

DETECÇÃO AUTOMÁTICA DE REBANHOS BOVINOS EM CAMPO ABERTO UTILIZANDO ARQUITETURA YOLO V8 E IMPLEMENTAÇÃO DO SOFTWARE CATTLEVISION

**AUTOMATIC DETECTION OF CATTLE HERDS IN OPEN FIELD USING YOLO
V8 ARCHITECTURE AND IMPLEMENTATION OF CATTLEVISION SOFTWARE**

**DETECCIÓN AUTOMÁTICA DE REBAÑOS BOVINOS EN CAMPO ABIERTO
UTILIZANDO ARQUITECTURA YOLO V8 E IMPLEMENTACIÓN DEL
SOFTWARE CATTLEVISION**

Daniel Xavier Vieira¹, Adriano Soares de Oliveira Bailão², Gustavo Moura Barros³, Luiz Antonio Anacleto Brasileiro⁴

DOI: 10.54899/dcs.v23i94.6799

Recibido: 20/07/2026 | **Aceptado:** 17/08/2026 | **Publicación en línea:** 26/08/2026.

RESUMO

O monitoramento autônomo de rebanhos bovinos representa um desafio na Pecuária de Precisão, especialmente devido às variações de iluminação, oclusões dinâmicas e similaridade morfológica entre as categorias animais. Este estudo propõe a implementação de um sistema de visão computacional baseado na arquitetura YOLOv8s para a detecção e classificação biométrica simultânea de touros, vacas e bezerros em condições de campo aberto. O modelo foi treinado com um conjunto de dados anotado e particionado, submetido a técnicas de aumento de dados para mitigar vieses de fundo. Os resultados indicaram eficácia discriminativa, alcançando Precisão global de 86,52%, Revocação de 81,67%, F1-Score de 84,02% e mAP@50 de 85,52%. A análise da matriz de confusão apontou desafios residuais na classificação de bezerros devido à entropia visual do pasto, enquanto as curvas de otimização confirmaram a convergência do modelo. Conclui-se que a arquitetura oferece robustez analítica para telemetria populacional, viabilizando intervenções zootécnicas e a futura integração com tecnologias de Edge Computing e Internet das Coisas (IoT). Complementarmente, o modelo treinado foi operacionalizado por meio de uma aplicação web denominada CattleVision, construída com o microframework Flask, que disponibiliza um módulo de classificação de imagens e de exportação de laudos em PDF, aproximando a solução do uso prático em ambientes de produção.

¹ Mestrando em Ciências Agrárias - Tecnologias Sustentáveis em Sistemas de Produção e Uso do Solo e Água, Instituto Federal de Educação, Ciência e Tecnologia Goiano, Rio Verde, Goiás, Brasil.

E-mail: daniel.xavier1@estudante.ifgoiano.edu.br Orcid: <https://orcid.org/0009-0003-5454-672X>

² Doutor em Ciência da Computação, Instituto Federal de Educação, Ciência e Tecnologia Goiano, Rio Verde, Goiás, Brasil. E-mail: bailao.adriano@ifgoiano.edu.br Orcid: <https://orcid.org/0009-0008-0122-9639>

³ Mestrando em Ciências Agrárias - Tecnologias Sustentáveis em Sistemas de Produção e Uso do Solo e Água, Instituto Federal de Educação, Ciência e Tecnologia Goiano, Rio Verde, Goiás, Brasil.

E-mail: gustavo.barros@estudante.ifgoiano.edu.br Orcid: <https://orcid.org/0009-0008-6383-4834>

⁴ Mestrando em Ciências Agrárias - Tecnologias Sustentáveis em Sistemas de Produção e Uso do Solo e Água, Instituto Federal de Educação, Ciência e Tecnologia Goiano, Rio Verde, Goiás, Brasil.

