

Desenvolvimento de Aplicação com Visão Computacional no Controle e Monitoramento Inteligente de Bovinos

Arthur Maica¹, Greice A. Welter^{1,2}, Larissa Guder^{1,3}, Adriano Vogel^{1,4}

¹ Laboratório de Pesquisas Avançadas para Computação em Nuvem (LARCC), Sociedade Educacional Três de Maio (SETREM), Três de Maio, RS, Brasil.

²Universidade Federal do Pampa (UNIPAMPA), Alegrete, RS, Brasil.

³Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS), Porto Alegre, Brasil.

⁴Dynatrace Research, Linz, Austria

{greice.welter, larissa.guder, adriano.vogel}@setrem.com.br

Resumo. Este trabalho apresenta o desenvolvimento de um sistema baseado no algoritmo YOLO (You Only Look Once) versão 4, aplicado à detecção automática de bovinos em ambientes rurais. Unificando técnicas de visão computacional, o algoritmo foi projetado para atender às necessidades do pequeno produtor rural, oferecendo uma solução de monitoramento e controle inteligente sem exigir investimentos elevados ou infraestrutura computacional robusta. O sistema permite o processamento de dados em tempo real com alta precisão, contribuindo significativamente para a modernização da gestão pecuária.

Abstract. This paper presents the development of a system based on the YOLOv4 algorithm, applied to the automatic detection of cattle in rural environments. The product, combining computer vision, was designed to meet the needs of small rural producers, offering an intelligent monitoring and control solution without requiring significant investments or robust computing infrastructure. The system enables real-time data processing with high accuracy, significantly contributing to the modernization of livestock management.

1. Introdução

A contagem manual de animais em ambientes extensivos ou semi-extensivos é suscetível a erros humanos, demanda mão de obra constante e pode comprometer a gestão da pecuária. A movimentação natural dos bovinos em pastagens, aliada à falta de tecnologias acessíveis em pequenas propriedades, dificulta o monitoramento preciso do rebanho. Nesse contexto, a detecção e contagem automática de bovinos configuram-se como um desafio relevante na pecuária moderna.

O artigo [Junhao et al. 2024] introduziu o *Cow-YOLO*, focado na detecção de posturas de acasalamento em vacas, utilizando uma arquitetura com *CSPDarknet53*, módulos de atenção e redes *transformer*, alcançando desempenho (mAP de 99,5% e 156,3 fps) mesmo em cenários complexos. Já o trabalho de [Zheng and Qin 2023] propôs o *PrunedYOLO-Tracker*, que aplicou poda de canais ao YOLOv5l para reduzir drasticamente o tamanho do modelo (73,5%) sem comprometer o desempenho, integrando ainda o algoritmo C-BIoU para rastreamento robusto (HOTA de 72,4% e 81 fps).

Este trabalho propõe um sistema preciso e eficiente, com uma interface gráfica simplificada, com o objetivo de tornar as tecnologias de detecção por transmissão de vídeo acessíveis a pequenos produtores rurais, mesmo em contextos com infraestrutura limitada e sem a necessidade de hardware especializado.

O artigo está estruturado em quatro seções. A próxima seção 2 descreve as métricas utilizadas para avaliar a acurácia da rede neural. Na seção 3, são apresentados o modelo adotado e o conjunto de dados utilizado nos experimentos. Por fim, a seção 4 apresenta as conclusões obtidas e os trabalhos futuros.

2. Metodologia

A metodologia empregada neste trabalho consiste no desenvolvimento de um sistema modular de detecção de bovinos baseado no algoritmo YOLOv4, projetado para ambientes com baixa capacidade computacional. O processamento do vídeo capturado ocorre em tempo real, analisando um a cada três quadros para equilibrar desempenho e responsividade. As detecções geram informações como classe do objeto, nível de confiança e imagem recortada.

Os registros são armazenados em um banco de dados voltado para séries temporais e grandes volumes de dados, escolhido por sua eficiência na consulta de informações. Para o acesso do usuário final, foi implementada uma interface gráfica leve usando a biblioteca *Tkinter*, que exibe uma tabela interativa com filtros por nome, confiança e data. Além disso, o sistema oferece uma visualização em tempo real com *bounding boxes*, validando a arquitetura de detecção e garantindo sua operacionalidade mesmo sem o uso de GPU.

