

## AVALIAÇÃO DE MODELOS YOLO PARA DETECCÃO DE PRAGAS EM FRUTICULTURA: UM ESTUDO EM HARDWARE DE BAIXO CUSTO

EDUARDO MACHADO BEHLING<sup>1</sup>, MARILTON SANCHOTENE DE AGUIAR<sup>2</sup>

<sup>1</sup> Universidade Federal de Pelotas – embehling@inf.ufpel.edu.br

<sup>2</sup> Universidade Federal de Pelotas – marilton@inf.ufpel.edu.br

### 1. INTRODUÇÃO

O cultivo agrícola tem sido um pilar da sociedade contemporânea, contribuindo para um expressivo crescimento demográfico nos últimos anos. Contudo, esse aumento populacional ocasionou uma elevada demanda por produtos agrícolas, sobretudo alimentos. O ambiente natural exerce forte influência sobre o cultivo, e as pragas configuram um desafio relevante, frequentemente ocasionando prejuízos significativos às colheitas e revelando-se de difícil manejo. Esse cenário evidencia a necessidade premente de sistemas eficazes para controlar populações de pragas e mitigar seus impactos na agricultura (TUDI et al., 2021).

Uma das soluções mais recorrentes para o manejo de pragas é a utilização de pesticidas. Embora esses compostos possam controlar de forma eficaz as infestações, estudos os relacionam a efeitos adversos sobre a saúde humana e o meio ambiente (GHAFARIFARSANI et al., 2024). Nesse contexto, o Manejo Integrado de Pragas (MIP) foi concebido para reduzir a dependência de soluções químicas. Essa estratégia enfatiza práticas preventivas, monitoramento contínuo e tomada de decisão fundamentada em limiares previamente estabelecidos, em vez de basear-se unicamente em aplicações reativas de pesticidas.

Uma técnica amplamente empregada para o controle de populações de insetos-praga é o uso de armadilhas. Essas armadilhas geralmente incorporam uma isca atrativa, frequentemente composta por feromônios sexuais ou alimentos, além de um mecanismo destinado a capturar o inseto no momento da entrada. Este artigo investiga a aplicação de modelos de detecção de objetos para o monitoramento de pragas, conforme proposto por (BEHLING; AGUIAR, 2025), a fim de oferecer uma alternativa ao pipeline descrito em (FREITAS et al., 2022). Essa variante automatiza a tarefa de monitoramento que, de outra forma, exigiria intervenção manual. Para tal, utiliza-se uma câmera V2 de 8 MP controlada por um Raspberry Pi III, com o propósito de identificar as pragas *Ceratitis capitata* e *Grapholita molesta*. Essas espécies são amplamente reconhecidas na fruticultura por sua elevada capacidade de adaptação a ambientes urbanos e rurais, sendo prevalentes em diversas regiões do Brasil, especialmente nos estados do Rio Grande do Sul e São Paulo (DIAS et al., 2023).

### 2. METODOLOGIA

Para esta aplicação, foram treinadas as versões YOLOv5, YOLOv8, YOLOv11 e YOLOv12 nas variantes Nano e Small. Essa escolha decorre dos requisitos de desempenho impostos pela utilização da plataforma Raspberry Pi III, bem como da eficiência e praticidade proporcionadas pelos modelos YOLO (You Only Look Once).

Os dados utilizados foram extraídos do dataset disponibilizado em (DIAS et al., 2023), a partir do qual foi realizada a reconstrução do conjunto para o formato de detecção de objetos. Esse formato requer a imagem originalmente capturada

pela câmera acompanhada de um arquivo que lista a posição de cada instância, utilizando o padrão de caixa de enquadramento (*bounding box*).

Durante o treinamento, para compensar o tamanho reduzido do *dataset*, foram empregadas técnicas de aumento de dados (*data augmentation*). De forma offline, aplicou-se o algoritmo CLAHE, com limite de contraste igual a 2.0 e grade de equalização de  $8 \times 8$ , aplicado de maneira aleatória, o que resultou em um acréscimo de 868 entradas (3,86%), conforme a distribuição descrita na Tabela 1. Já de forma online, foram elaboradas as seguintes configurações: Zero (nenhuma técnica aplicada), Cromática (ajuste de *hue*, saturação e valor), Oclusão (apagamento), Rotação (rotação, mosaico), Transformação (translação, escala, perspectiva, cisalhamento, mosaico), Parcial (transformação, rotação, *cutmix*, *mixup*, *copy-paste*, espelhamento vertical e horizontal) e Todos (cromática, parcial, oclusão).

As métricas selecionadas para a avaliação do desempenho de segmentação foram a *Intersection over Union (IoU)* em conjunto com a *Average Precision (AP)*. Um valor comumente adotado para a aplicação dessas métricas consiste no uso do *IoU* no intervalo 50–95, o que as torna mais rigorosas, sendo enunciado como  $mAP_{50-95}$ .

