

# DESENVOLVIMENTO DE ALGORITMO PARA CLASSIFICAÇÃO DE IMAGENS E DETECÇÃO DE AFÍDEOS EM LAVOURAS DE TRIGO

Erich Abreu Serafim<sup>1</sup>; Wânderson de Oliveira Assis<sup>2</sup>

<sup>1</sup> Aluno de Iniciação Científica do Instituto Mauá de Tecnologia (IMT);

<sup>2</sup> Professor do Instituto Mauá de Tecnologia (IMT).

**Resumo.** *Este trabalho apresenta um estudo comparativo de algoritmos para processamento de imagens digitais visando detecção e classificação espécies de afídeos que tipicamente impactam a cultura do trigo. A proposta é realizar um estudo comparativo entre classificação de imagens usando a detecção de objetos por meio de algoritmos da família You Only Look Once (YOLO), e o emprego de sistemas de classificação por meio de algoritmos PyramidNet. Com a proposta espera-se contribuir para o desenvolvimento de soluções eficientes que possam ser embarcadas em conjunto com tecnologias de Agricultura de Precisão e Internet das Coisas, a fim de aumentar e melhorar o controle e os ganhos do produtor sobre os insumos.*

**Palavras-Chave.** Inteligência Artificial; Detecção de Objetos; Classificação de Imagem; Afídeos; Trigo.

## Introdução

Com o avanço de tecnologias como a Internet das Coisas (IoT) e o processamento de imagens, surgem novas possibilidades para a agricultura de precisão, como o monitoramento em tempo real e a detecção precoce de problemas nas lavouras. Estudos mostram que a combinação de processamento de imagem com machine learning oferece um potencial promissor para enfrentar esses desafios na agricultura (Lins *et al.*, 2020) (Cesaro Júnior *et al.*, 2022). Combinando processamento de imagem com técnicas de *machine learning* e *deep learning* há potencial para o desenvolvimento de diversos projetos que muito contribuem para a agricultura de precisão (Barbedo, 2018) (Ferentinos, 2018) (Mantovani, 2020)

Banci (2023) e Daniel (2021) fundamentaram e validaram o uso de visão computacional para o acompanhamento e diagnóstico de características no desenvolvimento de hortas e soja, respectivamente, além de Coelho *et al.* (2025) onde foi desenvolvido um sistema para monitoramento de variáveis para coleta de múltiplos dados de extrema importância ao desenvolvimento de plantios, assim como a comunicação desses dados com uma central.

Esses estudos propõem e desenvolvem soluções para o monitoramento de fatores abióticos que afetam o desenvolvimento das lavouras, entretanto, sem abordar fatores bióticos externos relevantes. Esse estudo visa então desenvolver uma aplicação a fim de lidar com fatores bióticos que prejudicam as lavouras, em especial afídeos.

Os afídeos, também conhecidos como pulgões, são as principais pragas da cultura de trigo e demais cereais de inverno (Salvadori *et al.*, 2022). Diversas espécies foram identificadas e algumas delas mereciam atenção especial por causa da transmissão do vírus causal do nanismo-amarelo (Salvadori *et al.*, 2022). A evidência tornou necessário o desenvolvimento de soluções de Agricultura de Precisão (AP) e IoT para lidar com essas pragas.

Como demonstrado por Lins (2020), a implementação de visão computacional na detecção e classificação de insetos é eficiente e precisa, porém esse trabalho lida com amostras em condições ideais de laboratório. Outros trabalhos mostram o uso de armadilhas para atrair


os afídeos para um ambiente controlado e facilitar o processo de identificação a partir de imagens (Lau *et al.*, 2024) (Cesaro Júnior *et. al*, 2022).

Kuchakarian *et al.* (2024) utilizou a plataforma Roboflow e amostras de campo para fazer a identificação de espécies de afídeos. Apesar de a solução considerar um número reduzido de imagens, obteve alta precisão. Entretanto, a solução proposta por ele depende de conexão *Wi-Fi* constante, o que pode não ser viável para grande gama de aplicações.

Diante da relevância do tema, nesse trabalho serão avaliadas diferentes estratégias para identificação de diferentes espécies de pragas na cultura do trigo. Para o estudo foram consideradas as seguintes pragas, como identificado na Figura 1.

