

Predição do Peso de Bovinos utilizando Aprendizado de Máquina

Vítor L. G. Silva¹, Roniel Barbosa¹, Jhonata Costa¹,
Nathália Souza³, Érica Schultz³, Mario Chizzoti³, Ricardo Ferreira², José A. M. Nacif¹

¹Instituto de Ciências Exatas e Tecnológicas – Universidade Federal de Viçosa (UFV)
Rodovia LMG 818, km 06, s/n, Florestal - MG, 35690-000

²Departamento de Informática – Universidade Federal de Viçosa (UFV)
Viçosa, MG

³Departamento de Zootecnia – Universidade Federal de Viçosa (UFV)
Viçosa, MG

{vitor.luis, jnacif}@ufv.br

Resumo. *O agronegócio, que representou 24% do PIB brasileiro em 2023, destaca-se como um setor robusto. O ramo pecuário, contribuindo com 6,6% desse indicador, reforça sua significativa presença econômica. Dito isso, a atividade de criar bovinos de forma eficiente torna-se vital para a sustentabilidade desse setor. A pesagem convencional, realizada em balanças industriais de alto custo, gera estresse para animais e trabalhadores, o que impacta negativamente na qualidade da carne. Diante desse desafio de prever o peso, apresentamos uma proposta que utiliza aprendizado de máquina com otimização de hiperparâmetros e segmenta imagens antes de extrair as características geométricas essenciais, como altura e largura. O melhor algoritmo utilizado na metodologia desenvolvida atingiu bons resultados na predição: MAE de 11,12 kg e RMSE de 14,58 kg.*

Abstract. *The agribusiness, which accounted for 24% of the Brazilian GDP in 2023, stands out as a robust sector. The livestock branch, contributing 6.6% to this indicator, reinforces its significant economic presence. With that said, efficient cattle-raising activity becomes crucial for the sustainability of this sector. Conventional weighing, conducted on high-cost industrial scales, induces stress in animals and workers, negatively impacting meat quality. Faced with the challenge of predicting weight, we propose an approach that utilizes machine learning with hyperparameter optimization and image segmentation before extracting essential geometric characteristics such as height and width. The best algorithm employed in the developed methodology achieved promising results in prediction: MAE of 11.12 kg and RMSE of 14.58 kg.*

1. Introdução

Um dos ramos mais lucrativos no Brasil é o agronegócio, que representou cerca de 24% do Produto Interno Bruto (PIB) do país no ano de 2023. De acordo com o Centro de Estudos Avançados em Economia Aplicada (CEPEA) e a Confederação Nacional da Agricultura e Pecuária (CNA), o ramo pecuário contribuiu com 6,6% do PIB, gerando um faturamento

de aproximadamente 715 bilhões de reais até setembro desse mesmo ano [CEPEA 2023]. Nesse contexto econômico, torna-se evidente a importância da criação de bovinos de forma eficiente, uma vez que tal prática desempenha um papel crucial na sustentabilidade desse setor para a economia nacional.

A atividade de criar bois é composta de diversas tarefas, sendo uma delas a pesagem do animal. Normalmente, eles são pesados em balanças industriais de alto custo financeiro, o que torna inviável a aquisição delas para produtores de pequeno porte. Além disso, o processo de pesagem convencional pode ser um exercício estressante tanto para o animal quanto para o trabalhador, o que pode ocasionar a queda da qualidade da carne bovina [Melo 2016]. Sendo assim, uma das formas de resolver essa problemática é automatizar o processo de predição do peso através de técnicas computacionais e o uso de imagens [Wang et al. 2021].

Neste artigo, apresentamos uma abordagem capaz de prever o peso de bovinos através de imagens. Ela foi desenvolvida utilizando o método de aprendizado de máquina, juntamente com o conceito de otimização de hiperparâmetros para complementá-la. Além disso, antes de extrair as características geométricas do animal, como altura e largura, as imagens foram segmentadas para reduzir informações desnecessárias. Ademais, os resultados obtidos foram comparados com outras abordagens existentes no estado da arte.

Em [Wang et al. 2021], os autores apresentam diversos trabalhos que utilizam aprendizado de máquina para realizar a predição do peso de diversos tipos de animais, tais como bois e porcos. Entretanto, a maior parte deles não usa otimização de hiperparâmetros, além de que os resultados obtidos pelo presente artigo foram melhores e os modelos aplicados foram diferentes.