O algoritmo de detecção utiliza o algoritmo YOLO para identificar objetos em tempo real. A escolha pelo YOLOv4 justifica-se por sua robustez e estabilidade, especialmente em contextos com recursos computacionais limitados, como sistemas embarcados ou sem GPU dedicada [Hao et al. 2023].

O sistema realiza uma filtragem inicial nas detecções com base em dois critérios: o nível de confiança da predição e a classe do objeto. Apenas detecções com confiança superior a 0.3 e correspondentes ao identificador de bovinos no *dataset* COCO (*Common Objects in Context*) são consideradas válidas. Em seguida, aplica-se a técnica de NMS (*Non-Maximum Suppression*), utilizando os limiares de score 0.3 e NMS 0.4. Essa etapa é responsável por remover sobreposições excessivas de *bounding boxes*, garantindo que apenas a melhor predição por objeto seja mantida. Após esse processamento, as detecções finais são exibidas em tempo real com *bounding boxes* e rótulos identificadores.

O modelo YOLOv4 foi submetido a um processo de *fine-tuning* utilizando um *dataset* específico de bovinos, com o objetivo de adaptar a rede às características visuais do cenário rural e das raças observadas. O treinamento preliminar foi realizado em 10 épocas, o suficiente para avaliar a capacidade do modelo de aprender padrões relevantes sem superajuste.

Para garantir a acessibilidade ao usuário final, foi desenvolvida uma interface gráfica com a biblioteca *Tkinter*, escolhida por ser leve e de fácil distribuição, ideal para hardware com poucos recursos computacionais. A aplicação se conecta ao banco de dados de séries temporais exibindo os resultados em uma tabela (*Treeview*) que permite ao usuário aplicar filtros por data, nome do objeto e nível de confiança. Além disso, é possível selecionar um registro na tabela para visualizar a imagem recortada da respectiva detecção.

3. Resultados Preliminares

Os testes foram realizados em um ambiente limitado com 8 GB de memória RAM, processador Intel Core i5-650 X4 de primeira geração, 4 núcleos, e Disco Rígido de 1 TB de armazenamento, sem GPU dedicada.

A Figura 1 mostra a interface de visualização em tempo real com transmissão pelo protocolo HTTP, operando diretamente com o YOLOv4. Nesta janela, observa-se o uso

de *bounding boxes* verdes ao redor dos animais identificados, representando as detecções realizadas pelo modelo. Ela atua como um *proxy* para validar a infraestrutura do sistema de detecção de bovinos. O sistema processa apenas um a cada três *frames* para otimizar o desempenho, mantendo o equilíbrio entre eficiência e responsividade, mesmo sem uso de GPU [Aminiyyeganeh 2023].

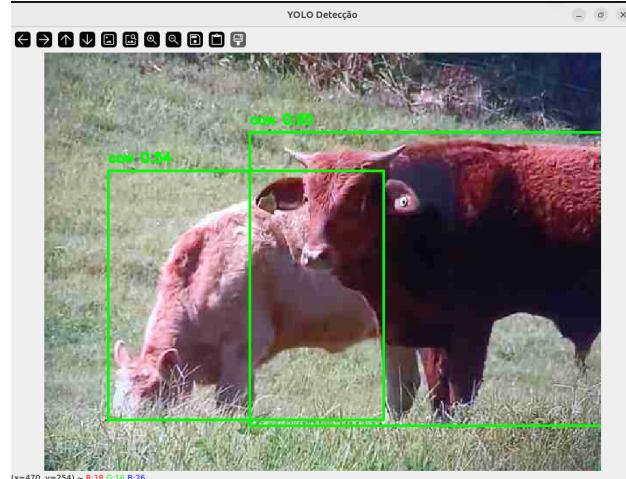


Figura 1. Janela com Stream Local da Detecção de bovinos.

A Figura 2 mostra a interface construída com a biblioteca *Tkinter*, que funciona como o painel de interação do usuário com o sistema para filtragem por data, nome do objeto e valor mínimo de confiança.

