. C. **Utilização de Inteligência Artificial na bovinocultura de corte**. [s. l.], 15 jun. 2023. Disponível em: <https://repositorio.pucgoias.edu.br/jspui/handle/123456789/6249>. Acesso em: 19 jun. 2025.

ROOMY, S.; ABU, A. B. S.; TONMOY, A. M. **Cattle Weight Detection Model**. 2023. Disponível em: <https://www.kaggle.com/datasets/sadhliroomyprime/cattle-weight-detection-model-dataset-12k>. Acesso em: 22 jun. 2025.

SERVIÇO NACIONAL DE APRENDIZAGEM RURAL. **Bovinocultura: manejo e alimentação de bovinos de corte em confinamento**. [S. l.]: Senar, 2018. v. 232, .

SILVA, L. F. dos S. da. **Desenvolvimento de um aplicativo android para gerenciamento de rebanho bovino de corte**. [s. l.], jun. 2022. Disponível em: <https://ric.cps.sp.gov.br/handle/123456789/23164>. Acesso em: 19 jun. 2025.