

Otimização de Modelos de Regressão para Predição de Peso em Pequenos Ruminantes Utilizando Medidas Corporais

Rafael Luz Araújo^{1,2,4}, Lilian Rosalina Gomes Silva⁵,
José Lindenberg Rocha Sarmiento³, Romuere Rodrigues Veloso e Silva^{1,4}

¹ Universidade Federal do Maranhão (UFMA) – São Luís – MA – Brasil.

² Universidade Federal do Piauí (UFPI) – Picos – PI – Brasil.

³ Universidade Federal do Piauí (UFPI) – Teresina – PI – Brasil.

⁴ Instituto Federal do Piauí (IFPI) – Picos – PI – Brasil.

⁵ Instituto Federal do Piauí (IFPI) – Uruçuí – PI – Brasil.

{rafaluzaraujo, lilian.rosalina}@ifpi.edu.br

{sarmiento, romuere}@ufpi.edu.br

Abstract. *Sheep and goat farming in Brazil is expanding but faces challenges in matching the productivity of cattle farming. On small farms, the absence of scales and the high costs associated with their implementation hinder precise zootechnical control. This study aimed to overcome these challenges by estimating the body weight of sheep and goats using regression techniques optimized with Grid Search. With morphological measurements as inputs, the SVR model showed robust results: MAE of 3.83, RMSE of 5.43, and R² of 85.0%, directly competing with leading literature works. These promising findings contribute to more efficient and sustainable livestock management, enhancing the sheep and goat farming sector in the country.*

Resumo. *A ovinocaprinocultura no Brasil está em expansão, mas enfrenta desafios para equiparar-se à produtividade da bovinocultura. Em pequenas fazendas, a ausência de balanças e os altos custos associados à sua implementação dificultam o controle zootécnico preciso. Este estudo buscou superar esses desafios ao estimar o peso corporal de ovinos e caprinos usando técnicas de regressão otimizadas com Grid Search. Com medidas morfológicas como entradas, o modelo SVR apresentou resultados robustos: um MAE de 3.83, RMSE de 5.43, e R² de 85.0%, competindo diretamente com os principais trabalhos da literatura. Esses resultados promissores contribuem para um manejo mais eficiente e sustentável dos rebanhos, potencializando o setor no país.*

1. Introdução

A ovinocaprinocultura, um setor vital para a produção animal no Brasil, tem mostrado um crescimento significativo nos últimos anos. De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), em 2019, o Brasil contava com um rebanho de aproximadamente 11,3 milhões de caprinos e 19,7 milhões de ovinos [Oliveira 2019]. A Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) relatou um aumento de 229%

e 298% na comercialização de ovinos e caprinos, respectivamente, entre 2006 e 2017 [NÓBREGA and VERGNE 2018]. Apesar desses avanços, a ovinocaprinocultura ainda não alcançou os níveis de produtividade da bovinocultura, necessitando de melhorias em seus processos [FAO. 2020].

Para aumentar a competitividade da ovinocaprinocultura, é essencial a adoção de técnicas modernas de manejo de rebanho, incluindo programas de melhoramento genético e monitoramento contínuo do peso e das condições corporais dos animais [Costa et al. 2018]. Em raças ovinas e caprinas destinadas ao corte, a medição precisa das características corporais é crucial. Essas medidas são usadas para estimar o peso corporal e o coeficiente de condição corporal, bem como para selecionar os melhores fenótipos para animais mais saudáveis e produtivos [Sabbioni et al. 2020]. A precisão na determinação das medidas corporais pode auxiliar em decisões importantes, como o momento ideal para o abate e a avaliação da adesão ao plano alimentar [Martins et al. 2020].

No entanto, a pesagem de animais em fazendas pode ser desafiadora devido à indisponibilidade de balanças de pesagem em campo. Essas balanças são caras e suscetíveis a danos devido ao contato direto com os animais e à exposição a fezes e urina [Song et al. 2018]. Uma alternativa viável é a predição do peso corporal usando medidas morfológicas, como circunferência torácica, altura da cernelha e largura do quadril.