E-mail: luis.brasileiro@estudante.ifgoiano.edu.br Orcid: <https://orcid.org/0009-0006-7447-4286>

Palavras-chave: Pecuária de Precisão. YOLOv8. Visão Computacional. Biometria Bovina. Redes Neurais Convolucionais.

ABSTRACT

Autonomous monitoring of cattle herds represents a challenge in Precision Livestock Farming, especially due to lighting variations, dynamic occlusions, and morphological similarity between animal categories. This study proposes the implementation of a computer vision system based on the YOLOv8s architecture for simultaneous detection and biometric classification of bulls, cows, and calves in open-field conditions. The model was trained with an annotated and partitioned dataset and subjected to data augmentation techniques to mitigate background biases. The results indicated discriminative efficacy, achieving a global Precision of 86.52%, Recall of 81.67%, F1-Score of 84.02%, and mAP@50 of 85.52%. The confusion matrix analysis pointed to residual challenges in calf classification due to the visual entropy of the pasture, while optimization curves confirmed model convergence. It is concluded that the architecture offers analytical robustness for population telemetry, enabling zootechnical interventions and future integration with Edge Computing and Internet of Things (IoT) technologies. Additionally, the trained model was operationalized through a web application named CattleVision, built with the Flask microframework, which provides an image classification module and a PDF report export feature, bringing the solution closer to practical use in production environments.

Keywords: Precision Livestock Farming. YOLOv8. Computer Vision. Cattle Biometrics. Convolutional Neural Networks.

RESUMEN

El monitoreo autónomo de rebaños bovinos representa un desafío en la Ganadería de Precisión, especialmente debido a las variaciones de iluminación, oclusiones dinámicas y similitud morfológica entre las categorías animales. Este estudio propone la implementación de un sistema de visión computacional basado en la arquitectura YOLOv8s para la detección y clasificación biométrica simultánea de toros, vacas y terneros en condiciones de campo abierto. El modelo fue entrenado con un conjunto de datos anotado y particionado, sometido a técnicas de aumento de datos para mitigar sesgos de fondo. Los resultados indicaron eficacia discriminativa, alcanzando una Precisión global del 86,52%, una Exhaustividad (Recall) del 81,67%, un F1-Score del 84,02% y un mAP@50 del 85,52%. El análisis de la matriz de confusión señaló desafíos residuales en la clasificación de terneros debido a la entropía visual del pasto, mientras que las curvas de optimización confirmaron la convergencia del modelo. Se concluye que la arquitectura ofrece robustez analítica para la telemetría poblacional, viabilizando intervenciones zootécnicas y la futura integración con tecnologías de Edge Computing e Internet de las Cosas (IoT). Complementariamente, el modelo entrenado fue operacionalizado mediante una aplicación web denominada CattleVision, construida con el microframework Flask, que pone a disposición un módulo de clasificación de imágenes y de exportación de informes en PDF, acercando la solución al uso práctico en entornos de producción.

Palabras clave: Precision Livestock Farming. YOLOv8. Visión por Computador. Biometría Bovina. Redes Neuronales Convolucionales.



Esta obra está bajo una [Licencia Creative Commons Atribución- NoComercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/)

INTRODUÇÃO

A pecuária de precisão emergiu como um paradigma na gestão agropecuária contemporânea, integrando tecnologias avançadas para otimizar a produção, o bem-estar animal e a sustentabilidade ambiental. Historicamente, o monitoramento dependia de sensores físicos e identificadores por radiofrequência, mas a evolução para sistemas baseados em visão computacional e Internet das Coisas (IoT) permitiu uma observação contínua, escalável e não intrusiva dos rebanhos. Conforme apontado por Neethirajan (2023), essa transição marca uma mudança de um modelo reativo para uma abordagem proativa e preditiva, onde a integração de Inteligência Artificial e dispositivos IoT permite a análise em tempo real do comportamento animal, transformando dados brutos em decisões precisas que impactam diretamente a rentabilidade e a eficiência operacional dos sistemas produtivos.

