

## **MODELO DEEP LEARNING PARA O RECONHECIMENTO DE PLANTAS DANINHAS EM CULTURAS AGRÍCOLAS**

Filipi Mesquita Machado<sup>1</sup>; Estéfani Sulzbach<sup>2</sup>; William Augusto Ellert Kroth<sup>3</sup>; Ismael Scheeren<sup>4</sup>,  
Catarine Markus<sup>5</sup>

Palavras-chave: Inteligência artificial, aplicação localizada de herbicidas, *You Only Look Once*, *Machine learning*, identificação de plantas daninhas.

### **Introdução**

O avanço das técnicas em agricultura de precisão tem promovido o uso de estratégias de alta tecnologia associadas à Inteligência Artificial (IA), como *machine learning* e *deep learning*, que possibilitam o controle localizado de plantas daninhas (Adhinata et al., 2024). Isso contribui para a redução de custos, maior eficiência no controle e redução da seleção de populações resistentes aos herbicidas (Evans et al., 2016). No contexto atual das áreas de terras baixas do Rio Grande do Sul (RS), caracterizadas por crescente diversidade de culturas e espécies de plantas daninhas (Goulart et al., 2020), essas tecnologias poderão apresentar grande importância. Essa diversidade tem se intensificado com a introdução da cultura da soja em áreas tradicionalmente cultivadas com arroz irrigado, o que aumenta a complexidade do manejo, sobretudo em sistemas de rotação e sucessão de culturas.

Dentre as novas tecnologias destaca-se a arquitetura da rede neural convolucional profunda YOLO (*You Only Look Once*) desenvolvida por Redmon em 2016. Esse algoritmo permite a detecção de objetos em tempo real, com alta velocidade de processamento, precisão e capacidade de identificar objetos sobrepostos. Essas características são fundamentais para a detecção e controle localizado de plantas daninhas. No entanto, a YOLO é um algoritmo que necessita da anotação de um grande volume de dados. Assim, a geração de banco de dados anotados se torna essencial para o treinamento da rede neural como também o aumento da assertividade na detecção de objetos. Considerando que culturas como soja e milho passaram a ser cultivadas em rotação em ~50% das áreas que cultivam arroz irrigado, os bancos de dados gerados nesses sistemas podem ser aproveitados para aprimorar a detecção de plantas daninhas também na cultura do arroz. Dessa forma, o objetivo do presente estudo foi avaliar o desempenho da rede neural YOLOv8 para detecção de plantas daninhas em tempo real nas culturas de soja e milho.

### **Material e Métodos**

O banco de imagens total foi composto por mais de 5.000 imagens RGB (vermelho, verde e azul) para detecção de soja, milho e plantas daninhas. As imagens foram obtidas em áreas agrícolas do RS. As imagens foram obtidas com câmera Sony (SONY Corporation, Minato,

---

<sup>1</sup> Estudante de graduação em Agronomia, Universidade Federal do Rio Grande do Sul, UFRGS, Porto Alegre, filipimesqmach@gmail.com.

<sup>2</sup> Doutoranda em Fitotecnia, Universidade Federal do Rio Grande do Sul, UFRGS, Porto Alegre, estefanisulzbach@gmail.com.

<sup>3</sup> Estudante de graduação em Agronomia, Universidade Federal do Rio Grande do Sul, UFRGS, Porto Alegre, williamkroth64@gmail.com

<sup>4</sup> Engenheiro mecânico, Me, Accore Automação & Controle Industrial, Porto Alegre, ismael.scheeren@accore.com.br.

<sup>5</sup> Professora Adjunta, Dra, Universidade Federal do Rio Grande do Sul, UFRGS, Porto Alegre, catarine.markus@ufrgs.br.

Tokyo, Japan) a ~1,0 metros de altura do solo. As quatro áreas selecionadas para coleta de imagens apresentam infestação natural das principais plantas daninhas relacionadas a cultura da soja e do milho. O banco de imagens foi composto principalmente pelas espécies de caruru (*Amaranthus* spp.), buva (*Conyza* spp.), trapoeraba (*Commelina* spp.), corriola (*Ipomoea* spp.), poaia branca (*Richardia brasiliensis*), picão-preto (*Bidens pilosa*), guanxuma (*Sida rhombifolia*), leiteiro (*Euphorbia heterophylla*), papuã (*Brachiaria plantaginea*), capim-pé-de-galinha (*E. indica*) e milhã (*Digitaria horizontalis*), as demais plantas daninhas com menor frequência nas áreas, foram classificadas como dicotiledôneas (folhas largas) ou monocotiledôneas (folhas estreitas), de acordo com a espécie. Para a soja foram obtidas imagens nos estádios fenológicos de VE a R1, para o milho entre VE a V6-V7. O banco de dados utilizado apresenta complexidade e robustez, pois as imagens foram obtidas em diversas condições de iluminação, cobertura do solo (com e sem palha) e distintos estádios fenológicos das plantas.

