

PREVISÃO DE MEDIDA DE PESO BOVINO UTILIZANDO REDES NEURAIAS CONVOLUCIONAIS

PREDICTING BOVINE WEIGHT USING CONVOLUTIONAL NEURAL NETWORKS

Carlos Henrique da Silva Barbosa – carlos.henrique.barbosa47@gmail.com
Fatec Bebedouro Jorge Caram Sabbag – Bebedouro– São Paulo – Brasil

José Lucas Gomes – joselucasgomes99.jl@gmail.com
Fatec Bebedouro Jorge Caram Sabbag – Bebedouro– São Paulo – Brasil

Paulo Eduardo Cardoso Andrade – paulo.andrade19@fatec.sp.gov.br
Fatec Bebedouro Jorge Caram Sabbag – Bebedouro– São Paulo – Brasil

Renan Guilherme Nespolo – renan.nespolo01@fatec.sp.gov.br
Fatec Bebedouro Jorge Caram Sabbag – Bebedouro– São Paulo – Brasil

DOI: 10.31510/inf.v21i2.2044

Data de submissão: 23/09/2024

Data do aceite: 23/11/2024

Data da publicação: 20/12/2024

RESUMO

O presente estudo apresenta uma proposta sobre a previsão de medidas de peso em bovinos por meio de técnicas de aprendizado de máquina utilizando imagens. A pesagem de bovinos é parte fundamental para otimizar a produção e cuidados com o animal, e garantir o bem-estar animal. Contudo, o método tradicional pode causar estresse no animal, podendo prejudicar todo processo produtivo. Portanto, desenvolver um modelo baseado em Redes Neurais Convolucionais, com o objetivo de estimar o peso dos bovinos utilizando suas imagens, minimizando a necessidade de manejo direto, promovendo um melhor bem-estar ao animal. As principais contribuições com a proposta de um modelo de Redes Neurais Convolucionais, a comparação de diferentes filtros de imagens (RGB e Escala de Cinza) e a análise de diferentes perspectivas do gado (lateral e frontal). Os resultados validam a eficiência do modelo proposto e contribuir para práticas mais sustentáveis e eficientes na pecuária.

Palavras-chave: Bovinos. Redes Neurais Convolucionais. Previsão de Peso. *Stress Animal*.

ABSTRACT

This study presents a solution for predicting weight measurements in cattle through machine learning techniques using images. Weighing cattle is crucial for optimizing production and ensuring animal welfare, but the traditional method can cause stress to the animal. The aim is to develop a model based on convolutional neural networks to estimate the weight of cattle through image analysis, minimizing the need for direct handling. The results validate the efficiency of the proposed model and contribute to more sustainable and efficient practices in livestock farming.

Keywords: Cattle. Convolutional Neural Networks. Weight Predicting. Animal Stress.

1 INTRODUÇÃO

Na pecuária, estimar o peso dos animais se faz necessário durante todas as etapas de produção, visto que a negociação deles geralmente é feita a partir do seu peso, além disso o peso do animal é um fator muito importante para definir seu desempenho dentro da produção agropecuária, assim como para fatores de nutrição, tais como troca de dieta, definir a quantidade diária ideal de ração, para que o bovino tenha os resultados esperados de produção. Pôr a pecuária ser uma atividade com grande demanda de mão de obra para ser realizada de forma adequada lucrativa, podendo ser distribuídas em várias etapas da produção, porém a maior demanda é no manejo direto com os animais. Pôr a pesagem dos bovinos ser realizada via manejo direto dos criadores, a torna uma atividade de muito estresse para os animais, sendo necessário o deslocamento do animal, e passagem pela balança, portanto é válido a busca por métodos para realizar a pesagem dos animais diminuindo ou excluindo manejo direto do processo (ALVARENGA, 2022).