Contudo, a implementação de sistemas de visão computacional em ambientes abertos e dinâmicos esbarra em desafios operacionais significativos. Os gargalos visuais inerentes a esses cenários incluem variações drásticas de iluminação natural, condições climáticas adversas e fundos texturizados que mimetizam a pelagem dos animais. Nesse contexto, estudos recentes, como os de Teng *et al.* (2024), destacam que a complexidade do ambiente de pastagem — caracterizada pela descontinuidade visual e pela alta variabilidade de fundo — atua como um fator crítico que reduz a acurácia dos modelos de aprendizado profundo (deep learning), exigindo o desenvolvimento de algoritmos mais robustos capazes de realizar segmentação de instâncias e detecção de objetos sob condições ambientais não controladas. Além disso, as oclusões são constantes devido ao comportamento gregário dos bovinos, exigindo arquiteturas analíticas robustas para extrair características em cenários de alta entropia visual.

Além dos fatores ambientais, a categorização fenotípica exige a diferenciação biométrica precisa entre touros, vacas e bezerros. As diferenças morfológicas entre essas categorias podem ser sutis, dependendo do padrão racial, estado nutricional e ângulo de captura, o que frequentemente resulta em sobreposição de características anatômicas. Conforme discutido por Wang *et al.* (2025), a alta variabilidade intraespecífica, somada à semelhança morfológica entre diferentes estágios de desenvolvimento, impõe limites severos à generalização dos modelos de classificação, evidenciando que a extração de características puramente geométricas é, por vezes,

insuficiente sem o aporte de métricas contextuais e de escala que considerem o dimorfismo sexual e a maturidade dos espécimes. Diante dessa complexidade e da necessidade de processamento em tempo real na borda (Edge Computing), optou-se pela arquitetura YOLOv8. Sua adoção justifica-se por seu design livre de âncoras (anchor-free), que reduz problemas de alinhamento e melhora a generalização para objetos de dimensões variadas em comparação com abordagens anteriores.

TRABALHOS RELACIONADOS

O desenvolvimento metodológico do monitoramento na pecuária reflete uma transição contínua. Abordagens iniciais baseavam-se em extratores de características artesanais combinados com aprendizado de máquina tradicional, apresentando limitações em cenários dinâmicos. A ascensão das Redes Neurais Convolucionais (CNNs) introduziu modelos de dois estágios, como a Faster R-CNN, que alcançaram alta precisão, mas com latência incompatível para inferência em tempo real na borda. Modelos de estágio único, como o Single Shot MultiBox Detector (SSD) e versões anteriores do YOLO, popularizaram-se pela velocidade. No entanto, o YOLOv8 apresenta vantagens estruturais ao dispensar o uso de caixas âncora pré-definidas, adaptando-se melhor à detecção de animais de diferentes portes. Nessa linha, trabalhos recentes de Silva *et al.* (2025) demonstram que a arquitetura anchor-free do YOLOv8 permite uma convergência mais rápida e um recall superior em detecções de rebanho, superando arquiteturas anteriores na segmentação e contagem de espécimes sob condições de oclusão parcial e variabilidade de escala, características intrínsecas ao manejo pecuário intensivo.

Tabela 1: Comparativo de Trabalhos Relacionados

Autores / Ano	Metodologias Empregadas	Principais Resultados
Neethirajan (2023)	Sensores vestíveis, IoT e integração via Cloud.	Melhora significativa na detecção precoce de estresse animal e maior acurácia no monitoramento de saúde.
Teng <i>et al.</i> (2024)	CNNs de dois estágios e técnicas de segmentação semântica.	Eficácia na identificação de animais em pastagens com alta complexidade de fundo e condições variáveis.
Presente Estudo	YOLOv8s, Data Augmentation agressivo	mAP@50 de 85,52% em condições de campo aberto.

Fonte: Elaborada pelos próprios autores.

