

# Predição de Pesos de Bovinos de Corte utilizando Visão Computacional

Roniel N. Barbosa<sup>1</sup>, Jhonata M. da Costa<sup>1</sup>, Vítor L. G. Silva<sup>1</sup>, Nathália Souza<sup>2</sup>,  
Mário Chizzotti<sup>2</sup>, Ricardo S. Ferreira<sup>3</sup>, José Augusto M. Nacif<sup>1</sup>

<sup>1</sup>Instituto de Ciências Exatas e Tecnológicas – Florestal – MG

<sup>2</sup>Departamento de Zootecnia – Viçosa – MG

<sup>3</sup>Departamento de Informática – Viçosa – MG  
Universidade Federal de Viçosa (UFV)

{roniel.barbosa, jnacif}@ufv.br

**Resumo.** *O monitoramento do peso de bovinos de corte é de extrema importância para os produtores rurais. Esta proposta busca prever o peso dos animais de forma automática com ênfase na extração de informações presentes nas imagens, mediante a utilização de visão computacional e algoritmos de aprendizado de máquina. Em contraste ao método convencional com balanças mecânicas, a nova abordagem propõe a geração de um conjunto de dados contendo imagens de bovinos, utilizadas para treinar um modelo U-NET capaz de realizar a segmentação do animal. Em seguida, são extraídos atributos relevantes e modelos de aprendizado de máquina são treinados para prever o peso do bovino. A implementação da abordagem foi realizada em Python, executada nas plataformas Google Colab e Google Cloud Virtual Machines. Os resultados obtidos demonstram a eficácia da proposta, com uma Mean Absolute Error (MAE) de 12,83kg.*

## 1. Introdução

O monitoramento do peso do gado de corte é essencial para os produtores do agropêlo, pois permite controlar a saúde dos animais, melhorar a seleção genética e determinar o momento ideal para o abate [LUDTKE 2012]. Isso é fundamental para o sucesso da produção de carne bovina, uma atividade econômica relevante em vários países, incluindo o Brasil. No primeiro trimestre de 2023, por exemplo, o país produziu aproximadamente 2 bilhões de quilos de carne bovina, segundo o IBGE [Instituto Brasileiro de Geografia e Estatística 2023]. A bovinocultura desempenha um papel fundamental na alimentação global, contando com o auxílio da computação para impulsionar sua eficiência. Conforme destacado por [Liakos et al. 2018], essa combinação estratégica busca aumentar a produtividade, detectar doenças precocemente e garantir o fornecimento de proteína animal, leite e outros derivados provenientes do gado bovino.

Atualmente, a pesagem do gado é predominantemente realizada por meio de métodos mecânicos que muitas vezes são rudimentares e envolvem o uso de balanças mecânicas expostas ao ambiente, sujeitas a danos causados por forças da natureza e ferrugem [Wang et al. 2021]. Essas balanças exigem manutenção e inspeções constantes para evitar resultados imprecisos por falha sistêmica, fazendo com que seja de grande importância desenvolver uma abordagem mais simples e robusta para a pesagem.

As principais contribuições deste trabalho são realizar a predição de peso, com ênfase em extrair atributos por meio da visão computacional, e a utilização de modelos de aprendizado de máquina para prever o peso do bovino. A metodologia adotada consiste em: i) geração e preparação do conjunto de dados; ii) segmentação do animal e extração de métricas relevantes; iii) utilização de modelos de aprendizado de máquina para realizar a predição do peso. Essas etapas visam criar um sistema robusto e confiável, capaz de performar com melhores indicadores em comparação com os métodos atuais. O diferencial do nosso trabalho, em comparação com o estado da arte, é a automatização da extração dos atributos.

Em relação às métricas de desempenho, nossa abordagem apresenta melhorias significativas. Ao utilizar a visão computacional para extrair métricas relevantes do animal, obtivemos informações de forma mais rápidas e objetivas, em comparação com a extração manual realizada na maioria dos trabalhos atuais. Essa automação aumenta a eficiência do processo e reduz a possibilidade de erros humanos. Com isso, espera-se que nossos modelos de aprendizado de máquina tenham acesso a dados de qualidade, levando a resultados mais precisos na predição do peso dos bovinos.