- A. Pulgão-verde-pálido (*Metopolophium Dirhodum*);
- B. Pulgão-verde-dos-cereais (*Schizaphis Graminum*);
- C. Pulgão-preto-dos-cereais (*Sipha Maydis*);
- D. Pulgão-da-espiga (*Sitobion Avenae*).

Figura 1 – Espécies de Afídeos Consideradas no Estudo



Tendo isso em vista realizar a classificação de afídeos, foram estudados dois tipos de algoritmos perceptuais: PyramidNet e YOLO (*You Only Look Once*) os quais serão detalhados a seguir.

## Material e Métodos

A pesquisa foi dividida em três etapas, primeiro a aquisição e tratamento de fotos para compor o banco de dados para treino e avaliação das IAs, desenvolvimento dos modelos de inteligência artificial, treino e avaliação.

### *Banco de Dados*

As fotos utilizadas foram em parte as mesmas utilizadas em (Kuchkarian *et al.*, 2024) e outra parte adquiridas na internet. A segmentação e formatação para a implementação do banco de dados para os modelos YOLO foi feita utilizando a plataforma Roboflow.

A fim de verificar a capacidade de expansão e generalização dos modelos foram feitos dois bancos de dados diferentes unicamente pelo número de fotos que compunham o banco de dados, com um banco tendo 166 imagens e o outro tendo 319 imagens. Considerando a precisão superior do modelo com o banco de 319 fotos, a qual será mostrada em resultados e discussões, esse banco também foi testado com suas fotos coloridas (RGB) e exclusivamente cinzas (GR).

### *Modelos*

Como afirmado por Chollet *et al.* (2021) redes neurais convolucionais (CNN), são a melhor escolha para dados perceptuais e Lins *et al.* (2020) demonstrou a eficácia desses na detecção e classificação de afídeos em um ambiente controlado. A fim de verificar a aplicação para o campo foram comparados modelos de Classificação de Imagem (PyramidNet) de Detecção de Objetos (YOLO).

PyramidNet é uma abordagem proposta em Han *et al.* (2017) para implementação de redes neurais convolucionais profundas (DCNNs – *Deep Convolutional Neural Networks*) em classificação de imagens, modelos desse tipo fazem análises globais das fotos, olhando somente para o todo ao invés de partes distintas da imagem. As DCNNs são pilhas compostas por um grande número de camadas de redes convolucionais e realizam a redução da amostragem ao longo da dimensão espacial por meio de agrupamento para separar e analisar características diferentes da imagem. A principal diferença da família PyramidNet é que o número de canais aumenta gradualmente, em vez de manter a dimensão até que uma unidade residual com redução da amostragem apareça. Como resultado possui capacidade de generalização superior em comparação com as redes residuais originais (Han *et al.*, 2017).

A segunda abordagem utiliza algoritmos de detecção de objetos YOLO (Redmon *et al.*, 2016) (Ultralytics, 2025), que se difere dos modelos de classificação de imagem por fazer uma análise local das fotos, separando ela em células que são analisadas individualmente, tanto de forma isolada quanto sendo relacionadas com as células vizinhas, assim analisando de forma independente diversas partes da mesma imagem. A família de modelos YOLO são amplamente utilizados pela fácil implementação e alto desempenho em diversas tarefas. Foram testados os modelos YOLOv8, YOLOv11 e YOLOv12, todos nas configurações *nano* (*n*), *medium* (*m*), *large* (*l*) e *extra large* (*x*), o tamanho altera o número máximo e mínimo que o modelo pode ter, afetando sua precisão, tamanho e tempo de inferência.

### *Implementação*

O PyramidNet foi implementado em Python utilizando a biblioteca PyTorch e os modelos YOLO foram implementados em Python utilizando a biblioteca própria da Ultralytics. Todos os treinos foram realizados no Cluster Drummond do Instituto Mauá de Tecnologia (IMT) utilizando GPU AMD.

