

# Automatic Cattle Detection and Counting System in Aerial Images Using Computer Vision Algorithms

Ismael Leal<sup>1</sup>, Allan Jayson<sup>1</sup>, Ricardo Lira<sup>1</sup>, Romuere Veloso<sup>1</sup>,  
Antônio Oseas<sup>1</sup> Maurício Benjamin<sup>2</sup>

<sup>1</sup>Programa de Pós-Graduação Doutorado em Ciência da Computação  
Associação UFMA/UFPI (DCCMAPI)  
CAIXA POSTAL 322 – CEP: 65080 – 040 – São Luis – MA – Brazil

<sup>2</sup>Curso de Sistemas de Informação  
Universidade Federal do Piauí - UFPI.

{ismaelleal30, jheyson, ricardoalr}@ufpi.edu.br

{romuere, antoniooseas, mauriciobenjamin}@ufpi.edu.br

**Abstract.** *This work presents the development of an automatic cattle counting system using computer vision and deep learning techniques. The image dataset was acquired using an Unmanned Aerial Vehicle (UAV) equipped with a high-resolution camera, flying over pasture areas under different environmental conditions in a rural town in Piauí. A total of 273 images were collected and used for training, testing, and validation of the model. The implementation employed the YOLO9 model, trained with the help of the RoboFlow platform. The results demonstrate an accuracy of 94.5%, precision of 96.6%, and recall of 90% in detecting and counting animals, with a mAP of 88.5%. The comparative analysis revealed a similar effectiveness to previous studies, indicating the potential of this approach for practical applications such as in agriculture.*

**Resumo.** *Este trabalho apresenta o desenvolvimento de um sistema de contagem automática de gado, utilizando técnicas de visão computacional e aprendizado profundo. A base de imagens utilizadas foi adquirida por meio de um Veículo Aéreo Não Tripulado (VANT) equipado com uma câmera de alta resolução, sobrevoando áreas de pastagem em diferentes condições ambientais numa cidade no interior Piauí. Um total de 273 imagens foram coletadas e utilizadas para treinamento, teste e validação do modelo. A implementação empregou o modelo YOLO9, treinado com o auxílio da plataforma RoboFlow. Os resultados demonstram uma acurácia de 94,5%, precisão 96,6% e recall de 90% na detecção e contagem de animais, com um mAP de 88,5%. A análise comparativa revelou uma eficácia aproximada em relação a estudos anteriores, indicando o potencial dessa abordagem para aplicações práticas como na agropecuária.*

## 1. Introdução

Segundo o Ministério da Agricultura e Pecuária, que divulgou dados da Pesquisa de Produção da Pecuária Municipal, o rebanho bovino brasileiro alcançou novo recorde de 234,4 milhões de animais em 2022 [MAPA 2024]. A gestão eficiente de rebanhos é uma

tarefa essencial na pecuária, influenciando diretamente a produtividade e a rentabilidade das operações. Tradicionalmente, a contagem de gado é um processo manual que demanda tempo e mão de obra significativa, além de estar sujeito a erros humanos. Neste contexto, a modernização dos métodos de contagem e monitoramento de rebanhos torna-se crucial para aumentar a eficiência operacional e a precisão dos dados obtidos.

Nos últimos anos, a aplicação de tecnologias de visão computacional e aprendizado de máquina na agricultura e pecuária tem mostrado grande potencial para automatizar diversas tarefas, incluindo a contagem de animais. Estudos como o de [Neto and de Freitas 2023] e [Takano et al. 2021] demonstraram o uso bem-sucedido de drones e técnicas de processamento de imagem para monitoramento de rebanhos e detecção de animais. Esses métodos não só reduziram o tempo e o esforço necessários para a contagem, mas também melhoraram significativamente a precisão dos resultados.

A tomada de decisão do agricultor, seja ele de pequeno, médio ou grande porte, pode ser auxiliada com o uso de equipamentos e softwares que vêm se tornando uma prática usual tanto nas atividades da agricultura como em outras tantas, isso devido a sua fácil aplicação, baixo custo e grande possibilidade de aplicações nas diferentes atividades do agronegócio [Chiacchio 2017].

Apesar dos avanços, muitos dos sistemas existentes ainda enfrentam desafios em termos de acessibilidade e facilidade de uso, especialmente para pequenos produtores que podem não ter acesso a equipamentos especializados ou infraestrutura complexa. Além disso, a variabilidade das condições ambientais e a diversidade dos cenários de pastagem podem impactar a eficácia dos modelos de detecção e contagem.