Levando em consideração esses desafios, este estudo propõe o uso de técnicas de otimização de regressores com grid search para prever o peso de pequenos ruminantes a partir de medidas corporais. A otimização dos modelos de regressão visa melhorar a confiabilidade das estimativas de peso, contribuindo para um manejo mais eficiente e sustentável dos rebanhos. Este trabalho não só aborda a viabilidade técnica das técnicas propostas, mas também destaca a importância de métodos não invasivos e de baixo custo para o bem-estar animal e a sustentabilidade na produção de proteína animal.

2. Trabalhos Relacionados

Diversos estudos estão sendo conduzidos para estimar o peso de pequenos ruminantes utilizando técnicas de aprendizado de máquina. Esses estudos exploram uma variedade de métodos, desde análise de modelos de regressão em dados obtidos através de medidas corporais, até estudos mais avançados que analisam imagens com modelos de aprendizado profundo. A Tabela 1 apresenta uma compilação desses estudos, destacando os métodos utilizados, o número de amostras e observações específicas de cada trabalho.

TRABALHO	MÉTODO	AMOSTRAS	OBSERVAÇÕES
[Iqbal 2013]	Regressão	230	Medidas Corporais
[Menesatti et al. 2014]	Visão Computacional Estereoscópica	120	Imagens 2D
[Abbas et al. 2021]	Regressão	152	Medidas Corporais
[Ibrahim et al. 2021]	Regressão	73	Medidas Corporais
[Samperio et al. 2021]	Deep Learning 3D	100	Imagens 3D
[Sant'Ana et al. 2021]	Visão Computacional + Regressão	150	Imagens 2D
[He et al. 2023]	Deep Learning RGB-D	80	Imagens RGB-D
Nosso Trabalho	Aprendizado de Máquina + Grid Search	633	Medidas Corporais

Tabela 1. Trabalhos Relacionados

Ao analisar os trabalhos relacionados, é possível observar uma variedade de abordagens utilizadas para estimar o peso de pequenos ruminantes. A principal diferença do

nosso trabalho em relação aos demais é a integração de aprendizado de máquina com uma busca sistemática de hiperparâmetros (Grid Search), aplicada em um conjunto de dados substancialmente maior, com 633 amostras. Essa abordagem não apenas permite a otimização dos modelos de predição, mas também fornece uma análise mais robusta e generalizável em comparação com estudos anteriores que utilizam um número menor de amostras ou metodologias menos sofisticadas. Além disso, o foco em medidas corporais simples, porém efetivas, oferece uma solução prática e acessível para o contexto de pequenos ruminantes, contrastando com abordagens que requerem equipamentos avançados de captura de imagens.

3. Metodologia

A metodologia proposta nesta pesquisa tem por objetivo a otimização de regressores através do GridSearch para estimação de peso de ovinos e caprinos de forma automática através de medidas corporais e segue o fluxo presente na Figura 1.

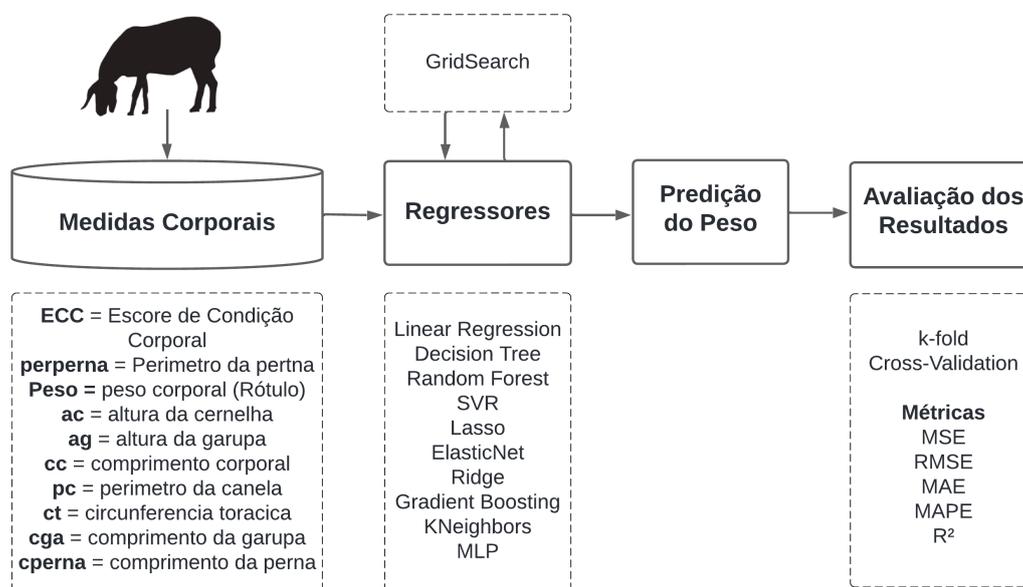


Figura 1. Fluxograma da metodologia proposta.