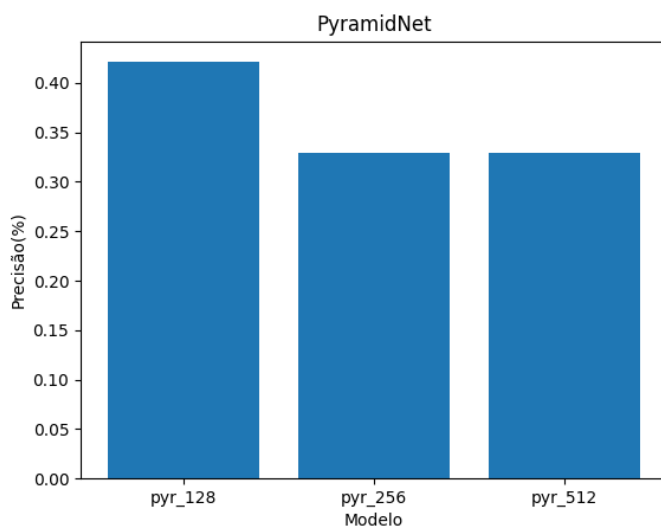
## Resultados e Discussão

Em todos os testes o banco de dados foi separado em 90% do banco para treino e 10% para validação.

### *PyramidNet*

Os modelos PyramidNet apresentaram desempenho abaixo do ideal com a precisão máxima sendo do modelo mais raso, com 128 mapas de características, marcando cerca de 41% de precisão, como mostrado na Figura 2.

Figura 2 - Precisão PyramidNet



A baixa precisão se dá pela natureza do modelo de classificação de imagem, que analisa a imagem de uma forma global, na Figura 3 (a) é mostrado um grupo de pulgões e na Figura 3 (b) um pulgão da mesma espécie, porém isolado. O modelo de classificação não é capaz de identificar que em ambas as fotos contém a mesma espécie de pulgão, simplesmente pela presença de um aglomerado de pulgões.

Figura 3 – Imagens da Espécie Sitobion Avenae

(a) Afídeos agrupados



(b) Afídeo isolado




## YOLO

No primeiro teste foi comparado o desempenho do modelo YOLO com um banco de dado menor contra um banco expandido, esse teste foi usado o modelo v12, com fotos coloridas, sem pesos pré treinados, no tamanho *extra large* (*x*). O modelo com o menor banco de dados teve como precisão máxima 39,01% na porção para validação, enquanto o modelo com o maior banco de dados teve precisão máxima de 55,87%. Esse resultado já implica que o aumento do banco de dados traz benefícios para o modelo, contanto que a expansão do banco de dados conte com imagens semelhantes às já existentes e, para o caso de imagens diferentes que imagens o suficiente sejam providenciadas para o modelo conseguir aprender os novos padrões, como consequência aumentar a competência do modelo girará em torno de expandir o banco de dados. Dado os resultados acima os testes seguintes foram realizados com o banco expandido.

Em seguida foi comparado a precisão do modelo v12 nos tamanhos *nano* (*n*), *medium* (*m*), *large* (*l*), *extra large* (*x*), sem pesos pré treinados, em relação à bancos de dados cinza (GR) e colorido (RGB), a fim de determinar se as cores na imagem são realmente importantes para a classificação dos afídeos, como ilustrado na Figura 4.


Figura 4 - Precisão GR versus RGB



Nota-se que, salvo os modelos no tamanho *m*, os modelos com imagens coloridas tem melhor desempenho em relação a sua contraparte em cinza, sendo a maior precisão de 55,86% do modelo RGBx e menor precisão de 48,56% do modelo GRl, válido também notar a alta precisão do modelo RGBl com 55,30% de acerto, que apesar de ser um modelo menor e teoricamente menos preciso teve resultado similar à sua versão *extra large*. Observou-se assim que as cores nas imagens são elementos importantes para determinação das pragas


Foi realizado também o mesmo conjunto de teste, porém utilizando pesos pré-treinados (pt), que são parâmetros pré-determinados para a estrutura do modelo providos pela própria Ultralytics, como mostrado na Figura 5.

