v7.n8.2026

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

ESTIMATIVA DE PESO DE SUÍNOS A PARTIR DE IMAGENS RGB UTILIZANDO REDES NEURAIS CONVOLUCIONAIS E O DATASET PIGRGB-WEIGHT

PIG WEIGHT ESTIMATION FROM RGB IMAGES USING CONVOLUTIONAL NEURAL NETWORKS AND THE PIGRGB-WEIGHT DATASET

ESTIMACIÓN DEL PESO DE CERDOS A PARTIR DE IMÁGENES RGB UTILIZANDO REDES NEURONALES CONVOLUCIONALES Y EL DATASET PIGRGB-WEIGHT

Vinicius Tessele[1] , Jhonatan da Silva Margraf[2], Vinícius Hillebrand Carraro[2], Marco Antonio Wandraski[2], Luiz Henrique Zavatini Feltrin[2], Davi Specia[2]

https://doi.org/10.47820/recima21.v7i8.8496

PUBLICADO: 08/2026

RESUMO

A estimativa do peso de suínos desempenha papel fundamental na suinocultura de precisão, auxiliando o manejo alimentar, o monitoramento do crescimento e a tomada de decisão no processo produtivo. Entretanto, os métodos convencionais baseados em pesagem física apresentam limitações relacionadas ao custo operacional, à demanda por mão de obra e ao estresse causado aos animais. Este trabalho propõe um modelo de estimativa de peso a partir de imagens RGB utilizando redes neurais convolucionais e o dataset público PigRGB-Weight. Para isso, foi empregada a arquitetura ResNet18 com transferência de aprendizado, adaptada para uma tarefa de regressão. As imagens passaram por etapas de pré-processamento e aumento de dados com o objetivo de ampliar a capacidade de generalização do modelo. O treinamento foi realizado durante 30 e 50 épocas utilizando o otimizador AdamW, a função de perda Mean Squared Error (MSE) e a métrica Mean Absolute Error (MAE). Os resultados obtidos demonstraram desempenho consistente, alcançando MAE aproximado de 6,51 kg no conjunto de validação. Além disso, as predições apresentaram boa precisão mesmo diante de variações nas condições de captura das imagens. Os resultados indicam que a utilização de aprendizado profundo aplicado a imagens RGB constitui uma alternativa promissora para sistemas automatizados de monitoramento na suinocultura, oferecendo uma solução não invasiva, escalável e de baixo custo.

PALAVRAS-CHAVE: Visão computacional. *Deep learning.* Suinocultura de precisão.

ABSTRACT

Pig weight estimation plays a fundamental role in precision livestock farming by supporting feeding management, growth monitoring, and decision-making throughout the production process. However, conventional weighing methods based on physical scales present operational limitations, including high costs, labor requirements, and animal stress. This study proposes a pig weight estimation model from RGB images using convolutional neural networks and the public PigRGB-Weight dataset. The ResNet18 architecture with transfer learning was adapted for a regression task. Image preprocessing and data augmentation techniques were applied to improve the model's generalization capability. Training was performed for 30 and 50 epochs using the AdamW optimizer, the Mean Squared Error (MSE) loss function, and the Mean Absolute Error (MAE) evaluation metric.

The proposed model achieved consistent performance, reaching an MAE of approximately 6.51 kg on the validation set. Furthermore, the predictions remained accurate despite variations in

[1] Doutorando em Informática UFPR - PPGInf, Professor Faculdade Donaduzzi, Toledo, Paraná, Brasil.
[2] Graduando em Inteligência Artificial, Aluno Faculdade Donaduzzi, Toledo, Paraná, Brasil.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

image acquisition conditions. These findings indicate that deep learning applied to RGB images represents a promising approach for automated monitoring in precision pig farming, providing a non-invasive, scalable, and cost-effective solution.

KEYWORDS: *Computer vision. Deep learning. Precision livestock farming.*

RESUMEN
La estimación del peso de los cerdos desempeña un papel fundamental en la ganadería porcina de precisión, contribuyendo al manejo alimentario, al monitoreo del crecimiento y a la toma de decisiones durante el proceso productivo. Sin embargo, los métodos tradicionales basados en balanzas físicas presentan limitaciones operativas, como altos costos, necesidad de mano de obra y estrés para los animales. En este trabajo se propone un modelo de estimación del peso a partir de imágenes RGB utilizando redes neuronales convolucionales y el conjunto de datos público PigRGB-Weight. Se empleó la arquitectura ResNet18 con transferencia de aprendizaje, adaptada para una tarea de regresión. Las imágenes fueron sometidas a procesos de preprocesamiento y aumento de datos con el fin de mejorar la capacidad de generalización del modelo. El entrenamiento se realizó durante 30 y 50 épocas utilizando el optimizador AdamW, la función de pérdida Mean Squared Error (MSE) y la métrica Mean Absolute Error (MAE). Los resultados mostraron un desempeño consistente, alcanzando un MAE aproximado de 6,51 kg en el conjunto de validación. Además, las predicciones mantuvieron una buena precisión incluso ante variaciones en las condiciones de captura de las imágenes. Los resultados indican que el aprendizaje profundo aplicado a imágenes RGB constituye una alternativa prometedora para el monitoreo automatizado en la producción porcina, ofreciendo una solución no invasiva, escalable y de bajo costo.