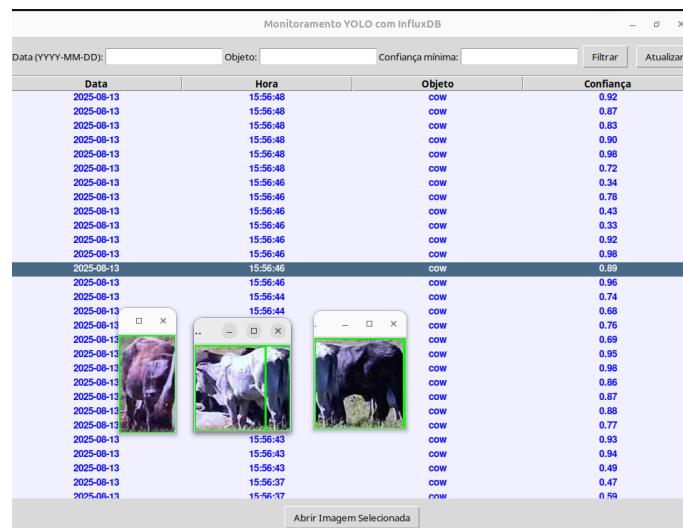


Figura 2. Interface gráfica da aplicação em tempo real do YOLOv4 e do Tkinter.

A validação do sistema foi realizada em duas frentes: a avaliação quantitativa do desempenho do modelo de detecção e a verificação funcional da aplicação de monitoramento. Para a avaliação de desempenho, o modelo foi treinado por 10 épocas para medir sua capacidade de aprender a detectar bovinos. A análise das métricas revelou uma evolução positiva e consistente. As perdas de validação, tanto para a localização de *box loss* quanto para a *class loss*, apresentaram uma queda constante ao longo do treinamento.

Este comportamento sugere que o modelo generalizou o aprendizado de forma eficaz para dados não vistos, sem indícios de *overfitting* nesse estágio.

Como resultado do treinamento, observou-se uma melhora contínua na acurácia do modelo ao longo das épocas, medida pela métrica mAP@50 (*Mean Average Precision*) com limiar de 0,50 para a IoU (*Interseção sobre União*). Essa métrica indica a precisão média das previsões corretas, considerando que uma detecção é válida se a sobreposição com o objeto real for de pelo menos 50%. O modelo iniciou o treinamento com uma mAP@50 de aproximadamente 68%, o que já indicava uma capacidade inicial razoável de identificar bovinos corretamente. Ao final da décima época, essa métrica evoluiu para 72,5%, refletindo o aprendizado progressivo e a melhoria do desempenho do modelo com base nos dados fornecidos.

4. Conclusão e Trabalhos Futuros

Este trabalho apresenta um sistema de detecção de bovinos utilizando YOLO. Diferentemente das soluções existentes na literatura e em repositórios públicos, que geralmente exigem alto poder computacional ou são voltadas para cenários específicos, o sistema aqui proposto se destaca por integrar diferentes módulos de detecção, armazenamento e interface em uma solução funcional de ponta a ponta, capaz de operar em ambientes com infraestrutura computacional limitada.

Como trabalho futuro, propõe-se o treinamento de modelos com capacidade de adaptação contínua a partir de *datasets* específicos de bovinos, ampliando a precisão do sistema em diferentes ambientes e condições. Além disso, a integração com *drones* e múltiplas câmeras pode expandir significativamente a cobertura e a eficiência do monitoramento.

Dessa forma, o algoritmo apresentado aqui se consolida como uma solução promissora para a modernização da pecuária, ao viabilizar a automação do manejo, promover melhorias no bem-estar animal e aumentar a eficiência operacional, sempre com foco na acessibilidade tecnológica e na realidade do pequeno produtor rural.

Referências

- Aminiyegeh, K. (2023). *Performance Evaluation of the Object Detection Algorithms on Embedded Devices*. PhD thesis, Concordia University.
- Hao, W., Ren, C., Han, M., Zhang, L., Li, F., and Liu, Z. (2023). Cattle body detection based on yolov5-ema for precision livestock farming. *Animals*, 13(22).
- Junhao, W., Zhe, Z., Baisheng, D., Kaixuan, Z., Weizheng, S., Yanling, Y., Yang, L., et al. (2024). Cow-yolo: Automatic cow mounting detection based on non-local csp-darknet53 and multiscale neck. *International Journal of Agricultural and Biological Engineering*, 17(3):193–202.
- Zheng, Z. and Qin, L. (2023). Prunedyolo-tracker: An efficient multi-cows basic behavior recognition and tracking technique.