3.1. Medidas Corporais

Os dados utilizados no estudo pertencem ao projeto "Estudo Genômico Aplicado ao Melhoramento Genético de Ovinos Santa Inês para Características de Carcaça", aprovado pela Comissão de Ética no Uso de Animais da Universidade Federal do Piauí (CEUA/UFPI) sob nº 340/17, que integra o Instituto Nacional de Ciência e Tecnologia em Ciência Animal (INCT-CA) do CNPq, coordenado pela Universidade Federal de Viçosa. Os dados são provenientes de 18 rebanhos manejados na sub-região Meio-Norte do Brasil (estados do Piauí e Maranhão), referentes a animais registrados junto à Associação Brasileira de Criadores de Ovinos (ARCO), ou pertencentes ao núcleo de conservação de caprinos e ovinos da Embrapa Meio-Norte (Campo Maior, Piauí). O banco de dados é composto por registros de pedigree e fenótipos mensurados entre os anos de 2012 a 2021.

A coleta de dados se referiu à medição manual dos animais com o objetivo de obter: peso corporal (P), Escore de Condição Corporal (ECC), perímetro da perna (PPerna),

altura da cernelha (AC), altura da garupa (AG), comprimento corporal (CC), altura do peito (AP), perímetro da canela (PC), perímetro torácico (PT), comprimento da garupa (CGa), e comprimento da perna (CPerna). A base inicial possui 1185 linhas e 43 colunas, porém após realização de pré-processamento para filtrar os atributos que possuem correlação com o peso e remoção de dados ausentes obtemos um dataset com 633 linhas e 10 colunas. Destaca-se que o peso dos animais varia entre 28 quilogramas (kg) e 119.2 kg, essa informação é importante para análise dos resultados.

3.2. Regressores

A aplicação de modelos de regressão para estimar o peso dos animais com base em medidas morfométricas é crucial em sistemas extensivos de criação de ovinos e caprinos, onde o controle zootécnico é limitado. No entanto, a regressão é desafiadora e requer ajustes cuidadosos para garantir resultados precisos. Para melhorar a performance, foi empregado o Grid Search, um método tradicional de otimização de hiperparâmetros, que explora de forma abrangente um subconjunto específico do espaço de hiperparâmetros do algoritmo de treinamento [Liashchynskyi and Liashchynskyi 2019].

Os regressores utilizados neste estudo abrangem uma variedade de técnicas de aprendizado de máquina. O Linear Regression estabelece relações lineares entre peso corporal e medidas morfométricas, porém é limitado a relações lineares e sensível a outliers [James et al. 2013]. Decision Tree, ao dividir o espaço de dados em subconjuntos, captura relações complexas, mas pode sofrer de sobreajuste se não for adequadamente [Hastie et al. 2009]. O Random Forest, constituído por múltiplas árvores de decisão, melhora a robustez e precisão ao reduzir o sobreajuste e melhorar a generalização [Hastie et al. 2009].

Outros métodos incluem o SVR (Support Vector Regression), que busca um hiperplano para minimizar a distância entre os dados e o hiperplano [Hastie et al. 2009]. Lasso, ao penalizar a complexidade do modelo, evita sobreajuste e seleciona variáveis importantes, mas pode eliminar variáveis relevantes se a penalização for excessiva [Muthukrishnan and Rohini 2016]. ElasticNet combina penalidades L1 e L2 para equilibrar seleção de variáveis e regularização [Candia and Tsang 2019]. Ridge penaliza o modelo com L2 para evitar sobreajuste, sendo menos agressivo que o Lasso na seleção de variáveis, mas eficaz na regularização [Carneiro et al. 2022].