Diante desse cenário, este trabalho propõe um sistema automatizado de contagem de gado utilizando imagens aéreas capturadas por drones. O sistema se distingue por sua integração com dispositivos móveis e computação em nuvem, tornando-o uma solução prática e acessível para pecuaristas de diferentes escalas. A proposta é transferir as imagens dos drones para um dispositivo móvel e, em seguida, enviá-las para um servidor na nuvem, onde são processadas por um modelo de aprendizado de máquina treinado com um conjunto diversificado de imagens aéreas de gado.

A definição do problema aborda a necessidade de um sistema que não só automatize a contagem de gado, mas também ofereça precisão e eficiência em diversos ambientes e condições. Este sistema visa superar as limitações dos métodos tradicionais e dos sistemas automatizados existentes, proporcionando uma ferramenta robusta e de fácil utilização que pode ser amplamente adotada na pecuária moderna.

A seguir, este trabalho detalha a metodologia empregada no desenvolvimento do sistema, discute os resultados experimentais obtidos e explora as implicações e futuras aplicações dessa tecnologia na gestão de rebanhos.

## **2. Trabalhos Relacionados**

O trabalho desenvolvido por [Neto and de Freitas 2023] apresenta o desenvolvimento de um software utilizando redes neurais convolucionais (CNN) para a contagem de gado bovino a partir de imagens obtidas em campo, com a utilização de drones por sensoriamento remoto. O objetivo é criar uma ferramenta para ser usada por produtores rurais, tornando o processo de contagem mais ágil e eficiente. O software foi desenvolvido em *Python*,

utilizando as bibliotecas *TensorFlow* e *Keras*, e obteve uma acurácia de até 92,61% nos testes.

O estudo feito por [Takano et al. 2021] aborda a utilização de redes neurais para a detecção de bovinos em imagens aéreas. Oferece uma abordagem eficiente para a identificação de animais em grandes áreas. A aplicação de técnicas de visão computacional e aprendizado de máquina permite a automação do processo de detecção, reduzindo a necessidade de intervenção humana e aumentando a precisão e a rapidez na obtenção de dados. O trabalho teve uma acurácia de 92,8%.

O trabalho de [Santo and Oliveira 2020] expõe um método que faz uso da visão computacional e da aprendizagem de máquina para possibilitar a detecção, classificação e contagem de bovinos brancos em imagens aéreas obtidas através de um drone. Foram utilizadas a linguagem de programação *Python* e as bibliotecas *OpenCV* (*Open Source Computer Vision*) para o pré-processamento e segmentação das imagens e *scikit-learn* para a classificação com regressão logística. O método foi testado em imagens divididas entre os períodos seco e chuvoso para auxiliar nas etapas de pré-processamento e segmentação e obteve eficiência de 95,2% na detecção e acurácia de 90,1% na classificação de bovinos brancos.

O estudo de [Barbedo et al. 2019] sobre a detecção de gado em imagens de VANT utilizando aprendizado profundo destaca-se pela abordagem focada na raça Canchim, comparando quinze arquiteturas de Redes Neurais Convolucionais (CNNs) em diversas condições. Os resultados revelam a robustez das CNNs na detecção de animais, mesmo em cenários desafiadores, evidenciando o potencial do uso de UAVs para monitoramento pecuário. O estudo menciona que a maioria dos modelos alcançou acurácias acima de 95%, com estruturas muito profundas.

O artigo de [Ribeiro et al. 2019] descreve o processo de desenvolvimento de um programa que aplica algoritmos de Visão Computacional na contagem de gado por meio de imagens aéreas coletadas em bancos de imagens públicas. O processamento das imagens é efetuado por bibliotecas de visão computacional e de processamento de imagens disponíveis para a linguagem de programação *Python*. O sistema desenvolvido teve uma taxa de acerto de 85,4%.

Nossa solução se diferencia pela utilização do modelo YOLO, que é conhecido por sua alta eficiência em detecção de objetos em tempo real, ao contrário de modelos mais lentos como o R-CNN. Além disso, a diversidade das imagens capturadas em diferentes condições ambientais e o uso de *data augmentation* proporcionam maior robustez ao nosso modelo, garantindo que ele lide bem com variações de iluminação e ângulo de captura.

Em resumo, este capítulo revisou as principais abordagens na contagem automática de gado usando imagens aéreas e algoritmos de visão computacional. A análise dos estudos existentes revelou avanços significativos e identificou áreas que podem se beneficiar de melhorias adicionais. Nossa pesquisa busca oferecer uma solução mais robusta e eficiente para o monitoramento pecuário, contribuindo para a evolução dessa tecnologia.