PALABRAS-CLAVE*: Visión por computadora. Aprendizaje profundo. Ganadería porcina de precisión.*

INTRODUÇÃO

A crescente demanda por eficiência produtiva na suinocultura tem impulsionado a adoção de tecnologias digitais voltadas ao monitoramento automatizado de animais. Entre os principais parâmetros do monitoramento animal, o peso corporal destaca-se como um indicador essencial para o manejo alimentar, acompanhamento do crescimento e definição do momento ideal de abate. No entanto, os métodos tradicionais de pesagem, baseados no uso de balanças físicas, apresentam limitações operacionais, como elevado custo, necessidade de mão de obra e potencial estresse aos animais.

Nesse contexto, a visão computacional surge como uma alternativa, permitindo a estimativa de peso de forma não invasiva a partir de imagens. Abordagens tradicionais utilizam técnicas de segmentação e extração manual de características morfológicas, como área corporal, comprimento e largura, associadas posteriormente a modelos de regressão. Entretanto, tais métodos dependem fortemente da qualidade da segmentação e da definição adequada das características, podendo limitar a capacidade de generalização dos modelos.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Com o avanço do aprendizado profundo, das redes neurais convolucionais, tornou-se possível desenvolver modelos capazes de aprender automaticamente padrões relevantes diretamente das imagens, eliminando a necessidade de engenharia manual de atributos. Nesse cenário, o uso de arquiteturas como a ResNet tem se destacado em tarefas de regressão baseadas em dados visuais, apresentando elevado desempenho e robustez.

O problema central deste estudo consiste em verificar se modelos baseados em aprendizado profundo são capazes de estimar com precisão o peso de suínos a partir de imagens RGB, superando ou complementando abordagens tradicionais baseadas em extração manual de características.

A justificativa deste trabalho fundamenta-se na necessidade de soluções automatizadas, escaláveis e não invasivas para o monitoramento do peso animal, contribuindo para a suinocultura de precisão e para a melhoria da eficiência produtiva. Além disso, a utilização de datasets públicos, como o PigRGB-Weight, possibilita a reprodutibilidade dos experimentos e o avanço científico na área.

O objetivo geral deste estudo é desenvolver e avaliar um modelo baseado em redes neurais convolucionais para estimar o peso de suínos a partir de imagens RGB.

Como objetivos específicos, destacam-se: (i) implementar um modelo baseado na arquitetura ResNet18 (Residual Network) adaptado para regressão; (ii) aplicar técnicas de pré-processamento e aumento de dados para melhorar a generalização do modelo; (iii) avaliar o desempenho do modelo por meio de métricas de erro, como o erro absoluto médio (MAE); e (iv) comparar a abordagem proposta com métodos tradicionais baseados em extração manual de características.

1. REFERENCIAL TEÓRICO

A estimativa de peso de suínos a partir de imagens tem sido investigada como uma alternativa não invasiva aos métodos tradicionais de pesagem. Estudos recentes têm explorado diferentes abordagens baseadas em visão computacional, variando desde técnicas clássicas de aprendizado de máquina até métodos mais avançados baseados em aprendizado profundo.

O trabalho de Ji et al. (2025) propõe um método baseado em aprendizado de máquina tradicional para estimativa de peso, utilizando o dataset PigRGB-Weight. Nessa abordagem, as imagens são inicialmente segmentadas para isolar o animal do fundo, sendo posteriormente utilizadas para extração de características morfológicas, como área corporal e dimensões geométricas. Essas características são então empregadas como entrada para modelos de

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

regressão, como Random Forest, Support Vector Regression (SVR) e XGBoost. Embora eficaz, essa abordagem depende fortemente da qualidade da segmentação e da seleção manual das características.

De forma semelhante, Chen et al. (2025) propõem um método baseado em segmentação de alta precisão combinada com extração de características bidimensionais. O foco principal deste trabalho está na melhoria da qualidade das características extraídas, buscando aumentar a correlação entre atributos geométricos e o peso real dos animais. No entanto, assim como em abordagens tradicionais, o desempenho do modelo está diretamente relacionado à etapa de engenharia de atributos.

Avançando na integração de técnicas de aprendizado profundo, Jiang et al. (2024) apresentam um framework que combina o uso de Mask R-CNN para segmentação dos suínos com modelos de regressão baseados em ensemble. Nesse caso, o deep learning é utilizado apenas para a detecção e segmentação, enquanto a etapa de estimativa de peso ainda depende de modelos tradicionais, caracterizando uma abordagem híbrida.