Figura 5 - Modelos com pesos Pré Treinados



Nessa instância todos os modelos com imagem colorida superaram suas contrapartes em cinza, sendo a precisão máxima de 66,41% do modelo RGBl, e pior precisão do modelo GRx com 59,25% de acerto. Dado que todos os modelos com pesos pré treinados tiveram desempenho superior aos modelos com pesos de inicialização aleatória e praticamente todos os modelos com fotos RGB superaram os bancos GR, foi realizado mais um conjunto de testes utilizando fotos RGB com aumento de dados, indicado por “+”, o aumento de dados recria o banco de dados original com mudanças determinadas antes do treino, aumentando o banco de tal forma que a precisão final do modelo aumente. Para o aumento de dados foram utilizados espelhamento horizontal e vertical, rotação entre  $-15^\circ$  e  $+15^\circ$  e cisalhamento vertical e horizontal entre  $-15^\circ$  e  $+15^\circ$  (Figura 6).


Figura 6 - Modelos com aumento de dados



Salvo os modelos n, todos os modelos com aumento de dados tiveram desempenho superior em relação aos modelos sem esse tratamento de dados, sendo a precisão máxima de 67,37% do modelo RGBx+ e pior desempenho do modelo RGBn+ com 64,23% de precisão. Conclui-se então que a melhor configuração para os dados, são fotos coloridas com aumento de dados.

Como teste final para família de modelos YOLO, foi feito a comparação entre modelos v8 e v11, todos com fotos RGB, pesos pré treinados e aumento de dados (Figura 7).

Figura 7 - Precisão modelos v8 e v11



O modelo v11 superou o modelo v8 em todas as instâncias salvo no modelo *m*, a precisão máxima foi do modelo l+v11 com 71,69% de precisão, superando todos os testes do modelo v12, sendo assim o modelo mais preciso para a detecção de pragas é o modelo YOLOv11 (*large*), treinados com pesos pré treinados e com aumento de dados.

## Conclusões

Conclui-se então que modelos de classificação de imagem não tem a capacidade de detectar de forma eficiente as pragas avaliadas, de qualquer tipo, nas lavouras de trigo. Além disso o modelo YOLO, em especial o modelo YOLOv11 *large*, é o modelo mais indicado para análise embarcada das lavouras em campo, tanto pela sua precisão quanto tempo de inferência por imagem, e dada ainda a facilidade de expansão do modelo com nova imagens sem apresentar um relativo grau de dificuldade de acesso e implementação. Assim, recomenda-se para trabalhos futuros o desenvolvimento de uma solução que considere esses fatores em suas previsões.

## Agradecimentos

O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Brasil, por meio de bolsa de Iniciação Científica concedida por meio do processo 2024/08406-0.

Adicionalmente o projeto contou com o suporte de pesquisadores participantes no projeto de pesquisa “Estimando o rendimento do trigo utilizando modelagem de cultivos: Assimilação de dados *in-situ*”. Trata-se de Projeto de Pesquisa Regular – FAPESP 2024/01308-3 cujo professor responsável é o Dr. Jayme Garcia Arnal Barbedo, Pesquisador da Embrapa Agricultura Digital.

Por fim, gostaríamos de agradecer à FAPESP, pela aquisição do cluster de computadores usando RTI (Reserva Técnica Institucional) por meio do processo 2022/14397-9. O cluster foi utilizado para permitir o processamento dos algoritmos de classificação de imagens.

## Referências Bibliográficas

Banci, Ricardo Cabral; Martins, Fernando de Almeida; Pires, Rogério Cassares; Coelho, Alessandra Dutra; ASSIS, Wânderson de Oliveira. **Deteção e medição do crescimento de plantação por processamento de imagens - uma aplicação integrada ao Smart Campus e à horta automatizada do IMT**. São Paulo: Instituto Mauá de Tecnologia, 2025. 9 p. Disponível em: <https://maua.br/files/banci-martins-1702303589.pdf>. Acesso em: 19 out. 2025.

Barbedo, J. G. A. (2018) **Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification**. Computers and Electronics in Agriculture, v. 153, p. 46-53.

Coelho, A. D.; Dias, B. G.; Assis, W. O.; Martins, F. A.; Pires, R. C. **Monitoring of Soil Moisture and Atmospheric Sensors with Internet of Things (IoT) Applied in Precision Agriculture**. In: 2020 XIV Congreso de Tecnología, Aprendizaje y Enseñanza de la Electrónica (XIV Technologies Applied to Electronics Teaching Conference) (TAEE), 2020, Porto. 2020 XIV Technologies Applied to Electronics Teaching Conference (TAEE), 2020. p. 1. Disponível em: <https://doi.org/10.1109/TAEE46915.2020.9163766>.