Com os avanços tecnológicos no campo de aprendizado de máquinas é possível estimar o peso do animal analisando imagens sem a necessidade de deslocar o animal evitando colocar sob stress. Um trabalho inicial foi feito por PERNEEL *et al.* (2023), que buscou em estudo somente reconhecer o animal. Deste modo, o presente estudo busca construir um modelo, baseado no estudo citado anteriormente, que realize a estimativa do peso por análise de imagens de forma digital e instantânea, utilizando o aprendizado de máquina para realizar essa tarefa. As principais contribuições do presente trabalho são:

- Propor um modelo de Redes Neurais Convolucionais para estimar o peso do gado por imagens;
- Comparar diferentes filtros de imagens para estimar o peso (RGB e Escala de Cinza);
- Comparar diferentes perspectivas dos bovinos (Lateral e Frontal).

O presente trabalho está organizado da seguinte forma: 1 Introdução; 2 Fundamentação Teórica; 3 Materiais e Métodos; 4 Resultados e Discussões; 5 Considerações Finais; e por último as Referências.

2 FUNDAMENTAÇÃO TEÓRICA

Na presente sessão é apresentado os conceitos fundamentais para a realização do estudo divididos em 2.1 Estresse Animal, 2.2 Perfil de Alimentação Animal, 2.3 Importância da Pesagem na Produção de Bovinos e 2.4 Redes Neurais Profundas.

2.1 ESTRESSE ANIMAL

É amplamente reconhecido que os animais devem atender às suas necessidades fundamentais (físicas, comportamentais e psicológicas) para sobreviver em ambientes desconhecidos ou em constante mudança. A capacidade de interação e a resposta individual são os principais determinantes da adaptação e sobrevivência de cada animal ao seu meio ambiente. Mudanças no ambiente ou no organismo animal podem perturbar o equilíbrio basal, e diferentes espécies têm estratégias únicas para lidar ou mitigar essas mudanças em suas vidas (SANTOS, 2005; ROSA, 2003).

No entanto, os danos do estresse no organismo animal são amplamente reconhecidos, afetando aspectos comportamentais, reprodutivos, psicológicos e produtivos. O estresse pode ser descrito como um estado que antecede ou surge em resposta a uma ameaça ao equilíbrio do organismo, buscando restaurar esse equilíbrio por meio de uma série de respostas fisiológicas e comportamentais (ZUARDI, 2015; ORSINI; FERNANDES, 2006).

2.2 Tipo de Alimentação em Bovinos

A nutrição é um dos pilares fundamentais do sistema de produção de bovinos de corte, juntamente com a genética e a saúde animal. O aumento da produtividade de carne e leite emerge como uma alternativa para incrementar a produção sem a necessidade de expandir ou abrir novas áreas para pastagens. Diferentemente dos outros nutrientes, a energia não se manifesta como uma entidade física no alimento, cuja quantidade disponível para os animais possa ser determinada por meio de análises laboratoriais.

A dieta dos bovinos de corte em confinamento é composta por uma combinação de volumosos e concentrados. Entre os principais volumosos utilizados estão a silagem de milho, a silagem de cana-de-açúcar, a cana-de-açúcar fresca picada e a silagem de capim (SENAR, 2018).

2.3 Importância da pesagem na produção dos Bovinos

A pesagem é um aspecto fundamental na produção de bovinos, pois fornece informações cruciais sobre o desenvolvimento e o desempenho dos animais ao longo do tempo. Por meio da pesagem regular, os produtores podem monitorar o ganho de peso dos bovinos, o que é essencial para avaliar a eficácia da dieta e a saúde geral do rebanho. Esses dados permitem ajustes precisos na alimentação e na gestão do manejo, garantindo que os animais atinjam seu potencial genético máximo de crescimento e produção. Além disso, a pesagem é vital para o planejamento estratégico da produção pecuária. Com informações precisas sobre o peso dos animais, os produtores podem tomar decisões fundamentadas em relação ao momento ideal para a venda, identificando os bovinos que alcançaram o peso de abate desejado. Isso ajuda a otimizar os lucros e a maximizar a eficiência da produção, evitando a permanência desnecessária dos animais no sistema de produção (Melo, A. F. et al., 2016, p.791).