Por outro lado, Ma et al. (2025) exploram o uso de redes neurais convolucionais mais avançadas, como EfficientNetV2, associadas a câmeras de profundidade. Essa abordagem permite a captura de informações tridimensionais, resultando em maior precisão na estimativa do peso. Entretanto, a necessidade de sensores adicionais aumenta o custo e limita a aplicabilidade em ambientes reais de produção.

A arquitetura ResNet, proposta por He et al. (2016), é uma rede neural convolucional profunda que introduz o conceito de conexões residuais, também conhecidas como *skip connections*. Essas conexões permitem que a informação seja propagada diretamente entre camadas não consecutivas, mitigando o problema do desvanecimento do gradiente (*vanishing gradient*) e facilitando o treinamento de redes mais profundas.

A variante ResNet18 foi adotada neste trabalho devido ao seu bom equilíbrio entre desempenho e custo computacional, sendo adequada para aplicações com conjuntos de dados de tamanho moderado. Além disso, sua estrutura relativamente simples favorece a utilização de técnicas de *transfer learning*, permitindo aproveitar pesos previamente treinados em grandes bases de dados, como o ImageNet.

Diante desse panorama, observa-se que grande parte dos trabalhos ainda depende de etapas intermediárias de processamento, como segmentação e extração manual de características. Nesse contexto, abordagens baseadas em aprendizado profundo end-to-end têm se mostrado promissoras, pois permitem que o modelo aprenda automaticamente representações relevantes diretamente das imagens.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Assim, o presente trabalho diferencia-se por adotar uma abordagem baseada em redes neurais convolucionais, utilizando a arquitetura ResNet18 para estimativa direta do peso a partir de imagens RGB, eliminando a necessidade de engenharia manual de atributos. Essa estratégia visa simplificar o pipeline e aumentar a capacidade de generalização do modelo.

2. METODOLOGIA

O presente estudo foi desenvolvido com o objetivo de estimar o peso de suínos a partir de imagens RGB utilizando técnicas de aprendizado profundo. Para isso, foi utilizado o dataset PigRGB-Weight, composto por imagens de suínos associadas aos seus respectivos pesos reais, organizadas em diferentes classes de peso.

Inicialmente, foi realizada a organização dos dados em subconjuntos de treinamento e validação, utilizando divisão estratificada, estratégia importante para avaliar a capacidade de generalização do modelo. Cada fold contém imagens distribuídas em diferentes faixas de peso, garantindo diversidade e representatividade do conjunto de dados. O treinamento foi realizado utilizando a linguagem Python e a biblioteca PyTorch. A arquitetura ResNet18 foi inicializada com pesos pré-treinados na base ImageNet, sendo substituída a camada totalmente conectada final por uma camada linear destinada à tarefa de regressão.

Durante o treinamento, foi utilizado o otimizador AdamW, com taxa de aprendizagem de 3×10^{-4} e *weight decay* de 1×10^{-4}, *batch size* igual a 64 e treinamento durante 30 e 50 épocas. A função de perda utilizada foi o Erro Quadrático Médio (MSE — *Mean Squared Error*). As imagens foram redimensionadas para 224 × 224 pixels e normalizadas utilizando os parâmetros padrão empregados no treinamento original da ImageNet (média=[0,485; 0,456; 0,406], desvio padrão=[0,229; 0,224; 0,225]). Além do Erro Absoluto Médio (MAE), foram calculadas métricas complementares para avaliar o desempenho do modelo, incluindo a Raiz do Erro Quadrático Médio (RMSE), o coeficiente de determinação (R^2) e estatísticas descritivas dos erros absolutos, como média, desvio padrão, mediana, valores mínimo e máximo. Essas métricas permitem uma avaliação mais abrangente da precisão e da capacidade de generalização do modelo.