O restante deste artigo está estruturado da seguinte forma: na seção 2, serão apresentados os trabalhos relacionados, abordando pesquisas anteriores sobre a predição de peso de gado de corte, modelo U-Net e explorando as diferentes abordagens utilizadas. Já na seção 3, explicamos de forma simples e intuitiva o funcionamento do modelo de segmentação U-NET utilizado. Em seguida, na seção 4, detalharemos a metodologia adotada neste artigo, descrevendo o processo de coleta de dados, as técnicas de pré-processamento e os modelos utilizados. Os resultados e discussão são discutidos na seção 5, com uma análise aprofundada do desempenho dos modelos propostos e uma comparação com trabalhos anteriores. Por fim, na seção 6, serão apresentadas as conclusões do estudo, destacando as principais visões, contribuições e possíveis direções futuras de pesquisa.

## **2. Trabalhos Relacionados**

Durante a revisão da literatura, identificamos estudos relacionados à estimativa de peso de animais, segmentação de imagens e extração de informações. Entre os métodos de predição explorados, destaca-se o uso de câmeras 3D, que fornecem uma quantidade significativa de informações por meio de registros em formato de dados. Além disso, há abordagens que se baseiam exclusivamente na análise de imagens, enquanto outras utilizam a extração manual de métricas como estratégia.

O trabalho realizado por [Gjergji et al. 2020], abordou o mesmo problema e utilizou uma combinação de Recurrent Attention Model (RAM) e Redes Neurais Convolucionais (CNN's) para prever o peso de bois das raças Angus e Nellore. Para realizar essa previsão, foram coletadas imagens da parte dorsal dos bois, capturadas por câmeras posicionadas acima do bebedouro. As imagens, em sua resolução original, foram submetidas aos modelos de RNA para prever o peso. O modelo que obteve o melhor desempenho foi o EfficientNetB1, com um MAE de 23,19kg. Seu foco estava voltado para a combinação dos modelos, enquanto este trabalho explora a extração de atributos automatizada.

Outro estudo significativo na área é o trabalho de [Ruchay et al. 2021], no qual foi considerado uma ampla variedade de atributos para treinar os modelos de regressão.

A extração de atributos foi feita de forma manual e teve como resultado estes atributos: altura da cernelha, altura do quadril, profundidade do peito, largura do peito, largura em maclocks, largura da colina ciática, comprimento oblíquo do corpo, comprimento traseiro oblíquo, circunferência do tórax, circunferência do metacarpo, meia circunferência traseira. Além disso, também foram feitas medições de idade de 1.500 vacas com idade entre 2 e 6 anos. Após treinamento, o modelo com o melhor resultado previsto foi o Random Forest Regressor com um MAE de 24,96 Kg. No ano seguinte, [Ruchay et al. 2022] apresentou já uma análise comparativa de diversos algoritmos de aprendizado de máquina para predição de peso. Em sua análise, o algoritmo que se sobressaiu foi o TreesRegressor. Em contraste, nosso artigo propõe uma abordagem nova em relação à geração das métricas, automatizando a extração para a predição do peso dos animais como já foi supracitado. Essa abordagem permite obter métricas de forma mais rápida e demonstra que, por meio da extração automatizada de atributos, também é possível obter previsões precisas.

Um trabalho anterior, proposto por [Miller et al. 2019], investigou uma abordagem utilizando câmera 3D, visando prever características de peso de bois vivos e carcaças com uma alta precisão mediante aprendizado de máquina. Com o sistema automatizado com a câmera 3D, foi possível extrair 60 variáveis preditoras como: comprimentos, alturas, larguras, áreas, volumes e proporções. A avaliação do modelo se deu com a utilização de  $R^2$  e RMSE, chegando nas predições de boi  $R^2=0.7$ , RMSE = 42, e carcaça de  $R^2=0.88$ , RMSE = 14. Nosso estudo obteve resultados similares mesmo a partir da perspectiva 2D. Embora a abordagem 3D seja considerada superior em termos de obtenção de informações mais detalhadas, é importante ressaltar que ainda conseguimos obter resultados significativos a partir de uma perspectiva teoricamente inferior.