Cesaro Júnior, T.; Rieder, F.; Di Domênico, J. R., Lau, D. (2022) **InsectCV: A system for insect detection in the lab from trap images**, Ecological Informatics, v. 67, 101516. <https://doi.org/10.1016/j.ecoinf.2021.101516>.

Chollet, François. **Deep Learning with Python**. 2. ed. Shelter Island (MA): Manning Publications, 2021. 504 p. ISBN 978-1-61729-686-4.

Daniel, Pedro Henrique Rodriguez; Assis, Wânderson de Oliveira; Pires, Rogério Cassares; Martins, Fernando de Almeida. **Monitoramento do crescimento de plantação por processamento de imagens – uma aplicação integrada ao Smart Campus e à horta automatizada do IMT**. São Paulo: Instituto Mauá de Tecnologia (IMT) / Escola de Engenharia Mauá (EEM-CEUN-IMT), 2021. 10 p. Disponível em: <https://maua.br/img/upload/daniel-assispdf-1645644996.pdf>. Acesso em: 19 out. 2025.

Ferentinos, K. P. (2018) Deep learning models for plant disease detection and diagnosis. Computers and Electronics in Agriculture, V. 145, P. 311-318.

Han, D.; Kim, J.; Kim, J. **Deep Pyramidal Residual Networks**. arXiv, 2017. Disponível em: <https://arxiv.org/abs/1610.02915>. Acesso em: 28 set. 2025.

Kuchkarian, O.C; **Desenvolvimento De Algoritmos De Processamento de Imagens Para Identificação de Pragas Em Lavouras de Trigo**. 2024. Relatório de Iniciação Científica – Instituto Mauá de Tecnologia, São Caetano do Sul, 2024. Disponível em: <https://maua.br/files/kuchkarian-assis-1734100540.pdf>. Acesso em 15 de outubro de 2025.

Lau, Douglas; Cesaro Júnior, Telmo de; Rieder, Rafael, 2024, **InsectCV: um sistema para detecção de insetos em laboratório a partir de imagens de armadilhas**. Disponível em: <https://doi.org/10.48432/OZOFMR>, Redape, V1.



Lins, Elison Alfeu; Rodriguez, João Pedro Mazuco; Scoloski, Sandy Ismael; Pivato, Juliana; Lima, Marília Balotin; Fernandes, José Maurício Cunha; Pereira, Paulo Roberto Valle da; Lau, Douglas; Rieder, Rafael. **A method for counting and classifying aphids using computer vision** *Computers and Eletronics in Agriculture*, 169, 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169919306039>. Acesso em: 28 set. 2025.

Mantovani, Evandro Chartuni; Miranda, Rubens Augusto de; Landau, Elena Charlotte; Passos, Alexandre Martins Abdão dos, 2020, **A agricultura de precisão no contexto do sistema de produção: lucratividade e sustentabilidade**. Embrapa Milho e Sorgo, Sete Lagoas, MG. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1124732/1/Bol-209.pdf>.

Redmon, J.; Divvala, S.; Girshick, R.; Farhadi, A. You Only Look Once: Unified, Real-Time Object Detection. In: IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, Las Vegas. **Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. Las Vegas, NV, USA: IEEE, 2016. p. 779-788. <https://doi.org/10.1109/cvpr.2016.91>.

Salvadori, J.R.; Marsaro Junior, A.L.; Suzana-Milan, C.S.; Lau, D.; Engel, E.; Pasini, M.P.B.; Pereira, P.R.V. da S. **Pragas da cultura do trigo**. Passo Fundo: Embrapa Trigo, 2022. 63 p. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1148374/1/Documentos-200-online-VFinal-ODS.pdf>. Acesso em: 19 out. 2025.

Ultralytics. **Modelos destacados**. *Ultralytics Docs*, 2025. Disponível em: <https://docs.ultralytics.com/models/#featured-models> Acesso em: 28 set. 2025.