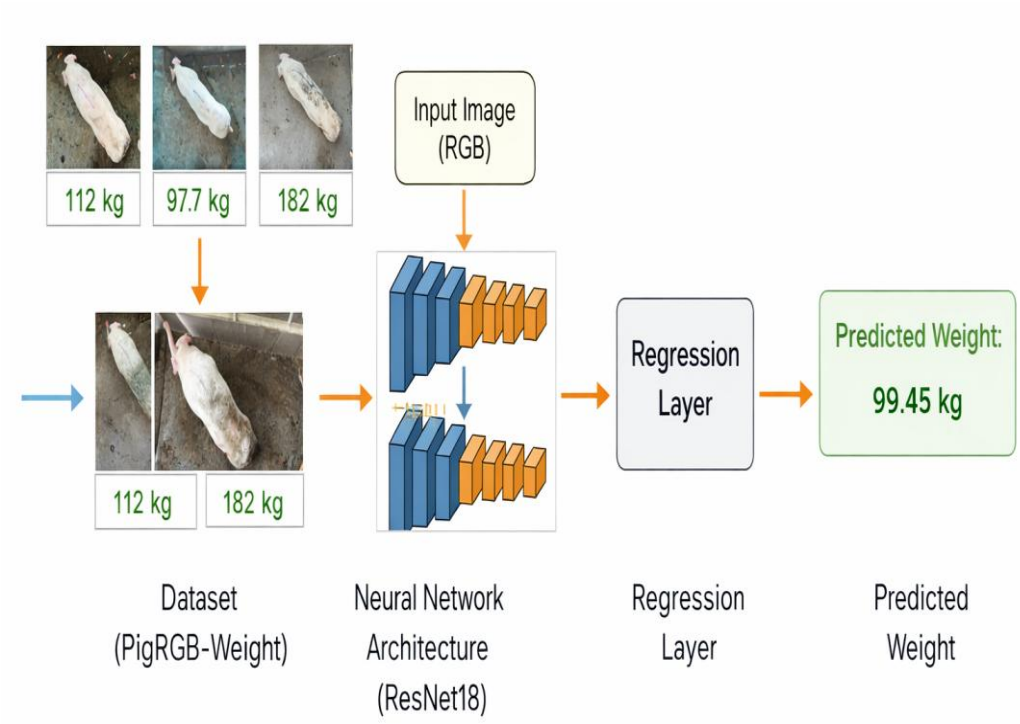
Para o conjunto de treinamento, foram aplicadas técnicas de aumento de dados (data augmentation), incluindo inversão horizontal aleatória (RandomHorizontalFlip), rotação aleatória de até 15°, variação de cor (ColorJitter) com fatores de brilho e contraste de 0,2, e translação aleatória (RandomAffine) de até 10% em ambos os eixos. No conjunto de validação, foram aplicadas apenas as transformações de redimensionamento e normalização, sem aumento de dados.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

O conjunto de dados foi dividido em 80% para treinamento e 20% para validação, utilizando divisão estratificada por faixas de peso (intervalos de 10 kg), garantindo representatividade em ambos os subconjuntos.

O treinamento foi conduzido na plataforma Google Colab, utilizando GPU Tesla T4, processador Intel Xeon de dois núcleos disponibilizado pela plataforma, e 15 GB de memória RAM. O tempo médio de treinamento foi de aproximadamente 190 minutos.

Figura 1. Arquitetura do modelo proposto para estimativa de peso de suínos utilizando imagens RGB



Fonte: Autoria própria (2026).

A Figura 1 apresenta a arquitetura geral do modelo proposto. O fluxo inicia-se com a entrada de imagens RGB provenientes do dataset PigRGB-Weight, contendo suínos em diferentes posições e condições ambientais. Em seguida, essas imagens são processadas por uma rede neural convolucional baseada na arquitetura ResNet18, responsável pela extração automática de características relevantes.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Antes de serem inseridas no modelo, as imagens passam por uma etapa de pré-processamento, que inclui o redimensionamento para dimensões compatíveis com a rede, a normalização dos valores de pixel e a aplicação de técnicas de aumento de dados (*data augmentation*), como rotações e inversões horizontais. Essas estratégias visam ampliar a variabilidade do conjunto de dados e contribuir para a redução do sobreajuste, promovendo maior capacidade de generalização do modelo.

Posteriormente, as características extraídas pela rede são encaminhadas para uma camada totalmente conectada adaptada para regressão, responsável por estimar diretamente o peso dos suínos. Esse processo permite a modelagem de relações não lineares entre as informações visuais e o peso real dos animais, eliminando a necessidade de extração manual de atributos.

Para a modelagem, foi utilizada a arquitetura ResNet18 pré-treinada em ImageNet, explorando a técnica de transfer learning. A camada final da rede foi adaptada para uma tarefa de regressão, permitindo a predição direta do peso dos animais a partir das imagens.

Foram treinados dois modelos, um por 30 e outro por 50 épocas, ambos apresentando convergência progressiva da função de perda. Durante o treinamento, observou-se uma redução significativa do erro desde valores iniciais elevados até níveis estáveis nas últimas épocas, indicando aprendizado eficiente por parte da rede.

A avaliação do modelo foi realizada com base no MAE no conjunto de validação, sendo obtido um valor aproximado de 6,51 kg ao final do treinamento. Esse resultado indica a capacidade do modelo em estimar o peso dos animais com erro relativamente baixo, considerando a variabilidade presente no dataset.

