



Visão Computacional Embarcada para Contagem Automática de Suínos no Processo de Carregamento Utilizando Câmera RGB e Inteligência Artificial

Maureu Jefferson Benvenho¹, Alberto Yoshihiro Nakano¹, Felipe Walter Dafico Pfrimer¹

¹UTFPR - Universidade Tecnológica Federal do Paraná, Toledo-PR, Brasil (maureu@alunos.utfpr.edu.br)

Resumo: Este trabalho apresenta o desenvolvimento e a validação de um sistema de contagem automática de suínos baseado em visão computacional e IA (inteligência artificial) embarcada, operando de forma *offline* e em tempo real. O objetivo é reduzir a necessidade de mão de obra, aumentar a precisão dos registros e aprimorar a rastreabilidade no processo de carregamento dos animais na granja. O sistema foi instalado na rampa de carregamento de uma granja localizada no oeste de Santa Catarina, registrando o fluxo de suínos destinados ao frigorífico. O banco de dados utilizado foi construído ao longo de diferentes épocas do ano de produção, contemplando variações de iluminação, posicionamento e condições operacionais. Os resultados demonstram desempenho consistente, com *F1-score* elevado e baixa incidência de falsos positivos e negativos. A discussão aborda limitações, como sobreposição de animais e dependência do posicionamento da câmera, além de propor melhorias futuras, incluindo aumento da diversidade do banco de dados e uso de sensores complementares. Conclui-se que a solução é viável, escalável e capaz de contribuir para a padronização e segurança do processo de carregamento.

Palavras-chave: Visão computacional; inteligência artificial; contagem automática; suínos; rastreabilidade.

INTRODUÇÃO

Uma das principais proteínas animais, tanto em relação ao custo para a população quanto à disponibilidade, é a carne suína ((BNDES), 2024), que apresenta alta digestibilidade e baixo teor de gordura saturada. A suinocultura moderna, graças as melhorias genéticas, possui altas taxas de conversão alimentar, ciclo curto de produção, produtividade elevada e exige pouco espaço para a sua produção, se comparada, por exemplo, a criação bovina.

A suinocultura moderna exige precisão, rastreabilidade e eficiência em todas as etapas da cadeia produtiva. Após o período de engorda, os suínos são carregados na granja e transportados ao frigorífico, momento em que ocorre a transferência de responsabilidade entre produtor, transporte e indústria. Tradicionalmente, a contagem dos animais é realizada manualmente, processo sujeito a erros, falhas humanas e inconsistências nos registros.

Além dos benefícios operacionais, a solução com contagem automática também apresenta relevância econômica, uma vez que divergências entre a quantidade ou o peso de suínos declarados e os efetivamente entregues podem acarretar penalidades aplicadas pelo SIF (Sistema de Inspeção Federal do Ministério da Agricultura, Pecuária e Abastecimento) (PECUÁRIA, 2024). Essa penalidade, tecnicamente associada à di-

vergência de peso ou quantidade, está ligada ao controle oficial de produtos de origem animal, que exige que os registros documentais, como nota fiscal, GTA (Guia de Trânsito Animal) e romaneio, correspondam exatamente ao que sai da granja ou do frigorífico. Em operações de grande volume, erros manuais na contagem ou no registro podem gerar custos financeiros significativos e comprometer a conformidade regulatória.

Com o avanço da visão computacional (LUO et al., 2025) e da IA embarcada (TIAN et al., 2019), torna-se possível automatizar esse processo, reduzindo falhas humanas e aumentando a confiabilidade dos dados coletados. Nesse contexto, o presente trabalho teve como objetivo desenvolver e validar um sistema automático de contagem de suínos utilizando uma câmera RGB (*Red, Green, Blue* — modelo aditivo de representação de cores em que cada pixel é descrito pelas intensidades das componentes vermelho, verde e azul) e IA. A IA refere-se a métodos computacionais capazes de aprender padrões a partir de dados e tomar decisões de forma autônoma, permitindo que o sistema opere *offline* e em tempo real, sem necessidade de infraestrutura adicional ou modificações estruturais na granja.