Gradient Boosting constrói um modelo sequencialmente, melhorando a precisão ao agregar árvores de decisão fracas, embora exija ajuste fino dos hiperparâmetros para evitar sobreajuste [Bentéjac et al. 2021]. KNeighbors prevê o peso corporal baseado na similaridade entre animais, utilizando a média dos pesos dos vizinhos mais próximos, mas é sensível à dimensionalidade dos dados e ao número de vizinhos escolhidos [Kramer and Kramer 2013]. MLP (Multi-Layer Perceptron), uma rede neural com múltiplas camadas, aprende relações complexas entre medidas morfométricas e peso corporal, necessitando de grande quantidade de dados e ajuste adequado para evitar sobreajuste [Taud and Mas 2018].

3.3. Avaliação dos Resultados

Na avaliação dos resultados deste estudo, utilizou-se o método de validação cruzada k-fold [Burman 1989] para avaliar o desempenho dos regressores. A validação cruzada

k-fold divide o conjunto de dados em k subconjuntos (folds) de tamanho igual. Em cada iteração, um dos subconjuntos é utilizado como conjunto de validação para testar o modelo treinado nos $k-1$ subconjuntos restantes. Nesse estudo utilizou-se $k = 5$. As métricas de avaliação utilizadas estão descritas abaixo conforme [Chicco et al. 2021]:

A Equação 1 ilustra o MSE (Erro Médio Quadrático), que mede a média dos quadrados dos erros, sendo uma medida comum para avaliar a precisão do modelo. E a Equação 2 ilustra o RMSE (Raiz do Erro Médio Quadrático): É a raiz quadrada do MSE e fornece uma interpretação na mesma unidade da variável de resposta.

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

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

A Equação 3 apresenta o MAE (Erro Médio Absoluto), que calcula a média das diferenças absolutas entre os valores previstos e os valores observados. O MAPE (Erro Percentual Absoluto Médio), ilustrado na Equação 4, mede a precisão das previsões em termos percentuais, calculando a média das diferenças percentuais absolutas entre os valores previstos e os valores observados.

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

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (4)$$

A Equação 5 ilustra o R^2 (Coeficiente de Determinação), que indica a proporção da variância na variável dependente que é previsível a partir da variável independente.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

onde \hat{y}_i são os valores previstos, y_i são os valores observados, \bar{y} é a média dos valores observados e n é o número de observações.

Essas métricas são essenciais para avaliar a capacidade dos modelos de regressão em prever corretamente o peso dos animais com base nas características morfológicas coletadas.

4. Resultados e Discussões

Os hiperparâmetros testados com Grid Search para cada um dos regressores estão detalhados na Tabela 2. Eles foram selecionados de maneira estratégica para abranger um amplo espaço de busca, garantindo uma exploração abrangente das configurações possíveis.

Regressor	Hiperparâmetros
Linear Regression	N/A
Decision Tree	max_depth: [None, 5, 10, 15, 20, 25], min_samples_split: [2, 5, 10]
Random Forest	n_estimators: [50, 100, 150, 200], max_depth: [None, 5, 10, 15, 20, 25], min_samples_split: [2, 5, 10]
SVR	kernel: ['linear', 'poly', 'rbf', 'sigmoid'], C: [0.1, 1, 10, 100, 200], gamma: ['scale', 'auto']
Lasso	alpha: [0.01, 0.1, 1, 10, 100], max_iter: [1000]
ElasticNet	alpha: [0.01, 0.1, 1, 10, 100], l1_ratio: [0.1, 0.3, 0.5, 0.7, 0.9], max_iter: [1000]
Ridge	alpha: [0.01, 0.1, 1, 10, 100]
Gradient Boosting	n_estimators: [50, 100, 150, 200], learning_rate: [0.01, 0.1, 0.2, 0.5], max_depth: [3, 5, 7, 9]
KNeighbors	n_neighbors: [3, 5, 7, 10, 15], weights: ['uniform', 'distance'], p: [1, 2]
MLP	hidden_layer_sizes: [(50,), (100,), (150,), (50, 50), (100, 100)], activation: ['identity', 'logistic', 'tanh', 'relu'], solver: ['lbfgs', 'sgd', 'adam'] alpha: [0.0001, 0.001, 0.01, 0.1], learning_rate: ['constant', 'adaptive']

Tabela 2. Regressores e seus Hiperparâmetros para Grid Search.