### 3. Sistema de Detecção e Contagem de Gado

Esta seção detalha os procedimentos e técnicas utilizados para o desenvolvimento do sistema de detecção e contagem automática de gado em imagens aéreas, empregando algoritmos de visão computacional. A metodologia adotada abrange desde a coleta e pré-processamento dos dados até a implementação e avaliação do modelo de aprendizado profundo. A Figura 1 representa o fluxograma das etapas deste trabalho.

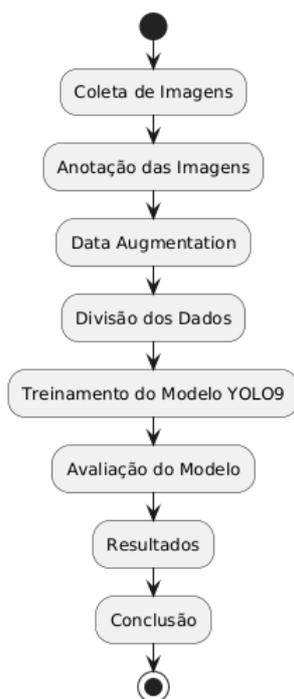


Figura 1. Fluxograma deste Trabalho

#### 3.1. Aquisição das Imagens

A construção da base de dados de imagens é um aspecto fundamental para o desenvolvimento do sistema de contagem automática de gado, impactando diretamente na eficácia do modelo. As imagens utilizadas neste estudo foram capturadas por meio de um Veículo Aéreo Não Tripulado (VANT), especificamente o modelo *Eachine Tyro129 F4 OSD DIY 7Racing Drone*, equipado com uma câmera de alta resolução *Go-Pro RunCam 2*. Essas aquisições ocorreram durante sobrevoos sobre áreas de pastagem na cidade de São João da Varjota, Piauí, sob diferentes condições ambientais e de iluminação, garantindo uma diversidade significativa no conjunto de dados.

No total, 120 imagens foram obtidas, sendo coletadas de múltiplos vídeos. As imagens foram cuidadosamente divididas em subconjuntos de treino, teste e validação, assegurando que imagens oriundas do mesmo vídeo não fossem distribuídas entre diferentes subconjuntos. Esse cuidado foi tomado para evitar qualquer tipo de viés no processo de treinamento e garantir que o modelo fosse testado em imagens completamente novas. Além disso, após aplicar técnicas de data augmentation, a base foi expandida para 273 imagens. Essa expansão permitiu aumentar a diversidade das imagens disponíveis,

proporcionando um conjunto de dados mais robusto e representativo, o que potencializou o treinamento do modelo e melhorou sua capacidade de generalização.

O conjunto de dados foi dividido da seguinte forma: 80% das imagens foram utilizadas para o treinamento do modelo de detecção e contagem de animais, enquanto os 20% restantes foram destinados ao teste. Não há sobreposição de áreas de captura entre as imagens dos diferentes subconjuntos, assegurando que o modelo tenha sido avaliado em diferentes cenários.

Essas imagens envolvem capturas de diferentes locais e momentos, o que implica em uma variabilidade temporal e espacial significativa. Além disso, procurou-se garantir que os animais presentes nas imagens não fossem os mesmos em diferentes capturas, promovendo a generalização do modelo. Para melhor ilustrar essas variações, figuras que demonstram as condições distintas de captura, como diferenças de iluminação e ambientes, estão incluídas para fornecer uma visão clara das características da base de dados.

### 3.1.1. Anotação das Imagens

A anotação das imagens foi realizada com o objetivo de assegurar a precisão na identificação dos animais. A seleção de um banco de dados bem anotado é fundamental para o treinamento de modelos de visão computacional, pois influencia diretamente na capacidade do modelo de aprender a detectar e contar os animais com alta precisão. Neste trabalho, a plataforma RoboFlow [Dwyer and Nelson 2022] foi utilizada para a anotação das imagens capturadas, fornecendo uma interface robusta para demarcar manualmente as localizações dos animais nas imagens.

A marcação das imagens foi realizada de duas maneiras distintas: automática e manual. A marcação automática foi utilizada como etapa inicial para acelerar o processo de anotação marcando automaticamente os animais nas imagens. No entanto, em casos onde a marcação automática não conseguia selecionar os animais de forma correta, uma marcação manual foi realizada para corrigir esses erros. Esse processo manual foi essencial para corrigir erros e garantir a precisão das anotações, assegurando que todos os animais fossem devidamente identificados. A combinação desses dois métodos permitiu criar um conjunto de dados altamente confiável e robusto, essencial para o treinamento eficaz do modelo. A Figura 2 mostra a marcação automática utilizando a ferramenta *smart polygon* da plataforma e a Figura 3 mostra a marcação manual.