### 3. Modelo U-Net

A U-Net é uma arquitetura de rede neural convolucional (CNN) largamente utilizada para trabalhos de segmentação de imagem. Proposto por [Ronneberger et al. 2015], ela se destaca por sua eficácia em problemas de segmentação de objetos, especialmente quando há poucos dados de treinamento disponíveis. A arquitetura é composta por uma seção de codificador (*encoder*) e uma seção de decodificador (*decoder*). Tendo à conexão entre essas partes a representação em “U” dessa arquitetura, que permite a troca de informações e preserva detalhes importantes durante o processo de segmentação da imagem.

O codificador é responsável por aprender recursos e extrair informações das imagens de entrada. Geralmente, é composto por camadas de convolução, seguidas por camadas de *pooling (downsampling)* para reduzir as dimensões espaciais dos recursos. Cada camada de convolução é normalmente seguida por uma função de ativação, como ReLU, para introduzir não linearidade. A profundidade das camadas convolucionais aumenta à medida que avançamos no codificador, permitindo que a rede capture características mais complexas.

O decodificador é responsável por gerar uma máscara de segmentação com a mesma resolução da imagem original. Ele recebe as informações do codificador e as utiliza para reconstruir a imagem segmentada. O *decoder* é geralmente composto por camadas de *upsampling (ou transposed convolution)* para aumentar as dimensões espaciais dos recursos. Em cada camada de *upsampling*, ocorre uma concatenação com os recursos

correspondentes do codificador, permitindo que as informações de detalhe sejam propagadas de volta à imagem reconstruída. Após a concatenação, são aplicadas camadas de convolução para refinar a segmentação. A saída final do decodificador é uma máscara de segmentação que indica a probabilidade de cada píxel pertencer a uma determinada classe.

Na U-Net a arquitetura é projetada para capturar informações contextuais em várias escalas, combinando recursos de diferentes resoluções espaciais. Essa capacidade de combinar recursos de diferentes escalas ajuda a rede a realizar segmentações precisas, mesmo quando há uma quantidade limitada de dados disponíveis. Por esse motivo, escolhemos a U-Net como a arquitetura ideal para o nosso trabalho, uma vez que nosso conjunto de dados contém cerca de 1.200 imagens de bovinos.

#### 4. Metodologia

O método proposto neste estudo é fundamentado na extração de informações de imagens segmentadas de bovinos de corte visando prever o peso deles. Ao longo do trabalho, foram executados seis etapas distintas, que podem ser vistas na Figura 1. Essas etapas foram desenvolvidas para fornecer uma abordagem abrangente e precisa na predição do peso do gado, com destaque para a extração automática dos atributos como principal diferencial. No decorrer desta seção, cada etapa será detalhada individualmente.

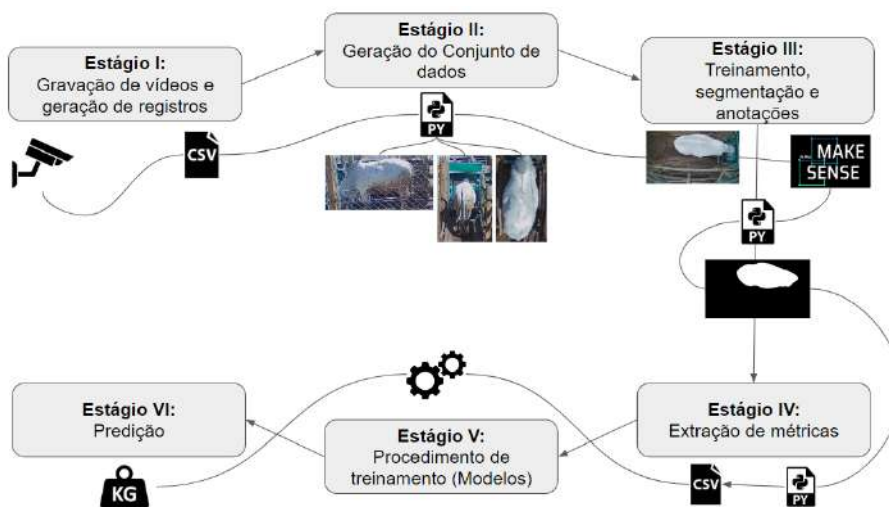
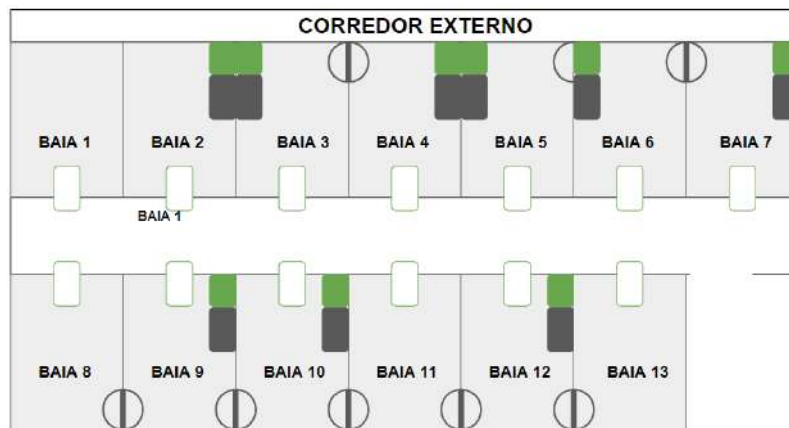