Os resultados da aplicação do Grid Search para os diferentes regressores estão apresentados na Tabela 3. Observando os resultados, destaca-se que o SVR apresentou o melhor desempenho geral entre os modelos avaliados, com um MSE de 29.53 ± 3.02 , RMSE de 5.43 ± 0.27 , MAE de 3.83 ± 0.22 , MAPE 7.00 ± 0.00 , e R^2 de 0.85 ± 0.02 , o SVR demonstrou uma capacidade superior de previsão.

	MSE	RMSE	MAE	MAPE	R2
Linear Regression	30.57 ± 3.36	5.52 ± 0.30	4.03 ± 0.29	7.00 ± 0.00	84.00 ± 2.00
Decision Tree	49.98 ± 11.23	7.03 ± 0.76	5.00 ± 0.21	9.00 ± 0.00	74.00 ± 6.00
Random Forest	34.31 ± 5.65	5.84 ± 0.48	4.21 ± 0.30	7.00 ± 1.00	83.00 ± 2.00
SVR	29.53 ± 3.02	5.43 ± 0.27	3.83 ± 0.22	7.00 ± 0.00	85.00 ± 2.00
Lasso	30.57 ± 3.36	5.52 ± 0.30	4.03 ± 0.29	7.00 ± 0.00	84.00 ± 2.00
ElasticNet	30.55 ± 3.37	5.52 ± 0.30	4.02 ± 0.28	7.00 ± 0.00	84.00 ± 2.00
Ridge	30.55 ± 3.36	5.52 ± 0.30	4.03 ± 0.29	7.00 ± 0.00	84.00 ± 2.00
Gradient Boosting	31.55 ± 5.52	5.60 ± 0.48	4.06 ± 0.37	7.00 ± 1.00	84.00 ± 2.00
KNeighbors	36.30 ± 2.25	6.02 ± 0.19	4.35 ± 0.25	8.00 ± 0.00	81.00 ± 2.00
MLP	30.57 ± 3.36	5.52 ± 0.30	4.03 ± 0.29	7.00 ± 0.00	84.00 ± 2.00

Tabela 3. Resultados da otimização dos modelos com Grid Search.

Para interpretar esses resultados, é crucial lembrar que a faixa de pesos dos animais na base de dados, vai de 28 kg a 119.2 kg. O RMSE de 5.43 ± 0.27 significa que, em média, as previsões do SVR podem variar cerca de 5.43 kg para mais ou para menos em relação ao peso real dos animais. Dado que a variação absoluta de peso na base é de aproximadamente 91.2 kg (119.2 kg - 28 kg), um RMSE de 5.43 ± 0.27 pode ser considerado aceitável, representando aproximadamente 6% da faixa total de peso.

Além disso, o R^2 de 0.85 ± 0.02 indica que o modelo SVR consegue explicar aproximadamente 85% da variabilidade observada nos dados de peso dos animais. Isso sugere uma boa capacidade do modelo em capturar as relações entre os dados de entrada (features) e o peso dos animais.

Os modelos de Regressão Linear, Lasso, ElasticNet, Ridge e Gradient Boosting apresentaram desempenho próximo entre si, com métricas de erro e coeficiente de determinação consistentes. Já os modelos Decision Tree, Random Forest, KNeighbors e MLP mostraram desempenho um pouco inferior, particularmente em termos de RMSE e MAE, o que pode indicar uma maior dispersão nas previsões ou uma tendência a subesti-

mar ou superestimar o peso dos animais. Os melhores hiper parâmetros encontrados estão presentes na Tabela 4

Regressor	Melhores Hiper Parâmetros
Decision Tree	max_depth: 5.0, min_samples_split: 2.0
Random Forest	max_depth: 20.0, min_samples_split: 2.0, n_estimators: 150.0
Gradient Boosting	max_depth: 3.0, learning_rate: 0.1, n_estimators: 50.0
SVR	C: 100.0, gamma: scale, kernel: poly
Lasso	alpha: 0.01
ElasticNet	alpha: 0.01, l1_ratio: 0.1
Ridge	alpha: 10.0
MLP	alpha: 0.1, learning_rate: constant, hidden_layer_sizes: (100, 100), activation: identity, solver: lbfgs
KNeighbors	n_neighbors: 10.0, p: 1.0, weights: distance

Tabela 4. Melhores parâmetros obtidos para cada regressor.