Especificamente, buscou-se reduzir mão de obra e tempo no carregamento dos animais, emitir registros precisos sobre quantidade e integridade visual, garan-



tir autonomia operacional por meio de processamento *offline*, facilitar auditoria visual e padronização do processo e integrar o sistema ao fluxo da granja sem necessidade de treinamento adicional ou mudanças de rotina ou cultura por parte dos trabalhadores envolvidos, uma vez que nesses ambientes a resistência à mudança é um fator crítico e pode por em risco a adoção de novas tecnologias.

MATERIAL E MÉTODOS

O protótipo do sistema foi desenvolvido empregando câmera RGB de alta resolução, unidade de processamento com IA embarcada (*edge computing* – computação de borda), *software* de visão computacional desenvolvido em *Python* e banco de dados armazenado em ambiente colaborativo, onde o operador pode interagir com conexão direta via aparelho celular.

O sistema foi instalado na rampa de carregamento de uma granja situada no oeste de Santa Catarina. A câmera RGB foi posicionada de forma elevada e ortogonal ao fluxo dos animais, garantindo que todos os suínos fossem capturados antes de entrarem no caminho, sem necessidade de modificação estrutural.

O banco de dados foi composto por imagens e vídeos coletados em diferentes épocas do ano de produção, contemplando variações de iluminação natural e artificial, diferentes posicionamentos e densidades de fluxo dos animais, ocorrência de sobreposição e obstruções e configurações distintas de câmera e ambiente. Essa diversidade foi essencial para garantir robustez ao modelo.

O processamento das imagens seguiu uma sequência estruturada de etapas, abrangendo desde o pré-processamento até a seleção do modelo final. O pré-processamento incluiu normalização, recorte, correção de cor e padronização de resolução de imagens, garantindo consistência entre diferentes condições de captura.

Para o treinamento do modelo de detecção, foram avaliadas arquiteturas amplamente utilizadas em visão computacional, como *YOLO* (REDMON; FARHADI, 2018), *SSD* (LIU et al., 2016) e *Faster R-CNN* (REN et al., 2015). O *YOLO* (*You Only Look Once* — “Você só olha uma vez”) é uma família de redes neurais para detecção de objetos que realiza localização e classificação em uma única passagem pela imagem, o que o torna especialmente adequado para aplicações com necessidade de resposta rápida e processamento eficiente. Essa abordagem está alinhada a diretrizes da Embrapa Suínos e Aves para aplicações de IA embarcada em pesquisa animal (Embrapa Suínos e Aves, 2025). Inicialmente, diferentes variantes das famílias *YOLO* foram testadas, incluindo *YOLOv5s*, *YOLOv5m* e *YOLOv8n*. Após testes preliminares, a versão *YOLOv11n* apresentou o melhor desempenho em termos de pre-

cisão, mesmo não sendo a mais rápida. Vale salientar que os números de versão nem sempre correspondem a simples melhorias e correções como acontece em *softwares* normalmente, mas no caso do *YOLO*, podem ocorrer mudanças nos métodos que não necessariamente sejam melhores na aplicação prática, dependendo da aplicação em si. Outra coisa é o caráter final na descrição do modelo, que no caso de *n* (*nano* – minúsculo), *s* (*small* – pequeno), *m* (*medium* – médio), *l* (*large* – grande) e *x* (*extra large* – extra grande), seguem a seguinte lógica: quanto menor mais rápido e melhor se adequam a equipamentos limitados em termos de processamento, como é o caso em estudo neste trabalho, e o contrário acontece com os modelos maiores que precisam de equipamentos mais robustos, embora geralmente sejam mais precisos. Ficando portanto, a escolha da *YOLOv11n* pela junção de 2 fatores, boa precisão e tamanho de modelo melhor implementável em nosso caso. Essa escolha segue exemplos de uso de detecção automática em produção animal, como o monitoramento de bovinos da Embrapa Agricultura Digital com *YOLO* e *SAM* (Embrapa Agricultura Digital, 2026). A velocidade não foi considerada crítica, pois o fluxo de suínos na rampa é relativamente lento se comparado à velocidade de captura e processamento do equipamento embarcado utilizado.