2.4 Redes Neurais Profundas

De acordo com HAYKIN (2001), a teoria das redes neurais surge da necessidade de criar sistemas que possam operar de forma semelhante ao cérebro humano. O cérebro é uma estrutura altamente complexa, não linear e um tipo de computador paralelo, capaz de manipular seus elementos estruturais e realizar certos cálculos mais rapidamente do que qualquer computador digital conhecido. Dessa forma, as redes neurais funcionam por meio de treinamento, em oposição à programação algorítmica.

Devido às suas características únicas, como não linearidade, capacidade de generalização, adaptabilidade e capacidade de mapeamento de saída, as redes neurais encontram aplicação em uma ampla gama de campos, incluindo engenharia, matemática, física, biologia e medicina, entre outros. Essas redes são, portanto, inspiradas no sistema nervoso humano.

As Redes Neurais Convolucionais (CNNs), sigla em inglês de *Convolutional Neural Networks*, têm desempenhado um papel significativo na aplicação de tecnologias de inteligência artificial na produção de bovinos. As CNNs são uma classe especializada de redes neurais profundas projetadas para processar e analisar dados de forma eficiente, especialmente em tarefas relacionadas à visão computacional. Na pecuária, as CNNs podem

ser aplicadas em diversas áreas, como na identificação e classificação de características físicas dos bovinos, como raça, idade e condição de saúde. Por exemplo, utilizando imagens de câmeras de monitoramento, as CNNs podem ser treinadas para identificar automaticamente anomalias, como lesões ou doenças visíveis.

2.4.1 Medidas de Avaliação

A métrica MAE (Erro Médio Absoluto) é uma medida estatística que quantifica a média das diferenças absolutas entre os valores preditos por um modelo e os valores reais observados. Após o desenvolvimento do modelo, o MAE é usado para avaliar a precisão das previsões. O MAE é calculado pela média das diferenças absolutas entre os valores preditos pelo modelo e os valores reais observados nos dados de validação ou teste. O MAE fornece uma medida para de interpretar da precisão do modelo, expressa nas mesmas unidades dos dados de entrada e ainda captura as variações nos erros de previsão de maneira intuitiva (HAYKIN, 2001).

Para realizar a validação do experimento, precisa-se dividir o conjunto de dados em dois conjuntos: um usado para treinamento e outro para teste e validação. Portanto para avaliar o método foi adotado, no presente trabalho, a técnica de *10-Fold-Cross-Validation*. Essa técnica dividi em partes iguais o conjunto de dados, no caso em 10 partes e após essa etapa treina o algoritmo com 9 partes e testa com 1 e vai trocando as 9 partes de treino e testes até que seja testada as 10 partes, para se obter resultados confiáveis, utilizando validação cruzada (MURPHY, 2012).

3 MATERIAIS E MÉTODOS

O presente estudo consiste na ideia de previsão de peso em bovinos utilizando técnicas de aprendizado de máquina por meio de imagens. Portanto como não há estudos relevantes focados a este assunto específico, este estudo foi baseado no trabalho de PERNEEL et al. (2023), que foi realizado um estudo para reconhecimento do gado a partir do uso de CNN.

O experimento foi realizado utilizando um *Dataset* (Acme AI Ltd. et al., 2023) de imagens de bovinos, nas posições: lateral e frontal sendo imagem original e imagem da silhueta do animal. O algoritmo irá realizar o aprendizado utilizando as imagens para a previsão do peso do bovino. Para inferência e avaliação foram adotados o método 10-Fold-


Validation com a métrica de Erro Médio Absoluto (MAE), ambos apresentados na seção 2.4.1.

3.1 Conjunto de Dados


A aquisição dos dados foi realizada em um estudo recente que se concentrou em inferir a pesagem de bovinos por meio de imagens levando em consideração as medidas do seu comprimento corporal e circunferência torácica (Acme AI Ltd. et al., 2023).