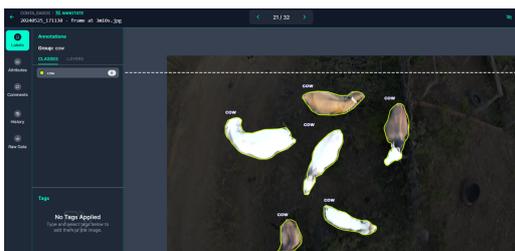


Figura 2. Marcação automática

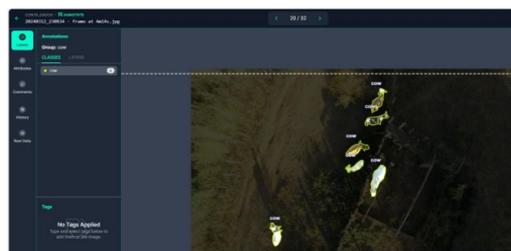


Figura 3. Marcação manual

### 3.1.2. Pré-Processamento

Após a marcação das instâncias nas imagens utilizando a plataforma *RoboFlow*, a próxima etapa fundamental é o pré-processamento, que inclui a aplicação de técnicas de *data augmentation*. O objetivo dessa fase é gerar variações das imagens marcadas para aumentar significativamente o conjunto de dados de treinamento, melhorando a capacidade do modelo de generalizar e lidar com diversas condições e variabilidades presentes no ambiente real. Essas variações criadas através da *data augmentation* são essenciais para enriquecer o conjunto de dados de treinamento, permitindo que o modelo de visão computacional aprenda a reconhecer os animais sob diferentes ângulos, iluminações e condições.

As técnicas de *data augmentation* aplicadas incluem: *Flip*: inversão horizontal das imagens para criar reflexos simétricos. *90° Rotate*: rotação das imagens em 90 graus, ampliando a diversidade de orientações. *Crop*: recorte de partes específicas das imagens para simular diferentes enquadramentos. Rotação entre -15 e +15 graus: pequenas rotações aleatórias dentro deste intervalo para variar a orientação dos animais. *Shear*: aplicação de transformações de cisalhamento para alterar a forma dos objetos nas imagens. Saturação: ajuste da saturação das cores para simular diferentes condições de iluminação e exposição. Escala de cinza: conversão das imagens para escala de cinza, aumentando a robustez do modelo em relação a variações de cor.

Ao aumentar a diversidade do conjunto de dados, garantimos que o modelo se torne mais robusto e eficiente, melhorando sua precisão e capacidade de generalização em situações do mundo real.

### 3.2. Exportação dos Dados Compatíveis com o Modelo

A etapa de Exportação dos Dados refere-se ao processo de preparar os dados pré-processados na plataforma *RoboFlow* para serem utilizados no treinamento com o algoritmo *YOLO (You Only Look Once)*[Redmon and Farhadi 2018], conhecido por sua eficiência e precisão na detecção de objetos em tempo real.

A plataforma *RoboFlow* oferece opções de exportação que são diretamente compatíveis com o modelo *YOLO*, o que simplifica significativamente o processo. Os dados preparados podem ser exportados em um formato específico que o modelo *YOLO* seja capaz de ler e usar durante o treinamento. Essa exportação garante uma transição suave para a próxima etapa, evitando a necessidade de conversões de formato ou processamentos adicionais, economizando tempo e esforço.

### 3.3. Treinamento com *YOLO*

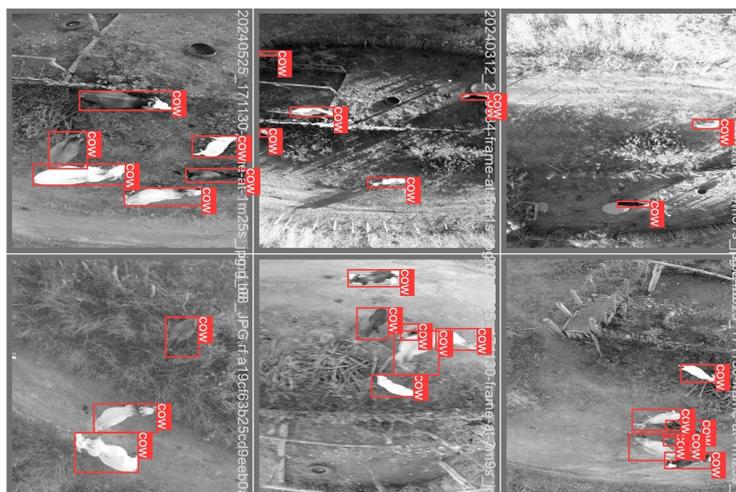
A arquitetura *YOLO* foi escolhida por sua capacidade de realizar a detecção de objetos em tempo real, utilizando uma única rede convolucional para prever *bounding boxes* e as classes dos objetos. Comparado a outros modelos como R-CNN e SSD, que segmentam a detecção em múltiplas etapas, o *YOLO* oferece uma solução mais eficiente para o cenário de detecção e contagem de gado em tempo real.