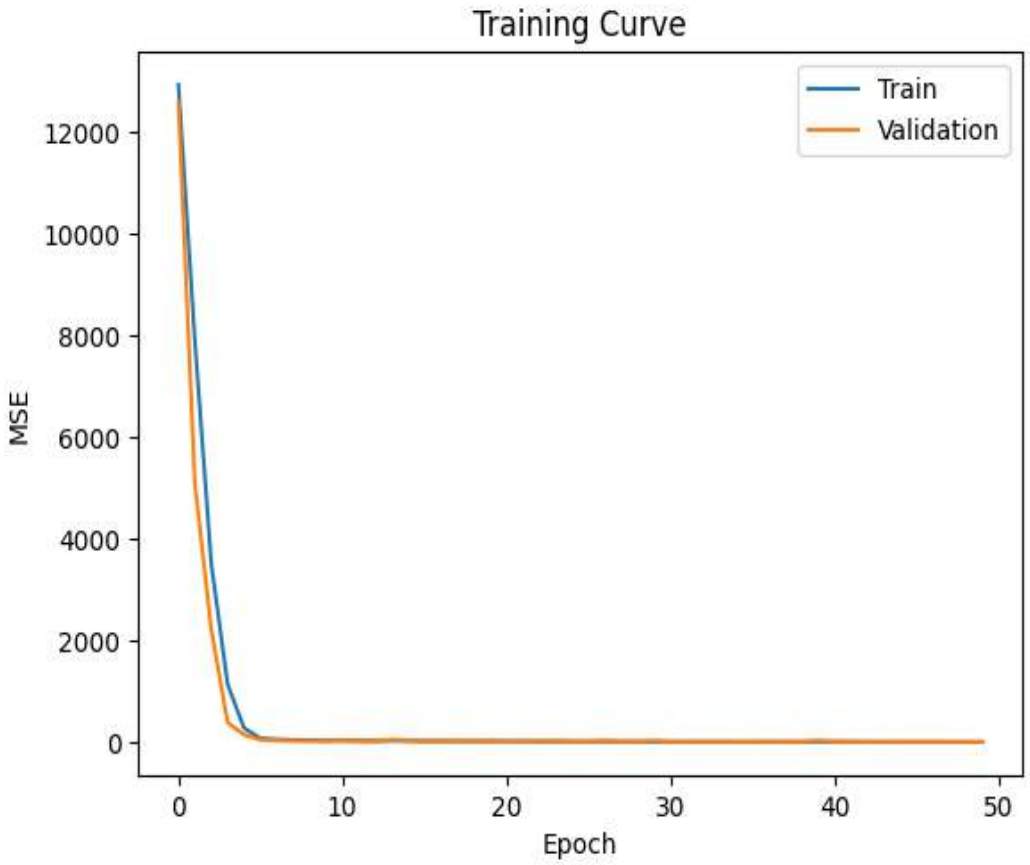
Por fim, os resultados foram analisados considerando diferentes amostras individuais, evidenciando que o modelo apresenta boa precisão na maioria dos casos, com erros reduzidos e consistentes entre diferentes faixas de peso.

3. RESULTADOS E DISCUSSÃO

Os resultados obtidos evidenciam a eficácia do modelo baseado em redes neurais convolucionais na estimativa do peso de suínos a partir de imagens RGB. Durante o processo de treinamento, observou-se uma redução significativa da função de perda, partindo de valores elevados nas primeiras épocas (acima de 12.000) até atingir níveis inferiores a 10 ao final do treinamento.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Figura 2. Curva de aprendizado do modelo ao longo das épocas, apresentando a evolução do erro quadrático médio (MSE) para os conjuntos de treinamento e validação



Fonte: Autoria própria (2026).

A Figura 2 apresenta a curva de aprendizado do modelo ao longo das épocas. Observa-se uma redução acentuada do erro nas primeiras iterações, seguida por uma estabilização progressiva, indicando convergência adequada do modelo.

A proximidade entre as curvas de treinamento e validação sugere boa capacidade de generalização, sem evidências significativas de sobreajuste. Esse comportamento é característico de modelos bem ajustados, que conseguem aprender padrões relevantes sem memorizar excessivamente os dados de treinamento.

Ao final das 50 épocas, o modelo atingiu um erro absoluto médio (MAE) aproximado de 6,51 kg no conjunto de validação, evidenciando desempenho consistente mesmo diante da variabilidade presente no dataset. Esses resultados reforçam a eficácia da abordagem proposta para a estimativa de peso de suínos a partir de imagens RGB.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Além do MAE, foi realizada uma análise estatística da distribuição dos erros absolutos. Observou-se que a maior parte das predições apresentou erro inferior a 2,00 kg (mediana), indicando boa estabilidade do modelo. O desvio padrão dos erros foi de 0,85 kg, demonstrando baixa variabilidade entre as predições. Considerando as amostras apresentadas na Tabela 1, o coeficiente de determinação (R^2) obtido foi de 0,9973, evidenciando elevada correlação entre os pesos reais e estimados. A Raiz do Erro Quadrático Médio (RMSE) foi de 1,90 kg.

A utilização de divisão estratificada por faixas de peso contribuiu para uma avaliação mais robusta do modelo, reduzindo possíveis vieses decorrentes da divisão dos dados. Além disso, a distribuição das imagens em diferentes faixas de peso possibilitou ao modelo aprender padrões relevantes associados a diferentes estágios de desenvolvimento dos animais.

A análise de predições individuais demonstrou que, em diversos casos, o erro absoluto foi inferior a 3 kg, evidenciando elevada precisão em condições favoráveis. Entretanto, também foram observadas variações maiores em algumas amostras específicas, o que pode estar relacionado a fatores como variação de iluminação, oclusão, posicionamento do animal e qualidade da imagem.