METODOLOGIA

Caracterização e Particionamento do Conjunto de Dados

As capturas visuais foram obtidas a partir de câmeras modelo Intel RealSense D435, instaladas em áreas de semiconfinamento localizadas em fazendas experimentais de pecuária de corte no centro-oeste brasileiro, durante o período de junho a agosto de 2025. As imagens, com resolução original de 1280x720 pixels, contemplam animais predominantemente da raça Nelore e cruzamentos industriais, capturados a uma distância média de 5 a 10 metros em condições climáticas de céu aberto, luminosidade diurna variável e sombra projetada. As imagens foram redimensionadas para 640x640 pixels para atender aos requisitos de entrada da arquitetura YOLOv8. O particionamento dos dados em treinamento (70%), validação (20%) e teste (10%) foi realizado de forma estratificada, garantindo que diferentes proporções de touros, vacas e bezerros estivessem representadas uniformemente, totalizando 280 imagens após a aplicação de técnicas de aumento de dados.

Infraestrutura Arquitetural e Hiperparâmetros de Ajuste

O pipeline foi desenvolvido em Python utilizando PyTorch (versão 2.3.0) e a biblioteca Ultralytics (versão 8.2.0). O treinamento foi processado em um ambiente de nuvem Google Colab, utilizando uma GPU NVIDIA Tesla T4 com 16 GB de VRAM, operando sobre um sistema operacional Linux (Ubuntu 22.04 LTS) com suporte a CUDA 12.1. A Tabela 2 descreve os hiperparâmetros configurados para o processo de otimização do modelo.

Tabela 2: Hiperparâmetros do Modelo

Hiperparâmetro	Valor Configurado
Arquitetura do Modelo	YOLOv8s (small)
Resolução de Entrada	640 x 640 pixels
Batch Size	16
Número de Épocas	200
Taxa de Aprendizado	0.01
Optimizer	SGD (Stochastic Gradient Descent)
Momentum	0.937
Weight Decay	0.0005
Data Augmentation	Mosaic, Mixup, Flip, HSV e Scale

Fonte: Elaborada pelos próprios autores.


Aumentação de Dados e Modelagem das Funções de Perda

Implementou-se um duto de aumento de dados agressivo, tendo a técnica de mosaico como base para aumentar a robustez à variabilidade de escala e posição dos animais. Foram aplicadas rotações geométricas estocásticas de até 15°, ajustes de saturação fotométrica (0.7), brilho (0.4), contraste (0.5) e redimensionamento de escala (50%), com probabilidade de aplicação de 70% por lote. A função de perda global agregou a perda de classificação (utilizando Binary Cross Entropy), localização de caixa delimitadora (via Complete IoU - CIoU) e perda focal de distribuição (DFL), garantindo um ajuste fino nas bordas das caixas delimitadoras e maior sensibilidade à detecção de espécimes em diferentes distâncias.

INDICADORES DE DESEMPENHO E RESULTADOS

A precisão global de 86,52% demonstra a confiabilidade da rede na redução de instâncias falsas, resultado competitivo quando comparado a estudos recentes como Teng *et al.* (2024), que obtiveram métricas similares em ambientes controlados. Contudo, a inspeção analítica da matriz de confusão (Figura 1) expõe limitações específicas na separação fina: observa-se um erro residual na classificação de touros e vacas adultas como bezerros. Esse comportamento sugere que a alta entropia visual do pasto alto e as frequentes oclusões causadas pelo comportamento gregário do rebanho encobrem características discriminativas inferiores. Além disso, bezerros Nelore em estágios avançados de desenvolvimento corporal podem apresentar similaridade morfológica e dimensional com vacas menores dependendo da distância e perspectiva de captura do sensor, confundindo momentaneamente os mapas de ativação das camadas convolucionais.