Os conjuntos de dados utilizados contêm um total de 15.000 imagens, segmentadas da seguinte forma: 7.500 imagens reais, das quais: 5.050 imagens mostram o animal na posição lateral, como apresentada na figura 1(a); 2.450 imagens mostram o animal na posição frontal, como apresentada na figura 2(a). Todas essas são subdivididas em três *Datasets*, nomeados: B2, B3, e B4.

Figura 1 - Exemplo de imagem que compõe: (a) O *Dataset B2 images*, com o animal na posição frontal e; (b) Exemplo de silhueta que compõe o *Dataset B2 annotation*, com tratamento de silhueta RGB.



(a)



(b)

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

7.500 imagens tratadas no formato RGB para silhueta do animal, sendo: 5.050 imagens com o animal na posição lateral, figura 1(b), e; 2.450 imagens com o animal na posição frontal, como apresentada na figura 2(b).

No total, os dados utilizados representam 5.050 animais divididos em 3 *Datasets* denominados: B2, contendo imagens de 510 animais nas posições lateral e frontal; B3, contendo imagens de 2600 animais na posição lateral e; B4, contendo imagens de 1940 animais nas posições lateral e frontal.

Figura 2 - Exemplo de imagem que compõe: (a) O *Dataset B2 images*, com o animal na posição lateral e; (b) Exemplo de silhueta que compõe o *Dataset B2 annotation*, com tratamento de silhueta RGB.



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

3.2 Pré-Processamento


O pré-processamento das imagens é uma etapa fundamental para garantir que os dados estejam em um formato adequado antes de serem passados para a Rede Neural Convolutacional. Para o presente estudo as imagens foram convertidas para formato RGB no tratamento em RGB e convertidas para tons cinza para o tratamento tons cinza, então redimensionadas para de 64x64 pixels.

3.3 Rede Neural Convolutacional

A rede será implementada na linguagem de programação Python versão 3.12.3, utilizando as bibliotecas Keras e *TensorFlow*, que fornecem ferramentas poderosas e intuitivas para a construção e treinamento de modelos de aprendizado de máquina. A biblioteca NumPy foi escolhida para tratar operações matemática, PIL (Python Imaging Library) para a manipulação de imagens, e por fim os módulos *os* e *os.path* para manipulação de caminhos de arquivos e diretórios.

A arquitetura da rede proposta no presente trabalho está configurada com as seguintes camadas: (1) Conv2D, 32 filtros 3x3 e ativação *Rectified Linear Unit* (ReLU); (2) MaxPooling2D, pool 2x2; (3) Conv2D, 64 filtros 5x5 e função de ativação ReLU; (4) MaxPooling2D pool 2x2; (5) *Dropout* 25%; (6) *Flattening*; (7) *Dense*, 128 neurônios, ativação ReLU; (8) *Dropout* 50%; saída, ativação *Adaptive Moment Estimation* (ADAM). Na figura 3, um fluxograma da CNN proposta é apresentado.

Figura 3 - Exemplar Fluxograma da arquitetura das camadas da CNN proposta.



Fonte: Elaborado pelo autor.

4 RESULTADOS E DISCUSSÃO

Os resultados obtidos no presente estudo a partir do algoritmo e das imagens em posição lateral e frontal utilizando escala cinza ou filtro RGB (usando apenas o filtro vermelho “R” ou verde “G”) apresentados no conjunto de dados. No decorrer dos testes o *Dataset* B2 apresenta um desempenho bastante similar em ambos os experimentos e em ambas as posições alcançando um erro MAE normalizado em torno de 0,075 e 34kg. O *Dataset* B3 foi realizado apenas um experimento pois esse *Dataset* possui apenas imagens na posição lateral tendo um desempenho similar em ambos, sendo necessário a troca do filtro de cor pois as imagens eram no tom rosa sendo diferente do B2 que a cor era verde. No *Dataset* B4 os experimentos foi o que se teve mais estável do que os demais tendo o tratamento em RGB superior a Tons de Cinza, porém teve a pior performance dentre os três (B2, B3 e B4).