O restante do artigo está estruturado da seguinte forma: na Seção 2, ressaltamos os trabalhos que possuem maior relevância com o tema abordado. Já na Seção 3, apresentamos a metodologia desenvolvida e, na sequência, os resultados obtidos (Seção 4). Por fim, discutimos as considerações finais na Seção 5.

2. Trabalhos Relacionados

Nesta seção, descrevemos as contribuições mais significativas e impactantes que possuem relação com o tema abordado neste artigo.

Em [Gjergji et al. 2020], temos uma análise dos resultados obtidos por Redes Neurais Convolucionais (*Convolutional Neural Network* - CNN) ao preverem o peso dos bovinos através de imagens. Em síntese, os autores fizeram comparações entre modelos que utilizam técnicas mais tradicionais de Visão Computacional, como regressão linear, e modelos com técnicas mais modernas, como CNN. Para compor as metodologias mais novas, os autores usaram três modelos: (i) EfficientNet e EfficientNet-B1 [Tan and Le 2019]; (ii) ResNet18 [He et al. 2015]; e (iii) Recurrent Attention Model (RAM) [Mnih et al. 2014]. O conjunto de dados era composto por 20 bois, sendo que 10 eram da raça Nelore e os outros 10 da raça Angus. As imagens utilizadas eram da visão dorsal e foram coletadas no momento em que o animal bebia água. Para medir o peso, os autores utilizaram balanças da Intergado. O resultado obtido no artigo foi um erro médio absoluto (*Mean Absolute Error* - MAE) de 23,19 kg para o peso do animal, que foi alcançado pelo modelo EfficientNetB1. Em contrapartida, o modelo de regressão linear usado para comparação obteve 38,46 kg [Weber et al. 2020].

O estudo apresentado em [Weber et al. 2020] ressalta a importância de incorporar características do boi, como a medida da distância entre o rabo e o pescoço, no processo de predição do peso dele. Os autores mostraram que a circunferência do coração (*heart girth*) tem uma forte correlação com o peso do animal, como também foi evidenciado nos trabalhos de [Sales et al. 2009] e [Abreu et al. 2015]. Além disso, eles concluíram que o tamanho do corpo e do quadril são medidas importantes para a predição do peso, igualmente visto em [Franco et al. 2017]. Eles analisaram 68 imagens de 34 gados da raça Girolando, sendo que 34 imagens eram da visão dorsal e as outras 34 eram da lateral do animal. Os modelos utilizados foram: (i) regressão linear com seleção de modelo utilizando o critério de informação do Akaike (*Akaike Information Criterion - AIC*) [Akaike 2011], (ii) máquina de vetores de suporte (*Support Vector Machine - SVM*) para regressão [Smola and Schölkopf 2004]; e (iii) regressão por discretização utilizando Florestas Aleatórias (*Random Forests*) [Frank and Bouckaert 2009] e [Breiman 2001]. O resultado obtido no artigo foi uma raiz do erro quadrático médio (*Root Mean Squared Error - RMSE*) de 42,52 kg e, como já mencionado, um MAE de 38,46 kg.

No trabalho conduzido por [Miller et al. 2019], foram utilizadas imagens 3D para predição do peso do gado. Além disso, eles também predisseram o peso das carcaças dos animais, bem como a estimativa do rendimento da carne comercializável e da porcentagem de gordura nelas contida. As câmeras 3D coletaram um total de 18.134 imagens de 1.484 bois, porém cerca de 2 mil foram descartadas devido a baixa qualidade. Com base nessas imagens, 60 características foram avaliadas para compor o modelo de predição do peso, sendo que o sexo do animal também foi incluído. Como os autores avaliaram diversas raças, eles categorizaram o gado em nativo, que eram menores em tamanho, e continental, que eram raças maiores. Eles construíram Redes Neurais Artificiais (*Artificial Neural Networks - ANN*) [Agatonovic-Kustrin and Beresford 2000] utilizando uma biblioteca na linguagem R. Além das redes neurais, eles também desenvolveram modelos de regressão linear. O melhor RMSE alcançado pelo artigo foi de 42 kg, que foi obtido por uma das redes.

Na Tabela 1, apresentamos uma síntese que destaca as principais características de cada um dos trabalhos previamente mencionados, incluindo os resultados obtidos. Também informamos os dados da abordagem proposta neste trabalho.

Tabela 1. Comparativo dos trabalhos apresentados na Seção 2 e a abordagem proposta neste trabalho.