Com as imagens preparadas, o modelo *YOLO9* foi carregado no ambiente de treinamento, configurado no *Google Colab* para aproveitar os recursos computacionais disponíveis, incluindo o uso de GPU para acelerar o treinamento. As configurações do mo-

delo incluíram a definição de 100 épocas de treinamento, permitindo ao modelo passar por múltiplas iterações sobre os dados, ajustando os pesos das camadas da rede neural a cada ciclo. As 100 épocas de treinamento foram escolhidas com base em testes preliminares, onde foi observado que o modelo convergia para um desempenho estável após aproximadamente 90 épocas. Escolhemos 100 épocas para garantir que o modelo tivesse tempo suficiente para ajustar seus parâmetros e alcançar uma performance robusta. Além disso, o tamanho das imagens de entrada foi definido como 640x640 pixels, um valor padrão da YOLO que visa atender à necessidade de detalhe suficiente para detectar objetos com precisão, ao mesmo tempo em que mantém a eficiência computacional.

Durante o treinamento, o modelo YOLO9, que foi pré-treinado na base COCO, aprendeu a reconhecer e contar os animais presentes nas imagens, ajustando-se continuamente para melhorar a precisão das suas predições. O pré-treinamento na base COCO permitiu ao modelo iniciar o processo de treinamento com pesos já ajustados para tarefas de detecção de objetos, resultando em uma melhor performance no reconhecimento de animais na nossa base específica. Este processo iterativo foi realizado com uma divisão de 70% das imagens para treinamento, 20% para teste, e 10% para validação, permitindo que o modelo desenvolvesse uma compreensão detalhada dos padrões visuais associados aos animais de interesse, resultando em um desempenho robusto na detecção de objetos.

Na Figura 4, podemos observar uma imagem do conjunto de validação durante o processo de treinamento do modelo YOLO9. Os rótulos associados às imagens indicam a localização e a classe dos objetos detectados, permitindo avaliar o desempenho do modelo e verificar se ele está identificando corretamente os animais nas imagens.



**Figura 4. Imagens do Conjunto de Validação. As caixas delimitadoras indicam os animais detectados.**

Ao final das 100 épocas de treinamento, o modelo foi avaliado utilizando conjuntos de dados de validação para verificar sua eficácia antes de ser implantado em um ambiente de produção. Este processo garantiu um modelo bem-treinado e pronto para uso em aplicações práticas de detecção e contagem de animais.

### 3.4. Aplicação Prática

Após a conclusão do treinamento do modelo de detecção de animais com *YOLO*, o próximo passo foi integrá-lo em uma aplicação prática.

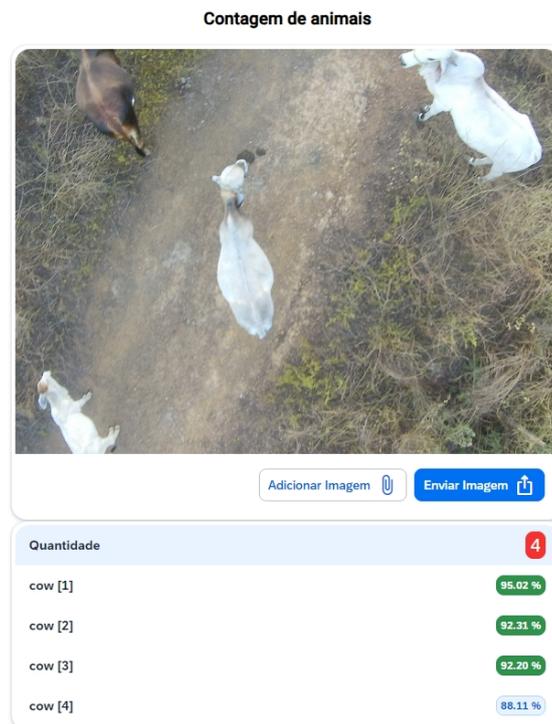
A tecnologia desenvolvida neste trabalho é especificamente projetada para a detecção e contagem automática de animais em imagens aéreas, utilizando visão computacional. Embora o foco principal seja a contagem de gado em ambientes agrícolas, a abordagem proposta tem o potencial de ser adaptada para outras aplicações. Por exemplo, pode ser utilizada para monitorar e rastrear espécies selvagens em estudos de conservação, auxiliando no manejo de habitats naturais. Na agricultura, além da contagem de rebanhos, a tecnologia pode contribuir para a detecção de pragas e o monitoramento das condições ambientais. Em termos de conservação ambiental, a solução pode ser empregada em estudos de impacto ambiental e no monitoramento de áreas protegidas. Finalmente, a tecnologia pode ser adaptada para aplicações em saúde pública, como o monitoramento de populações de animais transmissores de doenças. Essas potenciais aplicações demonstram a versatilidade e a utilidade da abordagem proposta, oferecendo soluções práticas e eficazes para diversos desafios em diferentes setores.