Comparativamente à literatura, abordagens que utilizam imagens RGB associadas a redes convolucionais apresentam desempenho competitivo, especialmente quando comparadas a métodos que demandam sensores adicionais, como câmeras 3D ou sistemas de pesagem automatizados. Nesse contexto, o presente estudo demonstra que é possível obter estimativas confiáveis de peso utilizando apenas imagens convencionais, reduzindo custos e aumentando a viabilidade de aplicação em ambientes reais. O desempenho obtido pode ser atribuído à capacidade das redes convolucionais de aprender características discriminantes diretamente das imagens, aliada ao uso de *transfer learning*, que favoreceu a convergência do treinamento mesmo com um conjunto de dados limitado. As maiores diferenças entre valores reais e estimados concentraram-se em imagens com variação de iluminação, oclusão parcial ou posicionamento desfavorável do animal, fatores que dificultam a extração de características pela rede. Ainda assim, os resultados reforçam que o uso exclusivo de imagens RGB constitui uma alternativa promissora para monitoramento automatizado em granjas comerciais, com menor custo de implantação frente a soluções baseadas em sensores tridimensionais ou sistemas de pesagem automatizados.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Figura 3. Exemplo de predição de peso em imagem de suíno, na qual o modelo estima o valor diretamente a partir da entrada visual



Fonte: dataset PigRGB-Weight (2024) Peso Predito.

A Figura 3 ilustra um exemplo de aplicação do modelo em uma imagem real, evidenciando sua capacidade de estimar o peso diretamente a partir de dados visuais. Nota-se que o modelo consegue identificar padrões relevantes mesmo em condições reais de ambiente, como variações de iluminação e posicionamento do animal.

Tabela 1. Comparação entre os valores reais e preditos pelos modelos treinados com 30 e 50 épocas

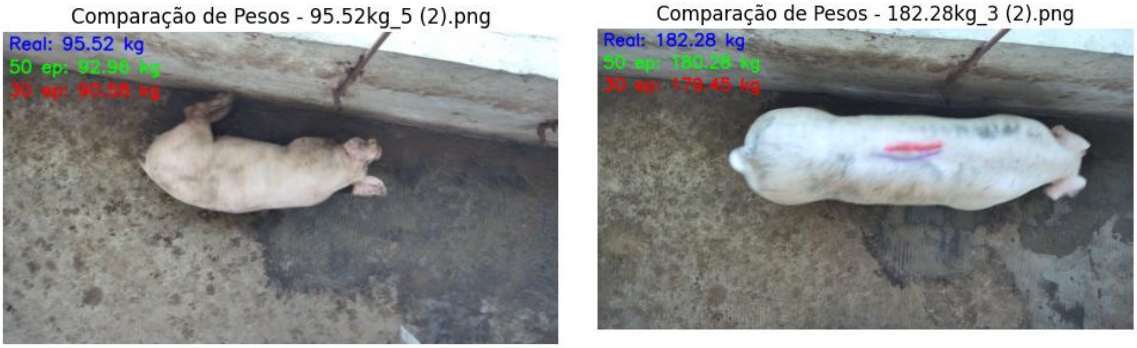
Imagem	***Peso Real (kg)***	***Modelo 50 ep (kg)***	***Modelo 30 ep (kg)***	***Dif. 50ep-Real***	***Dif. 30ep-Real***
95.52kg_5 (2).png	95.52	92.96	90.58	2.56	4.94
182.28kg_3 (2).png	182.28	180.28	179.45	2.00	2.83
167.8kg_3 (2).png	167.80	165.64	169.90	2.16	2.10
137.56kg_3 (2).png	137.56	135.27	139.08	2.29	1.52
146.3kg_1 (2).png	146.30	145.75	146.98	0.55	0.68
101.74kg_11 (2).png	101.74	99.24	100.62	2.50	1.12

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

178.54kg_1 (3).png	178.54	177.04	181.12	1.50	2.58
112.7kg_8 (4).png	112.70	112.59	110.07	0.11	2.63
73.36kg_4 (2).png	73.36	74.06	67.70	0.70	5.66
97.7kg_1 (3).png	97.70	100.45	99.99	2.75	2.29
87.3kg_2 (5).png	87.30	85.70	80.28	1.60	7.02

A Tabela 1 apresenta a comparação detalhada entre os valores reais e os valores preditos pelos modelos para um subconjunto representativo das amostras avaliadas. Ressalta-se que as estatísticas complementares apresentadas anteriormente (RMSE, R^2, mediana e desvio padrão) foram calculadas sobre esse subconjunto, enquanto o MAE de 6,51 kg refere-se ao conjunto de validação completo. Observa-se que o modelo treinado por 50 épocas apresenta desempenho superior na maioria dos casos, com menores diferenças absolutas em relação aos valores reais.