Artigo	Método(s)	Raça(s)	N.º de bois	MAE	RMSE
[Gjergji et al. 2020]	Regressão Linear, Redes Neurais Convolucionais	Nelore e Angus	20	23,19 kg	-
[Weber et al. 2020]	Regressão Linear, Regressão com SVM, Regressão por Discretização com <i>Random Forests</i>	Girolando	34	38,46 kg	42,52 kg
[Miller et al. 2019]	Regressão Linear, Redes Neurais Artificiais	Angus, Charolês, Limousin e Simental	1.484	-	42 kg
Presente artigo	Regressão com <i>Boosting</i> , Regressão de Árvores de Decisão	Nelore	20	11,12 kg	14,58 kg

3. Metodologia

Para o desenvolvimento do projeto, dividimos a metodologia nas seguintes etapas: (i) coleta dos dados; (ii) análise e classificação das imagens; (iii) segmentação das imagens;

e, por fim, (iv) treinamento e teste dos modelos de predição do peso do bovino. As etapas são explicadas no decorrer da seção.

3.1. Coleta dos Dados

Antes de iniciar o processo de filmagem dos animais, cada um deles recebeu um brinco para identificá-los via radiofrequência no sistema da Intergado. Após a brincagem, os bois foram enviados para um espaço confinado, ilustrado na Figura 1. Esse confinamento era composto de três setores, sendo que cada setor continha duas baias. Cada baia possuía três câmeras da Intelbras: uma para filmar a visão dorsal, outra para a lateral e a última para a traseira, como mostra as regiões numeradas da Figura 2. As imagens extraídas de cada visão podem ser visualizadas na Figura 3. Além das câmeras, também tinha um bebedouro e um cocho em cada baia. Para pesar o animal, uma balança da Intergado foi instalada para cada bebedouro, de modo que, quando o boi bebia água, o peso dele era registrado no sistema. Assim, o equipamento utilizado para armazenar os vídeos dos bois (*Digital Video Recorder - DVR*) foi configurado para gravar apenas as filmagens em que aparecia o animal.

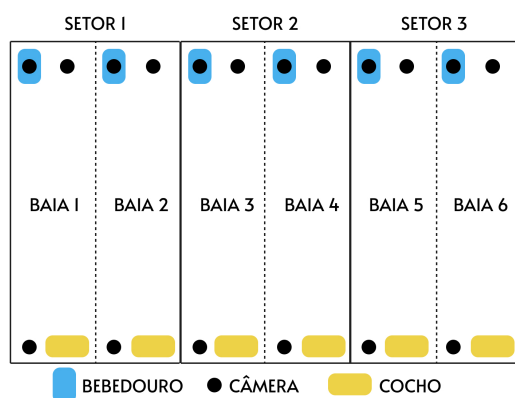


Figura 1. Confinamento dos animais dividido por baias.




Figura 2. Zoom em uma baia, destacando as porções do boi registradas pelas câmeras.

Dito isso, diversos vídeos foram gravados. Para facilitar a aquisição das imagens contendo bois, desenvolvemos um algoritmo em Python para calcular e encontrar o momento exato em que o animal bebia água. Basicamente, o sistema da Intergado fornecia uma planilha por boi contendo os horários que ele foi ao bebedouro. Então, usamos esse horário para comparar com os intervalos do vídeo, que eram obtidos no próprio nome do arquivo. Caso o horário estivesse no intervalo, o algoritmo abria o vídeo e calculava o momento exato em que se encontrava o boi. Para criar um intervalo de segurança, adicionamos e subtraímos alguns segundos para termos mais *frames* extraídos daquele momento. Como cada visão do animal encontrava-se em um vídeo diferente, esse algoritmo executava três vezes para cada horário da planilha. Assim, as imagens foram salvas para a análise descrita na Seção 3.2.



a) Imagem da vista dorsal



b) Imagem da vista traseira



c) Imagem da vista lateral

Figura 3. Imagens extraídas das câmeras de cada visão do animal.