A Figura 2 apresenta a reta de regressão de cada um dos 5 folds para que seja possível entender melhor os resultados obtidos. Ao analisar as plotagens, observou-se que a maioria dos animais na base de dados possui pesos até 80 kg, e esses estão mais próximos da linha de regressão, indicando que o modelo SVR consegue fazer previsões mais precisas para essa faixa de peso. No entanto, à medida que os pesos se aproximam de 80 kg e ultrapassam esse limite até 119.2 kg, observa-se uma maior dispersão das previsões em relação à reta de regressão. Os animais com pesos até 70 kg mostram-se especialmente bem ajustados pelo modelo, enquanto entre 70 kg e 80 kg já se percebe uma tendência de maior dispersão nas previsões. Para pesos acima de 80 kg, essa dispersão aumenta significativamente, indicando uma capacidade diminuída do modelo em prever com precisão os pesos dos animais mais pesados.

Essa análise visual ressalta a robustez do modelo SVR para a maioria dos animais na faixa de peso estudada, fornecendo insights importantes sobre suas capacidades e limitações específicas. Embora o modelo demonstre eficácia em prever pesos para a maioria dos animais, é crucial considerar a variabilidade observada, especialmente para os pesos mais elevados, onde a precisão das previsões pode ser mais desafiadora devido à maior dispersão dos dados. Isso, pode ser ocasionado pelo baixo número de amostras nessa faixa de peso.

4.1. Comparação com Trabalhos Relacionados

Os resultados apresentados na Tabela 5 revelam diferentes métricas de desempenho de estimação de peso em pequenos ruminantes, comparando diversos estudos recentes. Destaca-se que o trabalho de Abbas et al. [Abbas et al. 2021] alcançou o menor RMSE, indicando uma precisão significativa na estimativa de peso. Além disso, o estudo de Ibrahim et al. [Ibrahim et al. 2021] obteve o maior coeficiente de determinação (R^2), demonstrando uma boa capacidade de explicar a variação no peso corporal dos animais. Nosso trabalho, por sua vez, apresentou um MAE competitivo e um MRAE destacável em relação aos demais estudos listados, indicando uma boa performance na predição de peso em pequenos ruminantes. Entretanto, é importante destacar que as diferenças nos tipos de dados utilizados em cada um desses estudos representam um desafio significativo para

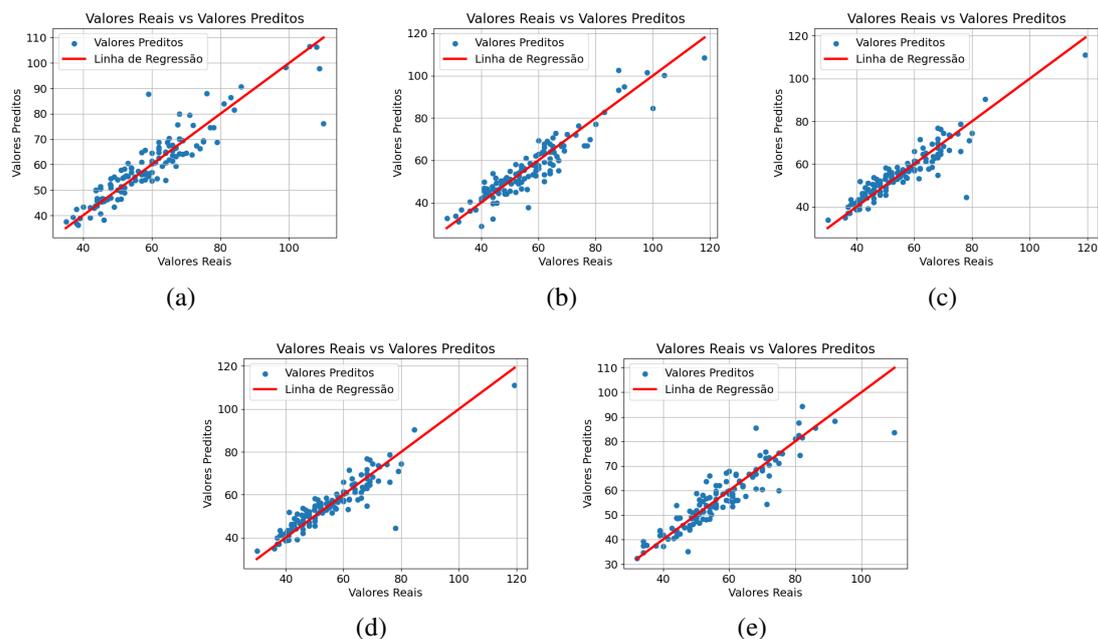


Figura 2. Retas de regressão para cada fold. (a) fold 1, (b) fold 2, (c) fold 3, (d) fold 4 e (e) fold 5.

uma comparação mais direta e justa. As variações nas características dos dados, como o ambiente de coleta, quantidade de amostras, e as metodologias de pré-processamento, podem impactar os resultados finais. Essa limitação deve ser considerada ao interpretar o desempenho dos nossos modelos em relação à literatura existente.