O modelo foi treinado com aproximadamente **2.300 imagens**, utilizando 1.840 imagens (**80%**) para treino e 460 imagens (**20%**) para validação. Técnicas de *data augmentation* (aumento de dados – técnicas utilizadas para aumentar artificialmente o número de amostras) foram aplicadas para aumentar a diversidade. Inicialmente foram realizadas 100 épocas de treinamento, mas os melhores resultados foram obtidos com **300 épocas**, garantindo maior estabilidade das métricas. Épocas, neste contexto, referem-se a ciclos completos de treinamento em que o modelo é exposto a todo o conjunto de dados de treino uma vez.

O desempenho foi avaliado utilizando *precision* (precisão), *recall* (revocação ou sensibilidade) e *F1-score* (pontuação F1). Após a validação, o modelo foi implementado em uma unidade de processamento embarcada, operando *offline* e *real time* (tempo real). Durante a validação visual, foram examinadas imagens de rótulos e predições do modelo para assegurar que as detecções correspondiam às anotações do conjunto de treinamento, chamadas de rótulos, que são utilizadas como referência para “treinar” a IA, exemplificadas na Figura 1. Posteriormente, esse treino é avaliado para testar sua eficácia utilizando outras imagens, como ilustrado na Figura 2, o que garante que o modelo aprendeu a identificar corretamente os suínos em diferentes condições de iluminação, ângulos e densidades de fluxo.



Figura 1: Exemplos de rótulos do YOLO.



Figura 2: Exemplos de validação do treino YOLO.

Métricas

As métricas utilizadas avaliam diferentes aspectos do desempenho do modelo de detecção. A *precision* indica a proporção de detecções corretas entre todas as predições positivas realizadas pelo modelo, refletindo sua capacidade de evitar falsos positivos. A *recall* mede a proporção de objetos corretamente detectados entre todos os objetos presentes na imagem, evidenciando a capacidade do modelo de evitar falsos negativos.

O *F1-score* combina *precision* e *recall* por meio da média harmônica, fornecendo uma medida equilibrada entre ambas, especialmente útil quando há assimetria entre falsos positivos e negativos, e é definido por

$$F1 - score = \frac{2 \times (precision \times recall)}{precision + recall}. \quad (1)$$


As curvas de *precision*, *recall* e *F1-score* permitem analisar o comportamento do modelo em diferentes limiares de confiança, enquanto a matriz de confusão evidencia a distribuição dos acertos e erros, des-

tacando padrões de desempenho e possíveis fontes de falhas.

RESULTADOS E DISCUSSÃO

A curva *precision versus recall* (curva de precisão versus revocação) apresentada na Figura 3 ilustra a relação entre a *precision* (eixo *y*), que indica a ocorrência de falsos positivos, e o *recall* (eixo *x*), que representa a capacidade do modelo de identificar corretamente os objetos reais sob diferentes limiares de confiança. Essa curva permite avaliar o equilíbrio entre falsos positivos e falsos negativos ao longo da variação do limiar. A proximidade da curva ao canto superior direito evidencia um desempenho elevado do modelo, caracterizado por alta capacidade de detecção e baixa incidência de erros. A curva *precision versus confidence* (curva de precisão em função do limiar de confiança) apresentada na Figura 4 mostra a variação da *precision* em relação ao limiar de confiança aplicado às predições do modelo. A curva indica que, mesmo com limiares mais altos, a *precision* permanece elevada, sugerindo que o modelo mantém uma baixa taxa de falsos positivos, mesmo quando se exige maior certeza nas detecções. Os resultados demonstram desempenho consistente do modelo, com *F1-score* elevado, próximo de 1, baixa taxa de falsos positivos e falsos negativos, mas ligeiramente pendendo para a ocorrência de falsos negativos, evidenciando estabilidade em diferentes condições de iluminação e capacidade de operação em tempo real, conforme pode ser observado na Figura 5.