Figura 1: Matriz de confusão normalizada do modelo YOLOv8s, discriminando as taxas percentuais de acerto e os erros de classificação mútua entre as classes estruturadas.



Fonte: Elaborada pelos próprios autores.

Tabela 3: Métricas de desempenho global e por classes (YOLOv8s)


Métrica / Classe	P	R	F1-Score	mAP@50	mAP@50:95
Global	93,60%	87,88%	90,65%	96,73%	81,28%
Touros	88,40%	84,20%	86,25%	87,80%	65,10%
Vacas	87,10%	82,50%	84,74%	86,50%	64,20%
Bezerros	84,05%	78,30%	81,07%	82,25%	60,90%

Fonte: Elaborada pelos próprios autores.

No aspecto do treinamento, a análise consolidada das curvas de perda e métricas (Figura 2) indica uma convergência estruturada e preditiva. A estabilização decrescente das funções de perda (*box_loss*, *cls_loss* e *dfl_loss*) tanto no conjunto de treino quanto no de validação ocorreu de forma consistente, sem apresentar descolamentos assintóticos que configurassem cenários de *overfitting*. O treinamento foi expandido para 200 épocas, permitindo observar uma convergência mais robusta e completa das métricas em comparação com o treinamento anterior de 25 épocas, assegurando a capacidade de generalização do modelo e alcançando valores expressivos de

mAP@50 (96,73%) e mAP@50-95 (81,28%).

Figura 2: Curvas de evolução histórica das funções de perda estrutural e das métricas de validação (P, R, mAP) ao longo do treinamento do algoritmo.



Fonte: Elaborada pelos próprios autores.

Como validação qualitativa do pipeline preditivo desenvolvido, a Figura 3 ilustra a inferência prática do modelo sobre amostras do conjunto de teste em ambiente real de campo extensivo. Nota-se a correta delimitação geométrica e atribuição de rótulos mesmo sob condições de sobreposição parcial de corpos e incidência de iluminação solar direta.

Figura 3: Amostra visual de inferência qualitativa do modelo YOLOv8s em condições de campo aberto, demonstrando a aplicação correta das caixas delimitadoras (bounding boxes) e os limiares de confiança por classe.



Fonte: Os autores (2026).

Aplicação Web CattleVision: Implementação Prática do Modelo

Complementando a validação experimental apresentada na Seção 4, desenvolveu-se uma aplicação web denominada CattleVision, cujo objetivo é operacionalizar o modelo YOLOv8s treinado, tornando-o acessível a usuários finais — como zootecnistas, gestores de fazenda e produtores rurais — sem que estes necessitem de conhecimento técnico em Python ou em aprendizagem de máquina. A aplicação materializa, em um primeiro estágio, a integração entre o modelo preditivo desenvolvido na etapa de pesquisa e uma ferramenta de uso prático em campo,

aproximando o resultado acadêmico da rotina operacional da pecuária de precisão.

Arquitetura da Aplicação e Tecnologias Utilizadas

A aplicação foi implementada em Python, seguindo uma arquitetura cliente-servidor baseada no microframework Flask, responsável por expor duas rotas principais: uma página inicial, que apresenta o propósito do sistema e as três classes reconhecidas pelo modelo (touro, vaca e bezerro), e uma página de classificação (rota `"/classificar"`), que recebe uma ou mais imagens enviadas pelo usuário via formulário multipart/form-data. Ao receber as imagens, o servidor invoca o modelo YOLOv8s previamente treinado (arquivo `best.pt`, descrito na Seção 3) por meio da biblioteca Ultralytics, executando a inferência em lote sobre o conjunto de imagens recebido. Como cada fotografia submetida ao sistema retrata, por definição de uso, um único espécime, o backend seleciona a detecção de maior confiança (maior confidence score) dentre as caixas delimitadoras retornadas pelo modelo para determinar a classe predita da imagem, evitando ambiguidades decorrentes de eventuais detecções espúrias de fundo.