3.2. Análise e Classificação das Imagens

Após a extração das imagens, analisamos a qualidade delas. Para tal, verificamos se o boi estava de fato na imagem. Isso foi necessário porque uma grande quantidade de imagens estava vazia devido a dessincronia entre o horário da planilha e o do vídeo. Dito isso, criamos um modelo específico para identificar a presença ou ausência do animal através da visão dorsal dele. Antes de começar o treinamento, rotulamos 596 imagens: 298 com boi e 298 sem boi. Para construir o modelo, utilizamos o SGDClassifier, um classificador linear disponível na biblioteca scikit-learn [Pedregosa et al. 2011]. Depois do treino, o modelo obteve uma precisão de, aproximadamente, 95%. Esse resultado foi suficiente para o propósito dessa etapa, visto que as imagens ainda seriam segmentadas manualmente. Como supracitado, usamos apenas a visão dorsal na classificação, então utilizamos o identificador único da imagem classificada, que foi definido no momento que a imagem foi salva, para recuperar as outras visões do *frame* em análise.

3.3. Segmentação das Imagens


A segmentação das imagens dos animais foi essencial na predição do peso deles, pois facilitou a extração de características geométricas. Além disso, ela também removeu toda informação desnecessária da imagem, como o bebedouro e outros animais indesejados. Algumas imagens foram descartadas nessa etapa, porque segmentamos apenas os bois que estavam bem posicionados, ou seja, que de fato bebiam água e não olhavam para cima ou para o lado, exemplificado na Figura 4.

Como mencionado na Seção 3.2, o processo de segmentar a imagem foi feito manualmente. Para isso, utilizamos a ferramenta Make Sense [Skalski 2019], que permite desenhar polígonos em imagens e exportá-los em arquivos no formato JSON. Assim, um algoritmo em Python foi desenvolvido para abrir esses arquivos e segmentar as imagens,




Figura 4. Exemplo de imagens que foram descartadas no processo de segmentação.


de modo que tudo que era polígono ficaria branco e o restante ficaria preto, como podemos observar na Figura 5.



a) Imagem da vista dorsal segmentada



b) Imagem da vista traseira segmentada



c) Imagem da vista lateral segmentada

Figura 5. Exemplo do conjunto de dados segmentados.

3.4. Treinamento e Teste dos Modelos de Predição

Para o treinamento e teste dos modelos, optamos por utilizar apenas a vista dorsal dos bois, devido ao tempo exigido para a segmentação manual das outras visões. Nesse contexto, foram empregadas 240 imagens segmentadas provenientes de 20 bovinos da raça Nelore.

Antes de começar o treinamento, foram extraídas as seguintes características da imagem: área, perímetro, altura, largura, circunferência da área, circunferência do raio, área da elipse e informações de Feret, como o diâmetro mínimo e máximo, totalizando 16 atributos. Vale ressaltar que o peso já estava rotulado, uma vez que essa informação era fornecida pelo relatório da Intergado. A aplicação das funções de Visão Computacional disponíveis na biblioteca da OpenCV [Bradski 2000] foi essencial nessa etapa, visto que elas foram responsáveis por realizar os contornos e tratamentos necessários na imagem,

como redimensionamento e cálculo de *thresholds*. Além disso, os dados de Feret foram calculados com auxílio da biblioteca *feret* disponível em Python.

Assim, utilizamos os dados extraídos para dar início ao treinamento. Primeiro, escolhemos os seguintes modelos para predição do peso: i) AdaBoost, que combina vários modelos menores de regressão linear para formar uma solução robusta. Os modelos menores são ponderados de acordo com seu desempenho individual e os mais eficazes compõem o modelo principal; ii) Gradient Boosting, que constrói árvores de decisão sequencialmente, de modo que a árvore atual tenta corrigir as falhas das anteriores. Normalmente as árvores de decisão são rasas, ou seja, com poucos níveis de profundidade; iii) K-Nearest Neighbors (KNN), que prevê o valor desejado de acordo com uma medida ponderada, normalmente a média, dos k vizinhos mais próximos. É importante ressaltar que o valor de k influencia diretamente no resultado obtido pelo modelo; e iv) XGBoost, que otimiza e aprimora o Gradient Boosting. Basicamente, ele tem mecanismos para regularizar a função de perda, utiliza estruturas de dados mais compactas e pode ser paralelizado mais facilmente.

Após a definição dos modelos, escolhemos a estratégia de busca aleatória para otimizar os hiperparâmetros. Esta escolha foi baseada na sua eficiência comprovada em relação às abordagens mais tradicionais, como a busca em grade e a busca manual, conforme destacado em [Bergstra and Bengio 2012]. Dessa forma, escolhemos quais hiperparâmetros seriam submetidos à variação para cada modelo, estabelecendo também o número de iterações como 10. Em outras palavras, a busca aleatória seria conduzida para retornar 10 configurações distintas para cada um dos modelos em consideração.