Figura 1. Diagrama do processo

##### 4.1. Etapa I: Gravação de vídeos e geração de registros

A etapa inicial do processo ocorre no ambiente de confinamento onde os bois são mantidos. O confinamento é constituído por 13 baias, conforme ilustrado na Figura 2, sendo que cada baia está equipada com um bebedouro e uma balança instalada em sua base. Em nossa coleta foram selecionados somente as baias de numeração de dois ao sete. Para capturar os vídeos, cada balança é monitorada por 3 câmeras, cada uma posicionada para capturar um ângulo distinto do boi durante o seu período de hidratação conforme pode ser visualizado na Figura 3.

A balança é ativada quando o boi posiciona sua cabeça pelo sensor localizado na parte frontal do bebedouro, como pode ser visto na Figura 4. Isso permite obter o registro




**Figura 2. Distribuição das baias**



**Figura 3. Imagens das câmeras**

do animal no exato momento em que ele utiliza o mecanismo. Durante a interação, são gravadas os três ângulos e registrado em uma planilha a identificação do boi, seu peso e horário de uso. Esses vídeos e registros são posteriormente utilizados na etapa seguinte.



**Figura 4. Posição do sensor em destaque verde**

#### **4.2. Etapa II: Geração do Conjunto de dados**

Na segunda etapa, ocorre a execução de um script desenvolvido em Python. Esse script realiza a leitura da planilha e identifica o horário em que houve a presença do boi no bebedouro. A partir dessa informação, o vídeo correspondente é acessado para extrair o registro daquele instante específico. Nesse processo, a imagem é salva com um título contendo o peso do animal e é direcionada ao ângulo de extração desejado, que pode ser dorsal, lateral ou posterior. Vale ressaltar, para o escopo deste estudo, optamos por utilizar apenas as imagens da posição dorsal, deixando a utilização das demais para trabalhos futuros.

### 4.3. Etapa III: Treinamento, segmentação U-Net e ferramenta de anotações

A terceira etapa iniciou-se com a geração de máscaras para treinar o modelo de segmentação selecionado. Para realizar essa etapa, utilizamos a ferramenta de anotações Makesense desenvolvida por [Skalski 2023] em conjunto com um script Python desenvolvido no projeto para ler as anotações e gerar as máscaras correspondentes às imagens. No total, foram geradas 1.274 máscaras, cada uma acompanhada por sua respectiva imagem do boi. Essas imagens e máscaras foram essenciais para o construir o nosso conjunto de treinamento, teste e validação.

