

## **AValiação de Modelos YOLO para Detecção 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](mailto:embehling@inf.ufpel.edu.br)

<sup>2</sup> Universidade Federal de Pelotas – [marilton@inf.ufpel.edu.br](mailto:marilton@inf.ufpel.edu.br)

### **1. DESCRIÇÃO DA INOVAÇÃO**

A inovação proposta consiste em um sistema inteligente de monitoramento de pragas agrícolas baseado em modelos de detecção de objetos da família YOLO (*You Only Look Once*), implementado em plataforma de baixo custo e consumo energético, o Raspberry Pi III, associado a uma câmera V2 de 8 MP.

O design do sistema integra hardware acessível com algoritmos de última geração em visão computacional, permitindo a identificação automática das pragas *Ceratitis capitata* e *Grapholita molesta*. Armadilhas físicas são equipadas com iscas atrativas (feromônios ou alimentos) e conectadas ao sistema embarcado, que registra imagens, processa os dados em tempo real e gera informações úteis para o manejo agrícola (BEHLING; AGUIAR, 2025).

A singularidade da inovação reside na combinação entre precisão, eficiência computacional e portabilidade. Enquanto soluções tradicionais dependem de inspeções manuais ou do uso extensivo de pesticidas, o sistema desenvolvido oferece monitoramento automatizado, contínuo e escalável. Diferentemente de pipelines convencionais (FREITAS et al., 2022), o modelo proposto otimiza o equilíbrio entre acurácia (avaliada por métricas como  $mAP_{50-95}$ ) e velocidade de processamento ( $T_{total}$ ), possibilitando sua operação em tempo real mesmo em hardware restrito.

### **2. ANÁLISE DE MERCADO**

Os principais beneficiários desta inovação são produtores agrícolas de pequeno, médio e grande porte, especialmente os inseridos na fruticultura intensiva, como nos estados do Rio Grande do Sul e São Paulo, onde as pragas-alvo são altamente prevalentes (DIAS et al., 2023). Além disso, cooperativas agrícolas, empresas de monitoramento ambiental e órgãos governamentais de vigilância fitossanitária podem incorporar a solução para reduzir perdas e aprimorar estratégias de manejo.

Do ponto de vista demográfico, estima-se que milhares de pequenos produtores dependem de culturas altamente suscetíveis às pragas monitoradas. Comportamentalmente, esse público busca soluções de baixo custo, de fácil operação e que reduzam a necessidade de mão de obra especializada. A inovação atende a essa demanda ao fornecer um sistema acessível, escalável e capaz de apoiar práticas de Manejo Integrado de Pragas (MIP) (TUDI et al., 2021).

Entre os competidores, destacam-se tecnologias baseadas em sensores avançados ou em drones, que, embora ofereçam precisão elevada, apresentam custos elevados e demandam infraestrutura complexa. Em contraste, a proposta aqui apresentada se posiciona como uma solução eficiente e acessível, favorecendo a adoção em larga escala. Considerando a expansão da agricultura de precisão no Brasil e no mundo, estima-se um mercado em crescimento acelerado, impulsionado pela busca por sustentabilidade e redução do uso de pesticidas (GHAFARIFARSANI et al., 2024).

### 3. ESTRATÉGIA DE DESENVOLVIMENTO E IMPLEMENTAÇÃO

O modelo de geração de receita pode se estruturar em duas frentes: (i) venda direta de dispositivos completos, destinados a produtores e cooperativas, e (ii) prestação de serviços de monitoramento por assinatura, com análise de dados e relatórios personalizados. Estratégias de distribuição incluem parcerias com cooperativas agrícolas, associações de produtores e empresas de insumos agrícolas.

O desenvolvimento seguiu etapas bem definidas. Inicialmente, foram treinadas e comparadas diferentes versões dos modelos YOLO (v5, v8, v11 e v12) nas variantes Nano e Small. O treinamento utilizou o conjunto de dados disponibilizado por (DIAS et al., 2023), adaptado para tarefas de detecção de objetos, e técnicas de aumento de dados (*data augmentation*), tanto offline (como o algoritmo CLAHE) quanto online (cromática, oclusão, rotação, transformações, entre outras).


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	Ceratitís	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>


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.

Figura 1: Resultados obtidos.



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 2: Impacto das configurações de aumento de dados.



Testes realizados demonstraram que os modelos da variante Nano apresentam melhor equilíbrio entre precisão e tempo de processamento, destacando-se o YOLOv11 Nano, que obteve  $T_{total}$  8,64% inferior com redução de apenas 0,41% no  $mAP_{50-95}$ . Protótipos funcionais já foram validados em simulações controladas, e a próxima etapa consiste em testes de campo em áreas de produção agrícola.

Entre os desafios a serem enfrentados, destacam-se a variabilidade ambiental (luminosidade, condições climáticas), a necessidade de manutenção simplificada do dispositivo e a adaptação a diferentes culturas. Tais riscos podem ser mitigados por calibrações periódicas do sistema, pelo uso de modelos de aprendizado contínuo e por estratégias de treinamento incremental.

#### 4. RESULTADOS ESPERADOS E IMPACTOS

O impacto da inovação transcende a esfera técnica, atingindo dimensões sociais, econômicas e ambientais. Ao permitir o monitoramento automatizado de pragas, reduz-se a dependência de pesticidas, minimizando efeitos adversos sobre a saúde humana e o meio ambiente (GHAFARIFARSANI et al., 2024). Além disso, a redução de perdas agrícolas contribui para a segurança alimentar e aumenta a rentabilidade dos produtores. Do ponto de vista econômico, a solução promove ganhos de produtividade e reduz custos operacionais associados ao monitoramento manual. Ambientalmente, a redução do uso de pesticidas auxilia na preservação da biodiversidade e no atendimento a normas de sustentabilidade. Socialmente, possibilita a inclusão de pequenos produtores em práticas modernas de agricultura de precisão, democratizando o acesso a tecnologias inovadoras.

## 5. CONCLUSÕES

A inovação apresentada consiste em um sistema de monitoramento inteligente de pragas agrícolas que combina eficiência, baixo custo e aplicabilidade prática. Baseado em modelos YOLO otimizados para hardware embarcado, o sistema mostrou-se capaz de atender às demandas do Manejo Integrado de Pragas, unindo precisão e rapidez.

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.

O potencial impacto sobre o setor agrícola é expressivo, tanto em termos econômicos quanto ambientais, com vantagens competitivas claras em relação a soluções mais caras e complexas. Os próximos passos envolvem a validação em campo, a consolidação de parcerias estratégicas e a expansão para outras culturas e regiões. Convida-se, portanto, stakeholders, investidores e parceiros a participarem do processo de consolidação e escalabilidade desta inovação, que se apresenta como uma ferramenta estratégica para o futuro da agricultura sustentável.

## 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>>.
- GHAJARIFARSANI, 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>>.