A matriz de confusão que é apresentada na Figura 6, permite visualizar o desempenho do modelo, indicando os acertos e erros (falsos positivos e falsos negativos), sendo uma análise essencial para avaliar o desempenho do modelo.

Figura 3: Curva *precision versus recall* (PR).




Figura 4: Curva *precision versus confidence*.Figura 5: Curva *F1-score versus confidence*.

Figura 6: Matriz de confusão.




Figura 7: Exemplo de detecção de caixas delimitadoras (cor verde) e contagem no canto superior esquerdo.



Figura 8: Instalação do equipamento na rampa de carregamento.

Resumo do Treinamento

Época	Precision	Recall	mAP50	mAP50-95
1	0,0276	0,0217	0,0023	0,0009
10	0,9674	0,9390	0,9805	0,8461
29	0,9838	0,9551	0,9879	0,8964
75	0,9911	0,9784	0,9931	0,9212
150	0,9856	0,9764	0,9924	0,9322
200	0,9802	0,9748	0,9926	0,9328

Tabela 1: Evolução das principais métricas ao longo do treinamento.

Os resultados do treinamento, conforme demonstrados na Tabela 1, indicam que o modelo apresentou convergência rápida e estável. Nas primeiras épocas, as métricas de *precision*, *recall* e mAP (*mean Average Precision* – precisão média da média) são muito baixas,



como observado na época 1 ($precision = 0,0276$; $recall = 0,0217$), refletindo o estágio inicial de aprendizado. Entretanto, já por volta da época 10, o modelo atinge valores elevados e consistentes ($precision$ de 0,9674 e $recall$ de 0,9390), demonstrando que a rede aprendeu rapidamente os padrões do conjunto de dados.

Ao longo do treinamento, as métricas permanecem altas e estáveis, com $precision$ frequentemente acima de 0,98 e $recall$ acima de 0,97, como observado nas épocas 29 e 75. O desempenho em termos de mAP50, que é a média de precisão usando IoU (*Intersection over Union* – Interseção sobre União) 0,5 que é considerado onde o modelo consegue detectar objetos de forma “razoável” e mAP50–95, ou seja, IoU entre 0,9 e 0,95 (que é considerado onde o modelo possui uma boa capacidade de detecção do objeto), também é elevado, atingindo valores próximos de 0,99 e acima de 0,90, respectivamente, o que indica excelente capacidade de localização e classificação dos objetos.

As perdas de treino e validação diminuem de forma suave e progressiva, sem oscilações abruptas, sugerindo um processo de otimização estável e sem indícios relevantes de sobreajuste. A proximidade entre as perdas de treino e validação reforça que o modelo generaliza bem para dados novos, ou seja, não empregados no processo de treinamento, o que é crucial para aplicações práticas em ambientes variáveis.

Por fim, observa-se que o modelo atinge um platô de desempenho entre as épocas 70 e 100, mantendo métricas elevadas até o final do treinamento (época 200). Isso indica que o modelo está adequadamente ajustado e que treinos adicionais tenderiam a trazer ganhos marginais.

Os resultados indicam que o sistema é eficiente para contagem automática de suínos, apresentando alta confiabilidade mesmo em condições variáveis de iluminação e fluxo. A imagem da Figura 7 mostra a detecção dos suínos propriamente dita, enquanto a figura 8 ilustra a instalação do equipamento na rampa de carregamento, reforçando a aplicabilidade prática do método.