A implementação da arquitetura do modelo seguiu o código desenvolvido por [Maynard-Reid 2022], disponibilizado pela PyImageSearch University. Foi utilizado a biblioteca Keras como base para essa implementação. Durante o processo, analisamos o modelo proposto e realizamos ajustes na entrada para adaptá-lo ao nosso problema, definindo uma resolução de 256x512 pixels. Inicialmente, a imagem possuía a resolução de 720x1.280 e foi aplicado um recorde de bordas visando reduzir para 512x1.024. Em seguida, implementamos um método de redução de dimensão em 50% para facilitar o treinamento e otimizar o uso dos recursos computacionais. Essa redução foi escolhida estrategicamente, permitindo que o processo seja revertido para retornar à resolução original quando necessário, especialmente para etapas que envolvam o uso de imagens de resolução diferente. No caso, essa reversão pode ser utilizada na imagem predita, para obter uma imagem em resolução original sem distorção.

A configuração utilizada para o treinamento consistiu em dividir os dados da seguinte forma: 80% para treinamento, 10% para validação e 10% para testes. Na etapa de compilação do modelo, foram feitas as seguintes escolhas: o otimizador *adam*, a função de perda *sparse categorical crossentropy* e a métrica *accuracy* para avaliação do desempenho. Além disso, foi configurado um *early stopping* com monitoramento da métrica *val loss* e *patience=3*, o que significa que o treinamento seria interrompido se não houvesse melhoria após 3 épocas consecutivas. O número total de épocas de treinamento estipulado foi de 20. Na Figura 5, apresentamos um teste realizado no qual é possível observar a imagem de entrada original e sua máscara correspondente, utilizada para comparação com a segmentação gerada.




Figura 5. Segmentação sem ruídos

### 4.4. Etapa IV: Extração de métricas

Na quarta etapa, realizamos um estudo do software ImageJ desenvolvido por [National Institutes of Health 2023], uma ferramenta de código aberto escrita em Java que permite em uma de suas funcionalidades a extração de informação a partir das imagens. Ao inserir uma imagem no software, é possível selecionar manualmente uma área de análise e obter diversos atributos relevantes. Para automatizar o processo

propomos a criação de um script que realiza essa tarefa sem a necessidade de usar o ImageJ. Nesse código, desenvolvemos uma classe para gerenciar a extração dos atributos, utilizando como principais módulos o OpenCV, Feret e PIL.

A classe proposta foi nomeada como *AnalyzeMeasurements*, realiza análises e medições em uma imagem. Ela possui várias propriedades que armazenam os resultados das medições realizadas, como área, perímetro, altura, largura, área de um círculo, raio do círculo, parâmetros de uma elipse e parâmetros de medições de diâmetro Feret.

Com o auxílio dos instrumentos desenvolvidos nesta etapa, foi possível extrair as métricas das máscaras previstas e relacioná-las com o peso dos bovinos exemplificados na Figura 6. Essa abordagem nos permitiu obter um conjunto de dados para treinar os modelos de predição. Importante ressaltar que cada registro gerado foi associado ao peso do bovino correspondente, para o qual o registro de extração foi realizado.




Figura 6. Extração de métricas

#### 4.5. Etapa V: Procedimento de treinamento

Na quinta etapa, procedemos com a seleção dos modelos de aprendizado de máquina para a tarefa de predição. Nossa escolha contemplou uma diversidade de modelos, incluindo o *KNeighborsRegressor*(KNN), *GradientBoostingRegressor*(GBoost), *AdaBoostRegressor*, *XGBRegressor*, *Lasso*, *ElasticNet* e *RandomForestRegressor*. Essa abordagem nos permitiu explorar diferentes algoritmos e técnicas de regressão para obter o melhor desempenho na previsão desejada.

Cada um dos modelos selecionados foi treinado com o conjunto de dados gerado na etapa anterior, sendo gerado 130 registros para essa fase. Sua divisão se baseou em 80% para treino e 20% para teste. Para otimizar os hiperparâmetros desses modelos, utilizamos um método de ajuste de parâmetros proposto por [Bergstra and Bengio 2012]. Nesse método, os autores descrevem a abordagem de busca aleatória como uma alternativa eficiente para otimizar os hiperparâmetros dos modelos de aprendizado de máquina.

Para validar o treinamento dos modelos, utilizamos diversas métricas de avaliação, incluindo o Erro Médio Absoluto (MAE), o Erro Quadrático Médio (MSE), a Raiz Quadrada do Erro Quadrático Médio (RMSE), o Erro Percentual Absoluto Médio (MAPE), o Erro Médio de Diferença Absoluta (MEDAE) e o Coeficiente de Determinação ( $R^2$ ).