Os resultados obtidos com o modelo treinado foram exportados no formato JSON, compatível com o ambiente de execução da aplicação. Esse formato foi escolhido por sua flexibilidade e facilidade de integração com sistemas de monitoramento e análise, permitindo que os dados de detecção e contagem de animais sejam facilmente processados e visualizados em tempo real. Uma vez exportado, o modelo foi incorporado em uma aplicação *Python* hospedada em um servidor na nuvem, utilizando um contêiner *Docker* para garantir a portabilidade e isolamento da aplicação. Essa aplicação foi responsável por receber as imagens enviadas pelos usuários através de um navegador web e aplicar o modelo de detecção de animais.

Quando uma imagem é enviada para o servidor na nuvem, a aplicação *Python* recebe a requisição e processa a imagem pelo modelo de detecção. O modelo analisa a imagem e identifica a presença de animais, contando quantos deles estão presentes na cena. Essa contagem é então retornada como resultado da análise e a confiança. A Figura 5 apresenta a aplicação em execução.

Os principais serviços utilizados nesta aplicação são *FastAPI* [Ramírez 2024], *Uvicorn* [Team 2024a] e *Ultralytics* [Team 2024b]. *FastAPI* é um *framework web* eficiente para a construção de *APIs RESTful* em *Python*, permitindo um desenvolvimento rápido e intuitivo. *Uvicorn* é um servidor *ASGI* de alto desempenho, utilizado para executar a aplicação *FastAPI* e lidar com solicitações *HTTP* de forma eficiente. *Ultralytics*, por sua vez, é uma biblioteca *Python* que simplifica o uso de modelos *YOLO*, facilitando o carregamento de modelos pré-treinados e a realização de inferências em imagens para detecção de objetos. Esses serviços, quando combinados, proporcionam uma solução robusta e eficaz para a detecção de objetos em imagens, garantindo fácil integração e alta performance.

O processo de implementação descrito acima oferece uma solução prática e eficiente para a detecção e contagem de animais em imagens. Ao utilizar o modelo *YOLO* treinado em uma aplicação *Python* hospedada em um contêiner *Docker* na nuvem, os usuários podem facilmente enviar suas imagens e receber a contagem dos animais pre-



**Figura 5. Sistema de Contagem de Animais**

sentes nelas em tempo real.

Além disso, a confiabilidade do ambiente de nuvem garante que o aplicativo possa lidar com eficiência com um grande volume de solicitações simultâneas, proporcionando uma experiência consistente e confiável aos usuários.

#### **4. Resultados**

Nesta seção, compartilharemos os resultados deste estudo de detecção de animais em imagens aéreas, onde buscamos desenvolver e avaliar uma abordagem eficaz para identificar e contar animais por meio de treinamento e avaliação do modelo *YOLO9*. Serão destacadas as principais métricas de desempenho utilizadas na avaliação do modelo como Acurácia, Precisão, *Recall* e mAP (*Mean Average Precision*).

Os resultados obtidos destacam o desempenho do modelo treinado. O valor da acurácia foi de 94,5% indicando que o modelo está classificando corretamente a maioria das instâncias no conjunto de dados. A precisão foi de 95,6% significando que a grande maioria das detecções do modelo são corretas, com poucos falsos positivos. Neste cenário, a acurácia mede o desempenho geral do modelo considerando todas as classes (verdadeiros positivos e negativos), enquanto a precisão considera apenas os verdadeiros positivos, indicando o quão eficaz o modelo é ao evitar falsos positivos. O valor do *recall* foi de 90,0% indicando que o modelo está identificando a maioria dos animais presentes nas imagens, mas ainda há espaço para capturar alguns que foram perdidos (falsos negativos). O mAP foi de 88,5% indicando que o modelo mantém uma boa precisão em uma variedade de condições, mas pode haver cenários em que o desempenho não seja tão elevado, possivelmente devido à variabilidade nas condições de imagem. O mAP foi