A rede neural selecionada para o reconhecimento de plantas daninhas foi a YOLO (versão 8 – YOLOv8) devido a sua acurácia e velocidade em detectar objetos em tempo real. Como a YOLO é uma arquitetura de aprendizado supervisionado foi necessária a anotação das imagens coletadas a campo para o treinamento da rede. A anotação das imagens foi realizada através da criação de caixas delimitadoras (*bounding boxes*) no entorno de cada planta das 2637 imagens, que foram selecionadas do banco de dados total para compor o *dataset*. Na anotação foi atribuída uma classe representativa para cada planta alvo, o que gerou as instâncias de cada classe. As classes utilizadas foram soja, milho, caruru, buva, trapoeraba, folhas largas e folhas estreitas. As anotações das imagens foram realizadas manualmente com o software livre, de interface gráfica denominado LabelImg. O *dataset* final foi dividido 80% para imagens de treinamento, 10% para teste e 10% para validação. Assim, 2073; 281; e 283 imagens foram utilizadas para treinamento, teste e validação, respectivamente. A avaliação do desempenho do algoritmo foi realizada através da obtenção das métricas de Precisão, Recall e a média da AP (mAP). Para a verificação do desempenho da YOLOv8 foi gerada matriz de confusão para observar as predições feitas pela rede neural versus a predição esperada. A precisão média para cada classe foi determinada através da curva de Precisão-Recall para todas as classes (Henderson; Ferrari, 2017).

## Resultados e Discussão

O *dataset* do presente estudo teve 2637 imagens e gerou um total de 12328 instâncias (Figura 1). As instâncias foram geradas a partir da diversidade de espécies, tamanhos e formas presentes no *dataset*. O desempenho geral do modelo foi de 0,69 (mAP50) e se aproxima dos resultados verificados em estudos realizados com bancos de dados restritos a poucas classes e com baixa diversidade de cenários (Barnhart et al., 2022; Pérez-Porras et al., 2023). Salienta-se que normalmente quanto maior a diversidade do *dataset* e número de classes, maior é a complexidade do *dataset* e maior a dificuldade para o treinamento da rede, no entanto, maior a proximidade para o reconhecimento em ambiente real.

Entre as diferentes classes utilizadas no presente trabalho verificou-se que o milho obteve o maior valor de Precisão, que correspondeu a 0,82, seguido pela buva com 0,74, folha larga com 0,71 e caruru com 0,70 (Figura 1). As demais classes ficaram abaixo de 0,70, sendo que a classe folha estreita apresentou o menor valor de Precisão, que correspondeu a 0,56 (Figura 1). O Recall é uma métrica que indica o percentual de predições que estão sendo identificadas corretamente. Cabe salientar que na anotação manual foi constatada maior complexidade de tamanhos, formas e morfologia de plantas para a classe folha estreita. O que sugere que para a cultura do arroz as marcações devem ser feitas de forma bastante precisa. A melhoria dos parâmetros pode ser obtida com o aumento do *dataset* para essa classe.

A)

Classes	Instâncias	Precisão	Recall	mAP50
Soja	2316	0,68	0,73	0,73
Milho	225	0,82	0,63	0,74
Caruru	1338	0,70	0,68	0,73
Buva	485	0,74	0,74	0,66
Trapoeiraba	323	0,61	0,61	0,67
(FL)	4751	0,71	0,62	0,69
(FE)	2890	0,56	0,61	0,59
Todas	12328	0,68	0,64	0,69

B)




Figura 1. A) Quadro com as classes avaliadas, número de instâncias e das métricas (Precisão, Recall e mAP50) utilizadas para avaliar o desempenho da rede neural YOLOv8. B) Matriz de confusão.

Uma matriz de confusão contém informações de objetos reais e esperadas de um sistema de categorização. A classe folha larga apresentou o maior número (3191) de predições corretas. Seguido pelas classes de folha estreita (2015) e soja (1869) (Figura 1-B). Cabe salientar que o aumento do banco de dados para cada uma das classes é importante para o aumento do desempenho da rede neural nas detecções de plantas. Na figura 2 é possível verificar as marcações realizadas pela rede neural após o treinamento para as culturas de soja (Figura 2-A) e milho (Figura 2-B). Os resultados evidenciam a capacidade da YOLOv8 em diferenciar plantas daninhas de culturas como também a diferenciação entre plantas daninhas.