Essas métricas nos permitiram quantificar o desempenho dos modelos em relação à precisão e qualidade das previsões realizadas. O MAE, MSE e RMSE medem a diferença entre os valores previstos e os valores reais, enquanto o MAPE avalia a porcentagem média de erro nas previsões. O MEDAE fornece uma medida robusta de erro, considerando a mediana das diferenças absolutas.

Por fim, utilizamos o  $R^2$ , que indica a proporção da variância nos dados de resposta explicada pelo modelo. Esse coeficiente nos ajuda a entender o quanto nosso modelo está ajustando-se aos dados e quão bem ele pode realizar previsões. Ao considerar essas métricas em conjunto, pudemos avaliar e comparar o desempenho dos diferentes modelos de aprendizado de máquina em relação à sua capacidade de realizar previsões precisas e acuradas.

#### **4.6. Etapa VI: Procedimento de Predição do peso**

Para realizar o procedimento de predição para uma imagem específica, seguimos uma sequência de etapas que resultam na geração do registro correspondente. O processo é detalhado a seguir:

1. Leitura da imagem: Iniciamos com a leitura da imagem de interesse para a predição.
2. Segmentação com o modelo: Utilizamos o modelo de segmentação previamente treinado para realizar a segmentação da imagem, identificando o objeto de interesse (boi).
3. Extração das métricas e geração do registro: A partir da segmentação obtida, extraímos as métricas relevantes relacionadas ao objeto segmentado. Essas métricas são utilizadas para compor um registro único contendo as informações necessárias para a predição do peso.
4. Predição do peso: Com o registro gerado, alimentamos os modelos de predição com as métricas extraídas. Os modelos aplicam seus algoritmos de aprendizado para estimar o peso do animal. Ao final do processo, obtemos o valor predito do peso do animal com base nas características extraída da imagem.

Dessa forma, ao seguir o procedimento completo, podemos obter uma estimativa precisa do peso para a imagem em questão. É importante destacar que esse processo envolve a execução direta etapas anteriores.


### **5. Resultados e discussão**

Para executar todo o processo, utilizamos as plataformas Google Colab e Google Cloud. No Google Cloud, configuramos uma máquina virtual com as mesmas especificações do Colab, incluindo 13 GB de RAM, uma CPU Intel Xeon e uma GPU NVIDIA Tesla T4. Os modelos foram treinados em um tempo razoável, levando em consideração a abrangência do estudo proposto. Essa configuração permitiu que realizássemos os experimentos de forma eficiente, aproveitando o poder de processamento da GPU para acelerar o treinamento dos modelos e a análise dos dados de imagem.


Após o treinamento do modelo U-NET, realizamos avaliações para mensurar a média de interseção sobre união (IoU) utilizada também em [Ronneberger et al. 2015] e a acurácia do modelo. Utilizando nosso conjunto de teste e validação, obtivemos



uma acurácia de 91% e 96%, respectivamente. Além disso, para ilustrar o processo de segmentação realizado, apresentamos exemplos de entradas e saídas geradas pelo modelo. Podendo ser vistas nas Figuras 7 e 8.



**Figura 7. Segmentação sem ruídos**



**Figura 8. Segmentação com ruídos**

As representações visuais destacam a eficácia do modelo U-NET na tarefa de segmentação dos animais nas imagens, demonstrando sua habilidade em extrair e segmentar com precisão. Os resultados obtidos nos testes da U-NET foram satisfatórios, o que está alinhado com o reconhecimento desse modelo como uma escolha promissora para tarefas de segmentação. No entanto, é importante ressaltar que em alguns casos podem ocorrer erros de predição, como evidenciado na Figura 8 na segmentação, onde ruídos estão presentes. Outra situação que pode ocorrer é quando há a presença da cabeça do animal na imagem, o que leva a um comportamento indesejado da U-NET ao tentar remover e gerar a predição sem essa área. Por esse motivo optamos por segmentar até o cupim do boi. No geral, a U-NET mostrou resultados satisfatórios.