calculado como a média das precisões obtidas para diferentes valores de *recall*. O modelo foi avaliado em vários limiares de confiança, e a média das precisões correspondentes foi calculada para fornecer uma medida de desempenho mais abrangente. Esses resultados não só ressaltam a eficácia do modelo na detecção e contagem precisa de animais, mas também evidenciam áreas potenciais para melhorias. A combinação de alta acurácia, precisão e mAP demonstra que o modelo é uma solução promissora para aplicações práticas de detecção de animais em imagens, embora existam oportunidades para aperfeiçoar a captura de instâncias perdidas e lidar com variações nas condições de imagem.

## 5. Discussão

Nesta seção, discutiremos os resultados de diferentes estudos recentes de detecção de animais, analisando suas respectivas métricas de desempenho e comparando suas eficácias na identificação precisa dos animais presentes nas imagens. A Tabela 1 apresenta os resultados de diferentes estudos de detecção de animais em imagens apresentados neste trabalho.

**Tabela 1. Resultados dos estudos de detecção de animais**

Trabalho	Acurácia
Neto e Freitas	92,61%
Takano	92,80%
Santo e Oliveira	95,20%
Barbedo	95,00%
Ribeiro	85,40%
<b>Metodologia Apresentada</b>	<b>94,50%</b>

A análise dos resultados apresentados na tabela revela uma comparação entre diferentes estudos de detecção de animais e a metodologia proposta neste trabalho. Embora apresente resultados de diferentes bases de dados, é importante ressaltar que cada trabalho utilizou conjuntos de dados específicos, o que dificulta a comparação direta. Para uma comparação mais justa, seria interessante utilizar uma base de dados comum para avaliar o desempenho sob as mesmas condições. A tabela mostra que a acurácia da metodologia apresentada é de 94,50%, o que a posiciona favoravelmente em relação aos outros trabalhos comparados.

Primeiramente, destacam-se os trabalhos de Neto e Freitas (92,61%) e Takano (92,80%), que apresentam valores de acurácia relativamente próximos, mas inferiores à metodologia proposta. Esses resultados indicam que as abordagens desses estudos podem ter limitações em comparação com o método apresentado, que alcança uma acurácia superior, evidenciando uma maior eficácia na classificação correta das instâncias no conjunto de dados.

Os trabalhos de Santo e Oliveira (95,20%) e Barbedo (95,00%) demonstram uma acurácia ainda mais alta, superior à da metodologia apresentada. Essa superioridade sugere que as abordagens empregadas por esses autores podem incorporar técnicas ou melhorias específicas que contribuem para um desempenho superior na detecção de animais. É importante considerar que, embora a acurácia da metodologia proposta seja notável, há espaço para explorar e incorporar as estratégias ou avanços observados nesses estudos para otimizar ainda mais o desempenho.

O trabalho de Ribeiro (85,40%) apresenta a menor acurácia entre os estudos comparados, o que indica que a abordagem utilizada por Ribeiro pode ter limitações significativas na detecção de animais. A diferença de desempenho em relação à metodologia proposta é notável, destacando a eficácia superior do método apresentado.

Em resumo, a metodologia proposta demonstra uma acurácia competitiva e superior à maioria dos estudos comparados, exceto aos de Santo e Oliveira e Barbedo, que obtiveram acurácias ligeiramente superiores. Essa comparação oferece uma visão valiosa sobre o desempenho da metodologia apresentada em relação a abordagens anteriores e aponta para oportunidades de aprimoramento, inspiradas nas técnicas e metodologias empregadas pelos estudos com resultados mais elevados.

## 6. Conclusão

Em resumo, este trabalho investigou e apresentou uma abordagem eficaz para detecção e contagem de animais em imagens utilizando o modelo *YOLO9* em conjunto com a plataforma *RoboFlow*. O sistema proposto e seus resultados demonstraram potencial significativo para aplicações práticas em diversas áreas que poderá ser utilizado no monitoramento da vida selvagem e agricultura. No monitoramento da vida selvagem, por exemplo, a alta precisão do sistema pode ajudar na proteção de espécies ameaçadas, fornecendo dados precisos e em tempo real sobre as populações animais. Na agricultura, o sistema pode ser uma ferramenta valiosa para uma gestão eficiente do rebanho, ajudando os produtores a monitorizar a saúde e a localização dos animais com menos esforço e maior precisão. Em termos de conservação ambiental, a capacidade de contar e monitorizar animais pode apoiar a criação de políticas mais eficazes para a preservação dos ecossistemas e da biodiversidade.