Para a avaliação de desempenho, a métrica adotada foi o tempo total agregado ( $T_{total}$ ), que corresponde à soma dos tempos de pré-processamento, inferência e pós-processamento. Esse valor representa o tempo necessário para que cada imagem seja analisada pela rede em um sistema de tempo real, no qual as imagens são fornecidas sequencialmente e não há possibilidade de agrupamento de entradas (*batching*).

Tabela 1: Distribuição do *dataset* após a aplicação do aumento de dados.

Segmento	Ceratitis	Grapholita	Outros	Total
Treinamento	12206 (53.15%)	6398 (27.86%)	4363 (19.00%)	22967 (70.03%)
Validação	1479 (48.81%)	968 (31.95%)	583 (19.24%)	3030 (9.24%)
Teste	3702 (54.45%)	1706 (25.09%)	1391 (20.46%)	6799 (20.73%)
<b>Total Geral</b>				<b>32796</b>

### 3. RESULTADOS E DISCUSSÃO

Nesta seção, são apresentados e analisados os resultados dos experimentos realizados com as versões YOLOv5, YOLOv8, YOLOv11 e YOLOv12 nas diferentes configurações enunciadas na metodologia. A Figura 1 exibe integralmente os resultados obtidos. A análise evidencia um aumento no tempo total superior a 150%, decorrente da elevação do tamanho do modelo provocada pela substituição da variante Nano pela Small.

A análise da Figura 2 evidencia que, nesta aplicação, as configurações Parciais, Todas, Transformações e Rotação exerceram impacto negativo sobre o  $mAP_{50-95}$ . Por outro lado, a configuração Oclusão apresentou efeito positivo apenas no modelo YOLOv5, na variante Small. Já a configuração Cromática resultou em impactos positivos na maioria dos modelos e variantes, com exceção dos modelos YOLOv11 Small e YOLOv12 Nano.

Figura 1: Resultados obtidos.

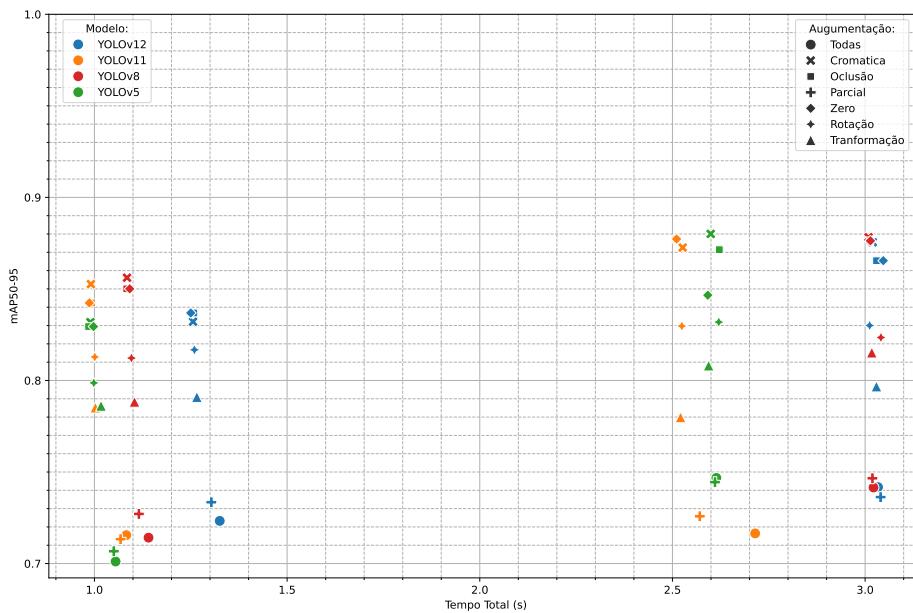
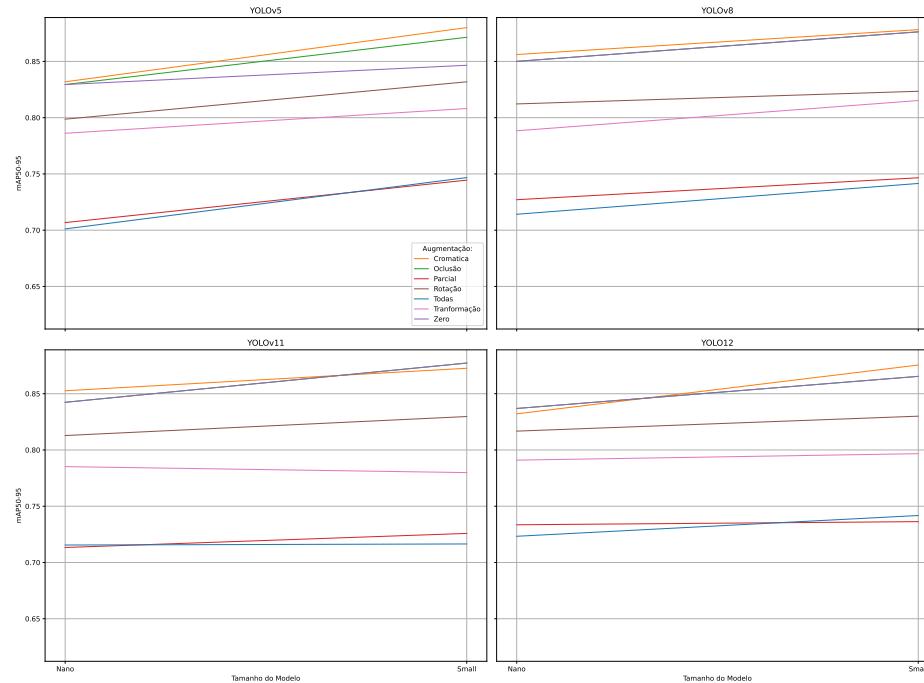