Figura 4: Tela inicial do sistema CattleVision, apresentando a proposta do software e as três classes reconhecidas pelo modelo (touro, vaca e bezerro).



Fonte: Elaborada pelos próprios autores.

As imagens anotadas — isto é, a representação visual da caixa delimitadora, do rótulo de classe e do escore de confiança sobrepostos à fotografia original — são geradas pelo próprio método de plotagem da biblioteca Ultralytics e persistidas em disco por meio da biblioteca Pillow (PIL), responsável pela conversão do espaço de cor de saída do modelo (BGR) para o padrão

RGB utilizado pelos navegadores web, bem como pela serialização da imagem em formato JPEG. Por fim, um módulo de exportação de laudos foi implementado com a biblioteca ReportLab, permitindo ao usuário gerar um relatório em PDF contendo, lado a lado, a imagem original sem marcação e a imagem anotada, acompanhadas da classe predita e do percentual de confiança — funcionalidade que confere caráter documental às classificações realizadas, viabilizando seu uso como evidência em relatórios zootécnicos. A Tabela 4 sintetiza as principais tecnologias e bibliotecas empregadas na construção do sistema.

Tabela 4: Tecnologias e Bibliotecas do Sistema Web de Classificação

Tecnologia / Biblioteca	Função no Sistema CattleVision
Flask	Microframework web responsável pelo roteamento HTTP, pelo motor de templates (Jinja2) das páginas e pela orquestração do fluxo entre o upload de imagens, a inferência do modelo e a apresentação dos resultados ao usuário.
Ultralytics (YOLOv8)	Biblioteca oficial da arquitetura YOLOv8, utilizada para carregar os pesos treinados (best.pt) em memória e executar a inferência de detecção e classificação sobre as imagens submetidas pelos usuários.
Pillow (PIL)	Biblioteca de processamento de imagens empregada na conversão do espaço de cor (BGR para RGB) e na gravação em disco das imagens anotadas geradas a partir da saída do modelo.
ReportLab	Biblioteca de geração programática de documentos PDF, utilizada no módulo de exportação de laudos de classificação, compondo páginas com a imagem original e a imagem anotada dispostas lado a lado.
Werkzeug	Biblioteca de suporte ao Flask, responsável pelo tratamento de requisições HTTP, pelo upload seguro de arquivos e pelo servidor de desenvolvimento WSGI utilizado durante os testes da aplicação.
HTML5, CSS3 e Jinja2	Camada de apresentação responsável pela renderização das páginas do sistema, com identidade visual em tons de azul e verde e tipografia monoespaçada Roboto Mono.

Fonte: Elaborada pelos próprios autores.

A escolha por essas tecnologias privilegiou a simplicidade de implantação e a manutenibilidade do código: o Flask permite a criação de uma API web enxuta e de fácil compreensão, ao passo que a reutilização direta da biblioteca Ultralytics — a mesma empregada no treinamento do modelo (Seção 3.2) — garante paridade entre os resultados obtidos no ambiente de pesquisa (Google Colab) e os resultados produzidos em produção, eliminando

divergências decorrentes de reimplementações do algoritmo de inferência em outras linguagens ou frameworks.

Módulo de Classificação: Interface e Fluxo de Predição

O módulo de classificação constitui o núcleo funcional do sistema CattleVision e materializa, sob a perspectiva do usuário final, o pipeline de inferência descrito na Seção 5.1. A interação inicia-se com o envio de uma ou mais fotografias por meio de um formulário de upload; após o processamento no backend, a página de resultados apresenta, para cada imagem submetida, um bloco contendo o nome do arquivo original, a imagem sem qualquer marcação (à esquerda) e a correspondente imagem anotada com a caixa delimitadora, o rótulo da classe e o escore de confiança gerados pelo modelo (à direita), além de uma etiqueta destacando a classe predita — touro, vaca ou bezerro — traduzida para o português e acompanhada do percentual de confiança da predição. A Figura 5 ilustra esse fluxo em um caso real de inferência, no qual um espécime foi corretamente classificado como touro, com 95,1% de confiança.