Tabela 3 - 10-Fold-Validation do Dataset annotation B2 utilizando o tratamento G com o animal na posição frontal.

| <i>Fold</i> | MAE (Normalizado [0,1]) | MAE (Quilogramas) |
|-----------------------|----------------------------|----------------------|
| <i>Fold 1</i> | 0,0690 | 32,2444 |
| <i>Fold 2</i> | 0,0988 | 43,0077 |
| <i>Fold 3</i> | 0,0888 | 40,6324 |
| <i>Fold 4</i> | 0,0569 | 26,8100 |
| <i>Fold 5</i> | 0,0740 | 33,5466 |
| <i>Fold 6</i> | 0,0638 | 27,8559 |
| <i>Fold 7</i> | 0,0681 | 31,5416 |
| <i>Fold 8</i> | 0,0620 | 26,8868 |
| <i>Fold 9</i> | 0,0909 | 40,2175 |
| <i>Fold 10</i> | 0,0660 | 30,4570 |
| Erro médio | 0,0738 | 33,3199 |

Fonte: Elaborada pelo autor.

Tabela 4 - 10-Fold-Validation do Dataset B2 utilizando as imagens com o tratamento Escala de Cinza com o animal na posição frontal.


| <i>Fold</i> | MAE (Normalizado [0,1]) | MAE (Quilogramas) |
|----------------|----------------------------|----------------------|
| <i>Fold 1</i> | 0,0779 | 32,9298 |
| <i>Fold 2</i> | 0,1078 | 44,4866 |
| <i>Fold 3</i> | 0,0933 | 41,7167 |
| <i>Fold 4</i> | 0,0643 | 27,1281 |
| <i>Fold 5</i> | 0,0782 | 33,2189 |
| <i>Fold 6</i> | 0,0703 | 28,1287 |
| <i>Fold 7</i> | 0,0798 | 32,6535 |
| <i>Fold 8</i> | 0,0661 | 28,0849 |
| <i>Fold 9</i> | 0,0893 | 42,3876 |
| <i>Fold 10</i> | 0,0749 | 31,2867 |
| Erro | 0,0801 | 34,2021 |

médio

Fonte: Elaborada pelo autor.


A média entre os erros dos três *Datasets* são apresentadas nos gráficos 1 e 2. No gráfico 1 pode-se constatar que as imagens laterais têm um erro inferior as frontais, no gráfico 2 também denota que em média as imagens da silhueta (RGB) obtiveram um erro inferior as apresentadas na escala de cor cinza (GS). No gráfico 3 é demonstrado os erros percentuais dos três *Datasets* e no gráfico 4 está discriminando os valores do MAE com ambos os treinamentos nas posições frontal e lateral com os filtros RGB e tons cinza

Gráfico 1 - Média dos resultados obtidos por meio da técnica 10-Fold-Validation utilizando a métrica MAE normalizada de [0,1].



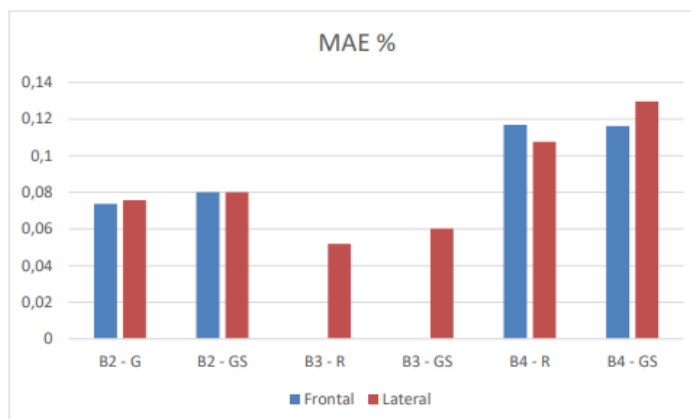
Fonte: Elaborada pelo autor.