Figura 4. Exemplo de predição de peso em imagem de suíno, na qual o modelo estima o valor diretamente a partir da entrada visual com 30 e 50 épocas



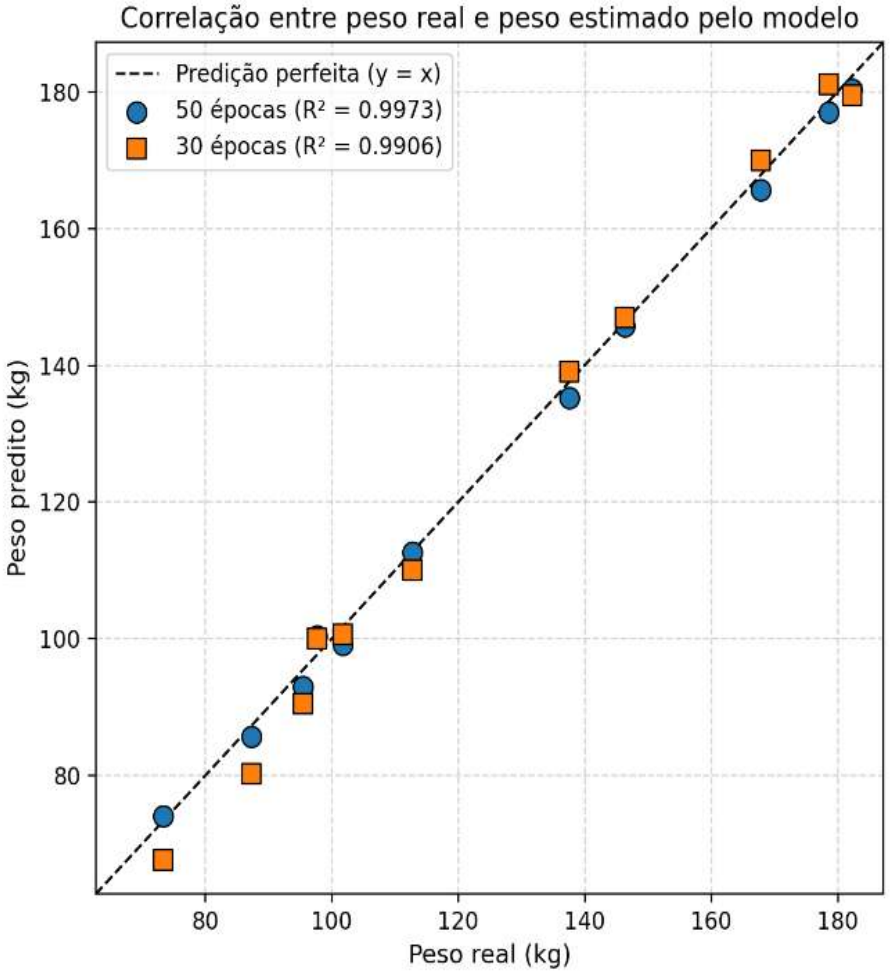
Fonte: Adaptado de Ji *et al.* (2025). Peso predito pelo modelo proposto.

A Figura 4 apresenta exemplos de predição de peso em imagens de suínos, comparando os resultados obtidos pelos modelos treinados com 30 e 50 épocas. Observa-se que, em ambos os casos, o modelo treinado por 50 épocas apresenta estimativas mais próximas dos valores reais, evidenciando melhor desempenho e maior capacidade de ajuste aos dados. No primeiro exemplo, a diferença entre o valor real e a predição é reduzida em relação ao modelo com 30 épocas, indicando maior precisão. Comportamento semelhante é observado no segundo exemplo, no qual o erro absoluto também é menor no modelo mais treinado. Esses resultados reforçam a importância de um treinamento mais prolongado para a convergência do modelo e

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

melhoria na qualidade das predições, além de demonstrar a capacidade da rede em capturar padrões visuais relevantes diretamente das imagens, mesmo diante de variações no ambiente.

Figura 5. Dispersão Peso Real × Peso Predito

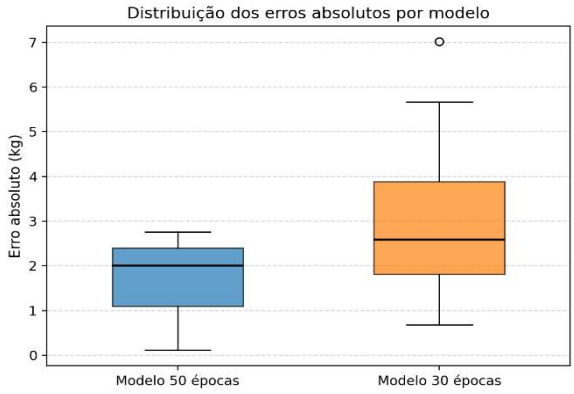


Fonte: Autoria própria (2026).