Com o objetivo de avaliar e comparar o desempenho dos modelos de regressão, foram realizados treinamentos utilizando um conjunto de dados composto por 130 registros de animais distintos como foi supracitado. A Tabela 1 apresenta os resultados obtidos para cada modelo, considerando as métricas de análise mencionadas anteriormente, como o MAE, MSE, RMSE, MEDAE e  $R^2$ . Essas métricas fornecem uma visão abrangente do desempenho de cada modelo em relação à previsão dos pesos dos animais.

A análise dos resultados obtidos revelou informações relevantes sobre o desempenho dos modelos de regressão utilizados no estudo. Inicialmente, observou-se que o modelo KNN apresentou um MAE baixo, indicando uma diferença média de aproximadamente 14,64 unidades entre os valores da predição e os valores reais dos pesos (Kg) dos animais. Em contraste, o modelo GBoost obteve um MAE de 12,83, evidenciando um desempenho superior em relação à média.

Além disso, ao analisar o coeficiente de determinação ( $R^2$ ), que mede a proporção da variância nos dados explicada pelo modelo, observou-se que o modelo GBoost obteve um valor de 0,875, indicando que cerca de 87,5% da variabilidade dos dados de peso dos animais pode ser explicada pelo modelo. Esses resultados sugerem que o modelo GBoost

**Tabela 1. Resultados dos modelos de predição.**

Modelo	MAE	MSE	RMSE	MEDAE	R2
knn	14,6417	613,3650	24,7662	3,6566	0,7937
gboost	12,8291	371,5887	19,2766	6,0264	0,8750
adaboost	26,4035	1027,9584	32,0618	22,8873	0,6543
xgboost	16,5425	655,4355	25,6015	12,1761	0,7796
Lasso	23,7432	1020,9560	31,9524	18,0434	0,5855
ElasticNet	23,8130	1026,3135	32,0361	18,4164	0,5833
RandomForestRegressor	18,3096	659,8389	25,6873	12,4143	0,7781

possui uma capacidade superior de capturar as relações entre as variáveis de entrada e a variável de saída.

Ao considerar as métricas RMSE e MEDAE, verificou-se que o modelo GBoost também apresentou desempenho favorável, com valores de 19,28 e 6,03, respectivamente. Essas métricas indicam que o modelo GBoost conseguiu minimizar os erros quadráticos médios e os erros absolutos medianos, tornando-se uma opção promissora para a previsão precisa dos pesos dos animais.

No entanto, é importante destacar que os demais modelos, como Adaboost, XGBoost, Lasso, ElasticNet e RandomForestRegressor, também forneceram resultados significativos, embora com desempenho ligeiramente inferior em comparação ao modelo GBoost. Essas descobertas sugerem que, dependendo das necessidades específicas do estudo, diferentes modelos podem ser considerados como opções viáveis para a predição do peso dos animais.

No geral, os resultados obtidos nessa análise fornecem uma visão abrangente sobre a eficácia dos modelos de regressão na previsão dos pesos dos animais. Essas informações podem ser úteis para futuros estudos e aplicações relacionadas à pecuária, permitindo a tomada de decisões mais precisas e informadas no gerenciamento do peso dos animais.

## 6. Conclusão

Os resultados obtidos neste estudo reforçam a eficácia da abordagem proposta, que combina visão computacional e algoritmos de aprendizado de máquina, na predição precisa do peso de bovinos de corte. Os resultados indicaram que o modelo GBoost apresentou um desempenho superior em termos de métricas de avaliação, como o MAE, RMSE, MEDAE e o coeficiente de determinação  $R^2$ . Isso sugere que o GBoost é capaz de capturar com mais precisão as relações entre as variáveis de entrada e a variável de saída, fornecendo previsões mais precisas do peso dos animais.

A aplicação do modelo U-NET para a segmentação dos animais nas imagens revelou-se eficiente na extração de atributos relevantes para a predição do peso. Esse enfoque, baseado em técnicas de visão computacional, possibilita um monitoramento mais preciso e menos invasivo em comparação com os métodos tradicionais de pesagem. Dessa forma, contribui para a eficiência produtiva e auxilia os produtores rurais na tomada de decisões estratégicas relacionadas à nutrição e manejo dos animais.