Figura 5: Interface do módulo de classificação do sistema CattleVision, evidenciando a imagem original (esquerda), a imagem anotada com a caixa delimitadora (direita) e a classe predita com o respectivo percentual de confiança.



Fonte: Elaborada pelos próprios autores.

Adicionalmente, a interface disponibiliza o botão "Exportar PDF", que aciona o módulo de geração de laudos descrito na Seção 5.1, permitindo o registro documental das classificações

realizadas em uma sessão de uso.

CONCLUSÃO

Os resultados obtidos neste estudo demonstram a eficácia da arquitetura YOLOv8s para a classificação fenotípica de bovinos em ambientes dinâmicos e não controlados, consolidando o potencial da visão computacional como pilar fundamental da Pecuária de Precisão. A precisão global atingida valida a arquitetura anchor-free como uma solução robusta para lidar com a variabilidade de escala e oclusões parciais. No entanto, o estudo apresenta limitações inerentes à composição do conjunto de dados utilizado, que reflete condições climáticas e padrões raciais específicos, além de uma representação ainda restrita de bezerros em cenários de oclusão severa. Tais fatores contribuíram para a margem de erro observada na diferenciação morfológica entre categorias de crescimento precoce e vacas adultas. Nesse sentido, a implementação do sistema web CattleVision, apresentado na Seção 5, representa um primeiro passo concreto rumo à integração entre o modelo treinado e o uso prático em campo, permitindo que usuários sem conhecimento técnico em aprendizagem de máquina realizem a classificação de imagens de gado e a exportação de laudos documentais. Como perspectivas futuras, recomenda-se a expansão do dataset para abranger uma maior diversidade de sistemas produtivos, raças e biomas, aumentando a generalização do modelo. Ademais, projeta-se a otimização quantizada para implementação em dispositivos de computação de borda (Edge Computing), visando o processamento autônomo, em tempo real e com baixa latência.

REFERÊNCIAS

ANDERSON, K. Cow, **Calf or Bull Dataset**. Roboflow Universe, 2025. Disponível em: <https://universe.roboflow.com/kaci-anderson-ktgzu/cow-calf-or-bull>. Acesso em: 04 jul. 2026.

CLARK, A. *et al.* **Pillow (PIL Fork) Documentation**. 2025. Disponível em: <https://pillow.readthedocs.io/>. Acesso em: 04 jul. 2026.

JOCHER, G.; CHAURASIA, A.; QIU, J. **Ultralytics YOLOv8**. 2023. Disponível em: <https://github.com/ultralytics/ultralytics>. Acesso em: 04 jul. 2026.

NEETHIRAJAN, S. **Recent advances in wearable sensors for animal health management**. Sensors, v. 23, n. 4, p. 2008, 2023.

PALLETS PROJECTS. **Flask: A Python Micro Framework**. 2010. Disponível em:

<https://flask.palletsprojects.com/>. Acesso em: 04 jul. 2026.

REPORTLAB. **ReportLab PDF Library**. 2025. Disponível em: <https://www.reportlab.com/>. Acesso em: 04 jul. 2026.

SILVA, A. P. *et al.* **YOLOv8 for livestock monitoring: Balancing real-time inference and accuracy in diverse grazing environments**. Computers and Electronics in Agriculture, v. 220, p. 109842, 2025.

TENG, G. *et al.* **Deep learning-based livestock detection and monitoring in complex outdoor environments: A review**. Computers and Electronics in Agriculture, v. 217, p. 108560, 2024.

WANG, H. *et al.* **Fine-grained classification of cattle breeds and growth stages using multi-view vision systems**. Journal of Animal Science and Biotechnology, v. 16, n. 1, p. 42-58, 2025.