A Figura 5 apresenta a dispersão entre os valores reais e estimados pelo modelo. A proximidade dos pontos em relação à linha da identidade evidencia elevada correlação entre as predições e os valores observados, confirmando o coeficiente de determinação $R^2 = 0,9973$ obtido pelo modelo treinado com 50 épocas. Observa-se ainda que o modelo com 30 épocas apresenta maior dispersão em pesos extremos (abaixo de 90 kg e acima de 170 kg), indicando que o treinamento mais longo contribuiu para o refinamento das predições nas faixas menos representadas.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Figura 6. Distribuição dos erros absolutos (kg) obtidos pelos modelos treinados com 30 e 50 épocas



Fonte: Autoria própria (2026).

A Figura 6 apresenta o boxplot dos erros absolutos para os dois modelos avaliados. O modelo treinado por 50 épocas apresenta uma distribuição mais concentrada, com mediana de 2,00 kg e amplitude interquartil reduzida, enquanto o modelo com 30 épocas exibe maior variabilidade e a presença de um outlier em 7,02 kg. Esse comportamento reforça a hipótese de que o treinamento mais prolongado favorece a convergência e a robustez do modelo frente à variabilidade visual das amostras.

Além disso, verifica-se que os erros tendem a aumentar em determinadas faixas de peso ou em condições específicas das imagens, o que sugere influência de fatores visuais na capacidade preditiva do modelo. Ainda assim, os resultados demonstram consistência e boa precisão geral.

Por fim, destaca-se que o modelo apresentou boa capacidade de generalização, sendo capaz de manter desempenho consistente ao longo das diferentes partições do dataset. Esses resultados reforçam o potencial do uso de técnicas de aprendizado profundo na área de zootecnia de precisão, contribuindo para soluções automatizadas no monitoramento e manejo de animais.

4. CONSIDERAÇÕES FINAIS

Os resultados obtidos neste estudo demonstram que o uso de redes neurais convolucionais aplicadas a imagens RGB constitui uma abordagem viável e eficiente para a estimativa de peso de suínos. O modelo desenvolvido foi capaz de aprender padrões relevantes diretamente das imagens, alcançando desempenho consistente, com erro absoluto médio de

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

aproximadamente 6,51 kg no conjunto de validação. A adoção de uma arquitetura baseada em ResNet18, aliada à técnica de transfer learning, mostrou-se adequada para o problema proposto, permitindo reduzir a complexidade do desenvolvimento e acelerar o processo de treinamento. Além disso, a utilização exclusiva de imagens RGB representa uma vantagem significativa em termos de custo e aplicabilidade prática, uma vez que dispensa o uso de sensores adicionais.

Outro ponto relevante refere-se à utilização de divisão estratificada dos dados, que contribuiu para uma avaliação mais robusta do modelo, evidenciando sua capacidade de generalização em diferentes subconjuntos de dados. Os resultados indicam que, mesmo diante de variações nas condições das imagens, o modelo mantém um desempenho satisfatório.

Como limitações, destaca-se a dependência de um volume considerável de dados para treinamento e a sensibilidade a variações visuais, como iluminação, oclusão e posicionamento dos animais. Nesse sentido, trabalhos futuros podem explorar o uso de técnicas mais avançadas de aumento de dados, arquiteturas mais robustas e a integração com outras fontes de informação, como dados de profundidade ou sensores adicionais.

Por fim, conclui-se que a abordagem proposta apresenta grande potencial para aplicação em sistemas de monitoramento automatizado na suinocultura, contribuindo para o avanço da agricultura de precisão e para o desenvolvimento de soluções tecnológicas acessíveis ao setor produtivo.

REFERÊNCIAS

CHEN, Yan et al. A Novel Approach of Pig Weight Estimation Using High-Precision Segmentation and 2D Image Feature Extraction. **Animals**, v. 15, n. 20, p. 2975, 2025. Disponível em: https://doi.org/10.3390/ani15202975. Acesso em: 13 fev. 2026.

JI, Xintong et al. A Machine Learning-Based Method for Pig Weight Estimation and the PIGRGB-Weight Dataset. **Agriculture**, v. 15, n. 8, p. 814, 2025. Disponível em: https://www.mdpi.com/2077-0472/15/8/814. Acesso em: 13 fev. 2026.

JIANG, Sheng et al. Pig weight estimation method based on a framework combining mask R-CNN and ensemble regression model. **Animals**, v. 14, n. 14, p. 2122, 2024. Disponível em: https://doi.org/10.3390/ani14142122. Acesso em: 13 fev. 2026.

MA, Weihong et al. Pig weight estimation using a movable top-mounted depth camera with improved EfficientNetV2. **Smart Agricultural Technology**, p. 101198, 2025. Disponível em: https://doi.org/10.1016/j.atech.2025.101198. Acesso em: 13 fev. 2026.

HE, Kaiming et al. Deep Residual Learning for Image Recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, 2016. p. 770–778. Disponível em: https://doi.org/10.1109/CVPR.2016.90. Acesso em: 13 fev. 2026.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.