A adoção dessa abordagem pode trazer benefícios significativos para a indústria

pecuária, permitindo um monitoramento contínuo do peso dos bovinos e oferecendo *insights* valiosos para a gestão eficiente do rebanho. Além disso, os resultados destacam o potencial da visão computacional e do aprendizado de máquina como ferramentas promissoras no contexto do agronegócio, impulsionando a modernização e a adoção de tecnologias avançadas.

No entanto, é importante ressaltar que este estudo representa um ponto de partida e que ainda há espaço para melhorias e aprimoramentos futuros. Pesquisas adicionais podem explorar outras técnicas de segmentação e extração de atributos, bem como a incorporação de dados adicionais, como informações genéticas e ambientais, para aprimorar ainda mais a precisão das previsões.

Vale ressaltar, a utilização de plataformas como o Google Colab e o Google Cloud possibilitou a execução eficiente dos experimentos, aproveitando o poder de processamento da GPU e acelerando o treinamento dos modelos e a análise dos dados de imagem.

Em suma, a abordagem proposta neste estudo demonstrou sua eficácia na predição do peso de bovinos de corte, fornecendo uma alternativa viável e precisa para o monitoramento desses animais. Combinando visão computacional e algoritmos de aprendizado de máquina, essa abordagem oferece uma solução promissora para a indústria pecuária, melhorando a produtividade e auxiliando os produtores na tomada de decisões estratégicas.

## Agradecimentos

Gostaríamos de agradecer CAPES, CNPq (Processo #401839/2021-4), Fapemig (Processo #APQ-02062-21) pelo financiamento a este trabalho.

## Referências

- Bergstra, J. and Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of machine learning research*, 13(2).
- Gjergji, M., de Moraes Weber, V., Otávio Campos Silva, L., da Costa Gomes, R., Luís Alves Campos de Araújo, T., Pistori, H., and Alvarez, M. (2020). Deep learning techniques for beef cattle body weight prediction. pages 1–8.
- Instituto Brasileiro de Geografia e Estatística (2023). Pesquisas trimestrais do abate de animais. Acesso em: 08/06, 2023.
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., and Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8).
- LUDTKE, C. B.; DALLA COSTA, O. A. R. R. d. O. S. E. T. F. A. N. B. A. A. P. d. M. J. A. d. A. N. C. d. (2012). Bem-estar animal no manejo pré-abate e a influência na qualidade da carne suína e nos parâmetros fisiológicos do estresse. *I*, 1(1):4.
- Maynard-Reid, M. (2022). pyimagesearch university-unet segmentation image.
- Miller, G. A., Hyslop, J. J., Barclay, D., Edwards, A., Thomson, W., and Duthie, C.-A. (2019). Using 3d imaging and machine learning to predict liveweight and carcass characteristics of live finishing beef cattle. *Frontiers in Sustainable Food Systems*, 3.
- National Institutes of Health (2023). *ImagJ: Image Processing and Analysis in Java*. National Institutes of Health. Versão 1.54.

- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *ArXiv*, abs/1505.04597.
- Ruchay, A., Kober, V., Dorofeev, K., Kolpakov, V., Dzhulamanov, K., Kalschikov, V., and Guo, H. (2022). Comparative analysis of machine learning algorithms for predicting live weight of hereford cows. *Computers and Electronics in Agriculture*, 195:106837.
- Ruchay, A. N., Kolpakov, V. I., Kalschikov, V. V., Dzhulamanov, K. M., and Dorofeev, K. A. (2021). Predicting the body weight of hereford cows using machine learning. *IOP Conference Series: Earth and Environmental Science*, 624(1):012056.
- Skalski, P. (2023). Makesense. Makesense Anotation. Disponível em: <https://www.makesense.ai/>. Acessado em 8 de junho de 2023.
- Wang, Z., Shadpour, S., Chan, E., Rotondo, V., Wood, K. M., and Tulpan, D. (2021). ASAS-NANP SYMPOSIUM: Applications of machine learning for livestock body weight prediction from digital images. *Journal of Animal Science*, 99(2). skab022.