Figura 2: Impacto das configurações de aumento de dados.



## 4. CONCLUSÕES

Este estudo realizou uma avaliação sistemática da aplicação de modelos de detecção de objetos da família YOLO para o monitoramento de pragas agrícolas em armadilhas inteligentes, com ênfase na busca por um equilíbrio ótimo entre precisão e eficiência computacional em hardware embarcado. A análise dos resultados, baseada na métrica que relaciona o  $mAP_{50-95}$  ao tempo total de processamento, possibilita a formulação de conclusões consistentes.

Os resultados evidenciam de forma inequívoca que os modelos da variante Nano são os mais apropriados para esta aplicação. Apesar de os modelos de maior porte alcançarem desempenho de segmentação ligeiramente superior, o elevado custo computacional os torna menos eficientes para a tarefa, que demanda agilidade.

Entre as variantes Nano, os modelos YOLOv11 Nano e YOLOv8 Nano destacaram-se pelo melhor desempenho geral, ocupando a maioria das primeiras posições na classificação de eficiência. Esses modelos apresentam um equilíbrio entre elevada acurácia e baixo tempo total, com a configuração de aumento de dados Cromática alcançando a mais alta pontuação de desempenho.

Portanto, para esta aplicação específica, é preferível a utilização do modelo YOLOv11 Nano, cujo  $T_{total}$  é 8,64% inferior, apresentando apenas uma redução de 0,41% no  $mAP_{50-95}$ . Essa configuração não apenas atende aos requisitos técnicos para operação na plataforma Raspberry Pi III, como também representa uma solução robusta e eficiente para a automação do Manejo Integrado de Pragas.

## 5. AGRADECIMENTOS

O presente trabalho foi realizado com apoio do Programa Institucional de Bolsas de Iniciação Tecnológica (PIBITI) do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

- BEHLING, E.; AGUIAR, M. Exploring yolo algorithm application in smart traps for fruit pest detection. In: **Anais do XVI Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais**. Porto Alegre, RS, Brasil: SBC, 2025. p. 336–339. ISSN 2595-6124. Disponível em: <<https://sol.sbc.org.br/index.php/wcama/article/view/36111>>.
- DIAS, N. P.; SILVA, F. F. D.; ABREU, J. A. D.; PAZINI, J. D. B.; BOTTA, R. A. Infestation level of fruit flies in the boundary zone in rio grande do sul, brazil. **Rev. Ceres**, 2023.
- FREITAS, L.; MARTINS, V.; AGUIAR, M. de; BRISOLARA, L. de; FERREIRA, P. Deep learning embedded into smart traps for fruit insect pests detection. **ACM Trans. Intell. Syst. Technol.**, Association for Computing Machinery, New York, NY, USA, v. 14, n. 1, nov. 2022. ISSN 2157-6904. Disponível em: <<https://doi.org/10.1145/3552435>>.
- GHAFARIFARSANI, H.; ROHANI, M. F.; RAEESZADEH, M.; AHANI, S.; YOUSEFI, M.; TALEBI, M.; MD, S. H. Pesticides and heavy metal toxicity in fish and possible remediation – a review. **Annals of Animal Science**, v. 24, n. 4, p. 1007–1024, 2024. Disponível em: <<https://www.proquest.com/scholarly-journals/pesticides-heavy-metal-toxicity-fish-possible/docview/3120254872/se-2>>.
- TUDI, M.; RUAN, H. D.; WANG, L.; LYU, J.; SADLER, R.; CONNELL, D.; CHU, C.; PHUNG, D. T. Agriculture development, pesticide application and its impact on the environment. **International Journal of Environmental Research and Public Health**, MDPI, v. 18, n. 3, p. 1112, Jan 2021. ISSN 1660-4601. Research Support, Non-U.S. Gov't, Review. Disponível em: <<https://doi.org/10.3390/ijerph18031112>>.