Para os treinamentos e testes dos modelos, utilizamos a estratégia de *k-fold cross validation*. Basicamente, os dados foram divididos em k pastas, de modo que o treino foi feito com os dados de $k-1$ subconjuntos e o teste com o subconjunto restante. Esse processo foi repetido k vezes, sendo que testamos com pastas de tamanho 5, 10, 15 e 35. Escolhemos essa estratégia para termos as estimativas mais precisas e menos enviesadas. Tanto o treino quanto o teste aconteceram no Google Colab com 12,67 GB de RAM e um processador Intel(R) Xeon(R) CPU @ 2,20GHz. Para validar os modelos, escolhemos dois indicadores bastante utilizados pelo estado da arte, que são o erro médio absoluto (MAE) e a raiz do erro quadrático médio (RMSE). Além deles, usamos o coeficiente de determinação (R^2) para indicar o quão bem o modelo se ajustou aos dados fornecidos. Os resultados podem ser vistos na Seção 4.

4. Resultados

A Tabela 2 contém os resultados obtidos pelos modelos selecionados. Como mencionado, escolhemos a estratégia do *k-fold*, de modo que o melhor k foi igual a 10. Dito isso, os valores da Tabela 2 foram calculados com base na média dos resultados das 10 execuções de cada modelo. Os erros e o coeficiente de determinação (R^2) foram estimados por meio das métricas fornecidas por funções da biblioteca scikit-learn. Como podemos observar, o Gradient Boosting obteve o melhor desempenho, com um MAE de 11,12 kg, RMSE de 14,58 kg e R^2 de 0,82.

Além da natureza inerente a cada modelo, o fator mais impactante nos resultados foi, sem dúvida, a configuração dos hiperparâmetros. Nesse contexto, o XGBoost escolhido possui poucos parâmetros ajustáveis, tornando mais difícil a otimização do modelo.

Tabela 2. Resultados obtidos pelos modelos utilizados neste trabalho.

Modelo	MAE	RMSE	R²
Gradient Boosting	11,12 kg	14,58 kg	0,82
XGBoost	12,33 kg	16,02 kg	0,79
K-Nearest Neighbors (KNN)	12,34 kg	15,96 kg	0,79
AdaBoost	19,02 kg	23,76 kg	0,51

Dito isso, os hiperparâmetros do Gradient Boosting Regressor foram otimizados de forma mais adequada, atingindo melhores resultados na predição do peso. No caso do AdaBoost, que obteve o pior resultado, o modelo não se ajustou bem ao conjunto de dados, como mostra o R², o que pode ser causado pela presença de ruído. Na Tabela 3, temos os melhores hiperparâmetros de cada modelo encontrados pela otimização utilizando busca aleatória.

Tabela 3. Hiperparâmetros ideais de cada modelo utilizado neste trabalho.

Modelo	Melhores hiperparâmetros
Gradient Boosting Regressor	<i> criterion = 'friedman_mse', max_depth = 50, n_estimators = 1000, learning_rate = 0,01, min_samples_split = 5, min_samples_leaf = 1, max_features = 'log2'</i>
XGBoost	<i> n_estimators = 100, max_depth = 20</i>
K-Nearest Neighbors (KNN)	<i> weights = 'distance', n_neighbors = 5, algorithm = 'auto'</i>
AdaBoost	<i> learning_rate = 0,0001, loss = 'square', n_estimators = 1000, estimator = DecisionTreeRegressor</i>

5. Considerações Finais

Este trabalho apresentou modelos de aprendizado de máquina projetados para prever o peso de bovinos com precisão, sendo que o Gradient Boosting obteve o melhor acerto. A acurácia dos resultados alcançados é atribuída a utilização de imagens segmentadas em conjunto com a otimização dos hiperparâmetros associados a cada modelo. Vale pontuar o papel fundamental das técnicas de Visão Computacional na extração das características geométricas dos animais.

Considerando esses avanços, podemos concluir que a metodologia proposta pode ser vista como uma alternativa no ramo da agropecuária, diminuindo assim os gastos com balanças industriais de alto custo. Contudo, é importante ressaltar que ainda existem melhorias para serem feitas, visto que uma simples alteração nos hiperparâmetros pode afetar diretamente o resultado do modelo. Além disso, como cada raça possui características específicas, seria importante incorporar no conjunto de dados mais de uma raça.