TRABALHO	MAE	MRAE	RMSE	MAPE	R ²
[Iqbal 2013]	—	—	—	—	69,1
[Menesatti et al. 2014]	3.54 ± 3.40	—	—	—	—
[Abbas et al. 2021]	—	—	2.61	6.20	64.48
[Ibrahim et al. 2021]	—	—	—	7.82	88.4
[Sant’Ana et al. 2021]	3.099 ± 1.52	—	3.481 ± 1.67	8.783 ± 4.56	68.7 ± 9.0
[Samperio et al. 2021]	—	6	—	—	86
[He et al. 2023]	6.736	—	8.866	14.605	—
Nosso Trabalho	3.83 ± 0.22	5.43 ± 0.27	5.43 ± 0.27	7.00 ± 0.00	85.0 ± 2.0

Tabela 5. Comparação com trabalhos relacionados

Em síntese, os resultados obtidos sugerem que o SVR é uma escolha robusta para este conjunto de dados, oferecendo previsões precisas dentro de uma margem aceitável em relação à variação de peso dos animais na base.

5. Conclusão

Neste estudo, exploramos a aplicação de técnicas de otimização com Grid Search para prever o peso de pequenos ruminantes a partir de medidas morfológicas. Utilizando um conjunto abrangente de dados sobre características corporais, implementamos e refinamos modelos de regressão que demonstraram uma precisão notável na estimativa de peso. Os resultados destacaram a eficácia do regressor SVR e mostraram que é viável substituir

métodos tradicionais de pesagem por abordagens baseadas em morfologia, oferecendo uma alternativa prática e econômica para fazendas que enfrentam desafios logísticos na pesagem de animais.

Além de melhorar a precisão na estimativa de peso, este estudo enfatizou a importância de métodos não invasivos e de baixo custo para o manejo eficiente dos rebanhos, promovendo o bem-estar animal e a sustentabilidade na produção animal. As descobertas indicam que a integração contínua de novas técnicas de aprendizado de máquina e a expansão do conjunto de dados podem aprimorar ainda mais a precisão dos modelos, tornando-os mais robustos e aplicáveis em diferentes contextos agropecuários.

Para futuras pesquisas, pretende-se explorar o uso de técnicas avançadas de aprendizado de máquina, como redes neurais profundas, para capturar relações complexas entre medidas morfológicas e peso corporal. Além disso, a ampliação do conjunto de dados para incluir informações genéticas e ambientais poderá enriquecer as previsões e fornecer *insights* adicionais sobre a influência desses fatores na produtividade animal. Essas abordagens têm o potencial de abrir novas perspectivas para o aprimoramento das práticas de manejo e seleção genética na ovinocaprinocultura, impulsionando ainda mais a competitividade e sustentabilidade do setor.