A)



B)

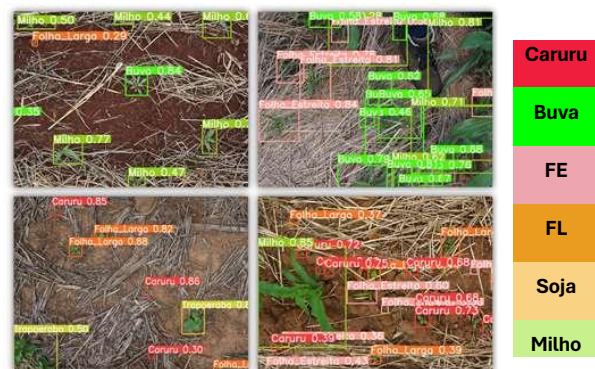


Figura 2. Identificação da cultura e plantas daninhas pela YOLOv8 após o treinamento. Em A e B estão representadas quatro imagens marcadas pela YOLOv8 em áreas de soja e milho, respectivamente. As cores representam as diferentes classes reconhecidas pelo algoritmo.

Na cultura da soja é possível verificar a presença de plantas daninhas como a buva e caruru (Figura 2-A). Para a cultura do milho, conforme figura 2-B, foram verificadas marcações assertivas de milho e folha estreita na mesma imagem, essa diferenciação é complexa visto que ambas pertencem a família das Poáceas. Assim, é possível verificar que a similaridade entre plantas daninhas e culturas não limitou a detecção correta realizada pela YOLOv8, bem como o

reconhecimento de plantas sobrepostas pela rede. Desta forma, o *dataset* construído no presente estudo pode ser adaptado e treinado para lavouras de arroz, principalmente levando-se em consideração a diversidade de espécies em terras baixas. Esses aspectos são fundamentais para utilização dessa ferramenta em sistemas embarcados e para aplicação localizada de herbicidas, que consistem nas próximas etapas de teste do presente trabalho.

## Conclusões

Esse trabalho é pioneiro no Brasil na aplicação da arquitetura de *deep learning* YOLOv8, lançada em 2023, para reconhecimento de plantas daninhas. Ainda, esse foi o primeiro estudo a esse modelo para a detecção de plantas daninhas em áreas de soja e milho, de forma conjunta em um único modelo. Isso aumenta a complexidade do *dataset* de espécies estudadas e demonstra a robustez da abordagem adotada. Além disso, indica a possibilidade de expansão para outras culturas e outros sistemas produtivos, como é o caso do arroz irrigado e outros cultivos conduzidos em terras baixas.

As anotações de imagens para modelos supervisionados representam um trabalho minucioso, com necessidade de profissionais capacitados para reconhecimento das espécies e com necessidade de tempo para anotações manuais. Considera-se que esses bancos de dados possam ser um diferencial para novos estudos e obtenção de métricas superiores. O modelo desse estudo será aperfeiçoado e posteriormente testado a campo para aplicação localizada de herbicidas em tempo real.

## Agradecimentos

Agradecemos a Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul–FAPERGS pelo financiamento desta pesquisa (processos nº 22/2551-0000394-0 e nº 24/2551-0001163-3) e ao CNPQ pela concessão de bolsa de doutorado.

## Referências

- ADHINATA, F. D. et al. A comprehensive survey on weed and crop classification using machine learning and deep learning. **Artificial Intelligence in Agriculture**, v. 13, p. 45-63, 2024.
- BARNHART, I. H. et al. Use of open-source object detection algorithms to detect Palmer amaranth (*Amaranthus palmeri*) in soybean. **Weed Science**, v. 70, n. 6, p. 648–662, 2022.
- EVANS, J. A. et al. Managing the evolution of herbicide resistance. **Pest Management Science**, v. 72, n. 1, p. 74–80, 2016.
- GOULART, Rafael Ziani et al. Cropping poorly-drained lowland soils: Alternatives to rice monoculture, their challenges and management strategies. **Agricultural Systems**, v. 177, p. 102715, 2020.
- HENDERSON, P.; FERRARI, V. End-to-end training of object class detectors for mean average precision. **arXiv**, 16 mar. 2017. Disponível em: <<http://arxiv.org/abs/1607.03476>>. Acesso em: 30 mar. 2024
- PÉREZ-PORRAS, F. J. et al. Early and on-ground image-based detection of poppy ( *Papaver rhoeas* ) in wheat using YOLO architectures. **Weed Science**, v. 71, n. 1, p. 50–58, 2023.
- REDMON, J. et al. You Only Look Once: Unified, Real-Time Object Detection. 2016 **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. Disponível em: <<http://ieeexplore.ieee.org/document/7780460/>>. Acesso em: 26 jul. 2023.