No que diz respeito aos trabalhos futuros, pretendemos automatizar a segmentação das imagens através de arquiteturas capazes de prever rótulos para imagens e realizar a

segmentação binária, como a U-Net [Siddique et al. 2021]. Também queremos avaliar e testar o uso das três visões do animal (dorsal, lateral e traseira) na criação de modelos para a predição do peso e comparar com os resultados obtidos pela metodologia atual. Adicionalmente, planejamos melhorar a qualidade dos dados, aumentando a quantidade de bovinos e diversificando a raça deles. Essas ideias visam aprimorar ainda mais a eficácia e a generalização dos modelos desenvolvidos, contribuindo para uma abordagem mais robusta e diversificada.

Agradecimentos

O presente trabalho foi realizado com o apoio das agências de fomento à pesquisa CNPq, CAPES, FAPESP e FAPEMIG. Agradecemos pelo suporte oferecido.

Referências

- Abreu, B. A., Magalhães, C. J., Duayer, E., Machado, S. H. M., and Silva, D. A. (2015). Variação da medida torácica obtida com a fita métrica tradicional com fator de correção e com a fita de pesagem para bovinos. *Acta Biomedica Brasiliensia*, 6:42–48.
- Agatonovic-Kustrin, S. and Beresford, R. (2000). Basic concepts of artificial neural network (ann) modelling and its application in pharmaceutical research. *J. Pharmac. Biomed. Anal.*, 22:717–727.
- Akaike, H. (2011). *Akaike's Information Criterion*, pages 25–25. Springer Berlin Heidelberg, Berlin, Heidelberg.
- Bergstra, J. and Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(10):281–305.
- Bradski, G. (2000). The OpenCV Library. *Dr. Dobb's Journal of Software Tools*.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45:5–32.
- CEPEA, Centro de Estudos Avançados em Economia Aplicada e CNA, C. N. d. A. e. P. (2023). Pib do agronegócio brasileiro de 1996 a 2023. <https://www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx>.
- Franco, M. O., Marcondes, M. I., Campos, J. M. S., Freitas, D. R., Detmann, E., and Valadares Filho, S. C. (2017). Evaluation of body weight prediction equations in growing heifers. *Acta Scientiarum. Animal Sciences*, 39:201–206.
- Frank, E. and Bouckaert, R. R. (2009). Conditional density estimation with class probability estimators. In Zhou, Z.-H. and Washio, T., editors, *Advances in Machine Learning*, pages 65–81, Berlin, Heidelberg. Springer Berlin Heidelberg.
- 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. In *2020 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8.
- He, K., Zhang, X., Ren, S., and Sun, J. (2015). Deep residual learning for image recognition. *CoRR*, abs/1512.03385.
- Melo, A. (2016). Fatores que influenciam na qualidade da carne bovina: Revisão. *Pubvet*, 10(10).

- 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.
- Mnih, V., Heess, N., Graves, A., and kavukcuoglu, k. (2014). Recurrent models of visual attention. In Ghahramani, Z., Welling, M., Cortes, C., Lawrence, N., and Weinberger, K., editors, *Advances in Neural Information Processing Systems*, volume 27. Curran Associates, Inc.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.
- Sales, M. F. L., Paulino, M. F., Valadares Filho, S. d. C., Paulino, P. V. R., Porto, M. O., and Couto, V. R. M. (2009). Composição corporal e requisitos energéticos de bovinos de corte sob suplementação em pastejo. *Revista Brasileira de Zootecnia*, 38(7):1355–1362.
- Siddique, N., Paheding, S., Elkin, C. P., and Devabhaktuni, V. (2021). U-net and its variants for medical image segmentation: A review of theory and applications. *IEEE Access*, 9:82031–82057.
- Skalski, P. (2019). Make Sense. <https://github.com/SkalskiP/make-sense/>.
- Smola, A. J. and Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14:199–222.
- Tan, M. and Le, Q. V. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. *CoRR*, abs/1905.11946.
- 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.
- Weber, V. A. d. M., Weber, F. d. L., Gomes, R. d. C., Oliveira Junior, A. d. S., Menezes, G. V., Abreu, U. G. P. d., Belete, N. A. d. S., and Pistori, H. (2020). Prediction of girolando cattle weight by means of body measurements extracted from images. *Revista Brasileira de Zootecnia*, 49:e20190110.