Referências

- Abbas, A., Ullah, M. A., and Waheed, A. (2021). Body weight prediction using different data mining algorithms in thalli sheep: A comparative study. *Veterinary World*, 14(9):2332.
- Bentéjac, C., Csörgő, A., and Martínez-Muñoz, G. (2021). A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, 54:1937–1967.
- Burman, P. (1989). A comparative study of ordinary cross-validation, v-fold cross-validation and the repeated learning-testing methods. *Biometrika*, 76(3):503–514.
- Candia, J. and Tsang, J. S. (2019). enetxplorer: an r package for the quantitative exploration of elastic net families for generalized linear models. *BMC bioinformatics*, 20:1–11.
- Carneiro, T. C., Rocha, P. A., Carvalho, P. C., and Fernández-Ramírez, L. M. (2022). Ridge regression ensemble of machine learning models applied to solar and wind forecasting in brazil and spain. *Applied Energy*, 314:118936.
- Chicco, D., Warrens, M. J., and Jurman, G. (2021). The coefficient of determination r-squared is more informative than smape, mape, mse and rmse in regression analysis evaluation. *Peerj computer science*, 7:e623.
- Costa, J. A. A., Reis, F. A., and de Lucena, C. C. (2018). Boletim do centro de inteligência e mercado de caprinos e ovinos [recurso eletrônico]. Dados eletrônicos.
- FAO. (2020). *World cattle inventory: Ranking of countries*. FAO.
- Hastie, T., Tibshirani, R., Friedman, J. H., and Friedman, J. H. (2009). *The elements of statistical learning: data mining, inference, and prediction*, volume 2. Springer.
- He, C., Qiao, Y., Mao, R., Li, M., and Wang, M. (2023). Enhanced litehrnet based sheep weight estimation using rgb-d images. *Computers and Electronics in Agriculture*, 206:107667.

- Ibrahim, A., Artama, W. T., Budisatria, I. G. S., Yuniawan, R., Atmoko, B. A., and Wi-dayanti, R. (2021). Regression model analysis for prediction of body weight from body measurements in female batur sheep of banjarnegara district, indonesia. *Biodiversitas Journal of Biological Diversity*, 22(7).
- Iqbal, M. (2013). Prediction of body weight through body measurements in beetal goats. *Pakistan Journal of Science*, 65(4).
- James, G., Witten, D., Hastie, T., Tibshirani, R., et al. (2013). *An introduction to statistical learning*, volume 112. Springer.
- Kramer, O. and Kramer, O. (2013). K-nearest neighbors. *Dimensionality reduction with unsupervised nearest neighbors*, pages 13–23.
- Liashchynskiy, P. and Liashchynskiy, P. (2019). Grid search, random search, genetic algorithm: a big comparison for nas. *arXiv preprint arXiv:1912.06059*.
- Martins, B., Mendes, A., Silva, L., Moreira, T., Costa, J., Rotta, P., Chizzotti, M., and Marcondes, M. (2020). Estimating body weight, body condition score, and type traits in dairy cows using three dimensional cameras and manual body measurements. *Livestock science*, 236:104054.
- Menesatti, P., Costa, C., Antonucci, F., Steri, R., Pallottino, F., and Catillo, G. (2014). A low-cost stereovision system to estimate size and weight of live sheep. *Computers and Electronics in Agriculture*, 103:33–38.
- Muthukrishnan, R. and Rohini, R. (2016). Lasso: A feature selection technique in predictive modeling for machine learning. In *2016 IEEE international conference on advances in computer applications (ICACA)*, pages 18–20. Ieee.
- NÓBREGA, A. and VERGNE, M. (2018). Novo censo agropecuário mostra crescimento de efetivo de caprinos e ovinos no nordeste. *Empresa Brasileira de Pesquisa Agropecuária: Embrapa Caprinos e Ovinos*.
- Oliveira, M. (2019). Produção da pecuária municipal 2018. *Catalog of the Instituto Brasileiro de Geografia e Estatística*, 84(01014234):1–8.
- Sabbioni, A., Beretti, V., Superchi, P., and Ablondi, M. (2020). Body weight estimation from body measures in cornigliese sheep breed. *Italian Journal of Animal Science*, 19(1):25–30.
- Samperio, E., Lidón, I., Rebollar, R., Castejón-Limas, M., and Álvarez-Aparicio, C. (2021). Lambs' live weight estimation using 3d images. *Animal*, 15(5):100212.
- Sant'Ana, D. A., Pache, M. C. B., Martins, J., Soares, W. P., de Melo, S. L. N., Garcia, V., de Moares Weber, V. A., da Silva Heimbach, N., Mateus, R. G., and Pistori, H. (2021). Weighing live sheep using computer vision techniques and regression machine learning. *Machine Learning with Applications*, 5:100076.
- Song, X., Bokkers, E., Van der Tol, P., Koerkamp, P. G., and Van Mourik, S. (2018). Automated body weight prediction of dairy cows using 3-dimensional vision. *Journal of dairy science*, 101(5):4448–4459.
- Taud, H. and Mas, J.-F. (2018). Multilayer perceptron (mlp). *Geomatic approaches for modeling land change scenarios*, pages 451–455.