Gráfico 2 - Erros em quilogramas obtidos por meio da técnica 10-Fold-Validation utilizando a métrica MAE em quilogramas.



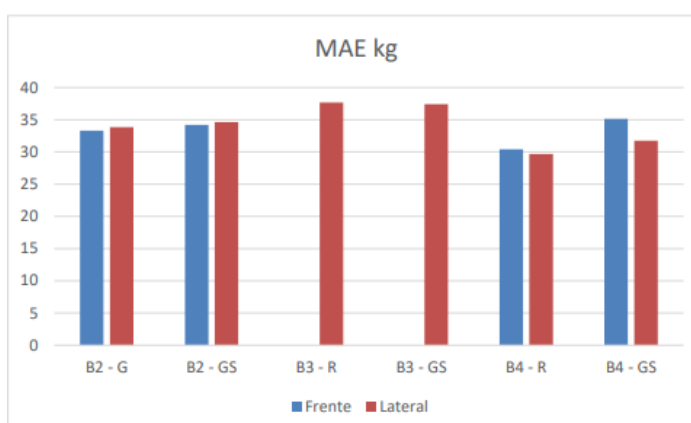
Fonte: Elaborada pelo autor.

Gráfico 3 - Média dos resultados obtidos por meio da técnica 10-Fold-Validation utilizando a métrica MAE normalizada de [0,1].



Fonte: Elaborada pelo autor.

Gráfico 4 - Resultados obtidos por meio da técnica 10-Fold-Validation utilizando a métrica MAE em quilogramas.



Fonte: Elaborada pelo autor.

Como observado nos gráficos 3 e 4, nota-se que nos resultados apresentados nos gráficos 1 e 4, o método com a maior performance é o realizado utilizando imagens com o filtro cinza e com a posição lateral do gado, já que os resultados obtidos do peso contêm uma diferença pequena comparados em quilos com o filtro RGB, aproximadamente 4Kg. Realizando o pré-processamento das imagens com tons cinza, é possível obter uma precisão melhor, fazendo assim o algoritmo realizar um melhor desempenho.

5 CONSIDERAÇÕES FINAIS

Pôr a pesagem de bovinos ter grande relevância para atingir resultados satisfatórios em produções agropecuárias, o *stress* animal por sua vez é um fator que atrapalha o desenvolvimento dos animais. Com base nos estudos do modelo apresentado,

é possível inferir a pesagem dos animais por meio de imagens adotando o modelo proposto.

Sendo assim mesmo que as imagens de silhueta tenham melhores resultados, utilizar as imagens em escala de cinza para a tarefa de predição do peso é uma solução recomendável, pois a diferença em quilos em relação as imagens de silhueta é pequena e exige uma etapa a menos no pré-processamento das imagens. Como trabalhos futuros os autores pretendem comparar o modelo proposto no presente estudo com outros modelos de CNN e outras técnicas de Aprendizado de Máquina.

REFERÊNCIAS

- 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.
- CHARNIAK, E. **Introduction to Deep Learning**. 1. ed. [S.l.: s.n.]: The MIT Press, 2019. ISBN 0262039516; 9780262039512.
- HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Bookman Editora, 2001.
- 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.
- 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.
- PERNEEL, Maarten et al. **Dynamic multi-pose, multi-viewpoint re-identification of Holstein-Friesian cattle**. In: Proceedings of the 3rd Workshop on CV4Animals: Computer Vision for Animal Behavior Tracking and Modeling. 2023.
- 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**. 2018. Disponível em: <<https://www.cnabrazil.org.br/assets/arquivos/232-BOVINOCULTURA.pdf>>.

ZUARDI, A.W. **Fisiologia do estresse e sua influência na saúde**. Programa de pós-graduação em Ciências da Saúde na UFU. Uberlândia, 2015.