As aplicações práticas, detalhadas na seção de aplicabilidade, demonstram a versatilidade e o valor do sistema em múltiplos contextos. No futuro, o aprimoramento contínuo do modelo, juntamente com a expansão do conjunto de dados de treinamento e otimizações adicionais, poderá contribuir significativamente para melhorar ainda mais a sua eficiência, fortalecendo a utilidade e relevância em cenários do mundo real.

Em futuros trabalhos, pretende-se explorar melhorias contínuas no modelo, expandir o conjunto de dados de treinamento e aplicar técnicas avançadas de aprendizado de máquina para lidar com a variabilidade das condições ambientais. Adicionalmente, a adaptação do sistema para operar em tempo real e a integração com tecnologias como a Internet das Coisas (IoT) poderão abrir novas oportunidades para aplicações inovadoras e práticas no campo da detecção e contagem de animais. A implementação de uma interface de utilizador intuitiva para dispositivos móveis também poderia alargar o acesso à tecnologia, tornando-a mais utilizável para pequenos produtores e comunidades rurais.

Em última análise, este trabalho representa um passo significativo na implementação de soluções eficazes e inovadoras para desafios relacionados com a detecção e contagem de animais, oferecendo benefícios tangíveis para a ciência e agropecuária. A abordagem aqui desenvolvida não só promove avanços técnicos, mas também contribui para a criação de ferramentas práticas e acessíveis que podem ter um impacto positivo em diversas disciplinas e setores. À medida que continuamos a aperfeiçoar e a expandir esta tecnologia, esperamos que ela se torne parte integrante dos esforços para monitorar e proteger a vida selvagem e aumentar a eficiência agrícola.

## 7. Agradecimento

Esta pesquisa foi financiada pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) por meio das bolsas N° 307967/2022-0 (Desenvolvimento de Arquitetura Inteligente para Aplicações na Internet das Coisas Robóticas) e N° 407274/2021-9 (Soluções Estratégicas para Arquiteturas de Redes IoT Aéreo-Terrestres).

## Referências

- Barbedo, J. G. A., Koenigkan, L. V., Santos, T. T., and Santos, P. M. (2019). A study on the detection of cattle in uav images using deep learning. *Sensors*, 19(24):5436.
- Chiacchio, S. S. R. (2017). *Veículo aéreo não tripulado de asa rotativa na atividade de mapeamento e coleta de imagem na agricultura de precisão e no monitoramento de animais*. PhD thesis, Universidade de São Paulo.
- Dwyer, B. and Nelson, J. (2022). Roboflow (version 3.0) [software]. <https://roboflow.com>. Acesso em: 27 de maio de 2024.
- MAPA (2024). Título do site. <https://www.gov.br/agricultura/pt-br>. Acesso em: 10 de junho de 2024.
- Neto, V. and de Freitas, A. (2023). Desenvolvimento de software para contagem de gado bovino usando redes neurais convolucionais. Bagé, RS, Brasil. Universidade Federal do Pampa.
- Ramírez, S. (2024). *FastAPI*. Disponível em: <https://fastapi.tiangolo.com/>.
- Redmon, J. and Farhadi, A. (2018). Yolov9: An incremental improvement. <https://docs.ultralytics.com>. Acesso em: 27 de maio de 2024.
- Ribeiro, N. G., Guedes, G. B., and Barbieri, T. T. (2019). Aplicação de algoritmos de visão computacional na contagem de gado por meio de processamento de imagens aéreas. Hortolândia, SP, Brasil. Instituto Federal de Educação Ciência e Tecnologia de São Paulo.
- Santo and Oliveira (2020). Classificação e contagem de bovinos em imagens aéreas utilizando visão computacional e aprendizagem de máquina. In *Anais da VIII Escola Regional de Computação do Ceará, Maranhão e Piauí*, pages 165–172, Porto Alegre, RS, Brasil. SBC.
- Takano, W. H., Almeida, L. L., and da Silva, F. A. (2021). Detecção de animais bovinos utilizando imagens aéreas por meio de redes neurais. In *Colloquium Exactarum*. ISSN: 2178-8332, volume 13, pages 47–56.
- Team, U. (2024a). Unvicorn. <https://github.com/unvicorn/unvicorn>. Accessed: 2024-05-27.
- Team, U. (2024b). Yolov9. <https://github.com/ultralytics/yolov9>. Accessed: 2024-05-24.