Entretanto, algumas limitações foram observadas, como sensibilidade à sobreposição de animais, que pode levar a contagens incorretas, e a dependência do posicionamento da câmera, que requer ajustes cuidadosos para garantir cobertura adequada. Além disso, a necessidade de ampliar a diversidade do banco de dados foi identificada como um ponto crítico para melhorar a robustez do modelo. Essas limitações podem ser mitigadas com técnicas de *data augmentation* e expansão do banco de dados para diferentes granjas e épocas do ano, garantindo maior representatividade das condições reais de operação.

CONCLUSÃO

O sistema desenvolvido demonstrou ser uma solução viável, eficiente e aplicável ao contexto real da suinocultura. O uso de IA permitiu contagem precisa, operação em tempo real e maior segurança na transferência de responsabilidade entre granja e transporte. A possibilidade de auditoria visual e padronização do processo contribui para a rastreabilidade e conformidade regulatória, atendendo às exigências do SIF, além de trazer segurança a todos os participantes do processo. Melhorias futuras incluirão a ampliação do banco de dados, a inclusão de sensores complementares, o desenvolvimento de interface para integração com sistemas de gestão e a avaliação de modelos mais leves para dispositivos embarcados, visando maior eficiência e escalabilidade da solução.

AGRADECIMENTOS

Os autores agradecem à equipe da granja onde o sistema foi avaliado e aos profissionais envolvidos na coleta de dados, incluindo veterinários e transportadores, pela colaboração durante as etapas experimentais deste trabalho acadêmico.

REFERÊNCIAS

(BNDES), B. N. de Desenvolvimento Econômico e S. Suinocultura: *Estrutura da Cadeia Produtiva e Panorama do Setor no Brasil*. 2024. Acesso em: 15 jul. 2026. Disponível em: <https://web.bndes.gov.br/bib/jspui/bitstream/1408/11794/1/BS\%2045\%20Suinocultura\%20\%20estrutura\%20da\%20cadeia\%20produtiva\%2c\%20panorama\%20do\%20setor\%20no\%20Brasil\%5b..\%5d_P.pdf>.

Embrapa Agricultura Digital. *Deep learning-based UAV framework for automated morphological and growth analysis of feedlot cattle*. [S.l.], 2026. Estudo sobre detecção automática e monitoramento de bovinos com YOLO e SAM.

Embrapa Suínos e Aves. *O Marco da Inteligência Artificial (IA) na pesquisa animal da Embrapa Suínos e Aves*. [S.l.], 2025. Documento de referência sobre visão computacional e aprendizado de máquina aplicada à pesquisa animal.

LIU, W. et al. Ssd: Single shot multibox detector. In: *European Conference on Computer Vision*. [S.l.]: Springer, 2016. p. 21–37.

LUO, Y. et al. A lightweight model for automatic pig counting in intensive piggeries using a



green inspection robot and image segmentation method. *Smart Agricultural Technology*, v. 12, p. 101115, 2025. ISSN 2772-3755. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S277237552500348X>>.

PECUÁRIA, M. da Agricultura e. *Serviço de Inspeção Federal (SIF)*. 2024. Acesso em: 15 jul. 2026. Disponível em: <<https://www.gov.br/agricultura/pt-br/assuntos/inspecao/produtos-animal/sif>>.

REDMON, J.; FARHADI, A. YOLOv3: An incremental improvement. *arXiv preprint arXiv:1804.02767*, 2018.

Disponível em: <<https://arxiv.org/abs/1804.02767>>.

REN, S. et al. Faster r-cnn: Towards real-time object detection with region proposal networks. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2015. p. 91–99.

TIAN, M. et al. Automated pig counting using deep learning. *Computers and Electronics in Agriculture*, v. 163, p. 104840, 2019. ISSN 0168-1699. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168169918313176>>.