

Engenharia Agrícola

Uso de inteligência artificial e visão computacional para contagem de flores de calêndula em imagens de alta resolução

Silmara Gonçalves Dias - 3º modulo de Engenharia Agrícola, UFLA.

Thiago Orlando Costa Barboza - Coorientador, Pós-graduando do Departamento de Agricultura (DAG), UFLA.

Girley Valdes Fernandez - Pós-graduanda do Departamento de Agricultura (DAG), UFLA.

Franklin Daniel Inácio - Pós-graduanda do Departamento de Agricultura (DAG), UFLA.

Rai Fernandes Queiroz Alves - Pós-graduando do Departamento de Agricultura (DAG), UFLA.

Adão Felipe dos Santos - Orientador, professor do Departamento de Agricultura (DAG), UFLA. - Orientador(a)

Resumo

A *Calendula officinalis* L. é caracterizada por suas propriedades antibacterianas, antioxidantes, antissépticas e culinárias, tendo alto valor agregado por seus óleos essenciais. No entanto, a produção enfrenta desafios relacionados às perdas na colheita, causadas tanto pela definição incorreta do momento ideal quanto pela predominância de métodos manuais, que tornam o processo oneroso e dependente de mão de obra. Nesse contexto, o uso de visão computacional associada a imagens de alta resolução surge como uma alternativa promissora para reduzir perdas e apoiar os produtores na tomada de decisão sobre o ponto de colheita. Portanto, o objetivo do trabalho foi avaliar a eficiência de duas arquiteturas de You Only Look Once (Yolo) versão 8 na contagem de flores de calêndula utilizando imagens de alta resolução. O experimento foi realizado na Universidade Federal de Lavras em um campo de 805 m², utilizando um drone DJI Mavic 3 multiespectral para a captura de imagens RGB a 20 metros de altura. As imagens foram processadas e recortadas com formato de 640x640 pixels, sendo rotuladas no software LabelImg e divididas em 70% para treinamento e 30% para teste. Foi utilizado o modelo YOLOv8-nano(2,7milhoes de parâmetros) e o YOLOv8-XLarge (58,8 milhoes de parâmetros) treinados no Google Colab com GPU T4 por 250 épocas. Assim, a eficiência dos modelos foi comparada através das métricas de avaliação de Precisão e mAP50. Os modelos apresentaram diferentes resultados médios para Precisão e mAP50 com valores de aproximadamente 0,35 e 0,63 para o modelo Nano e X-large em ambas as métricas. Além disso, a arquitetura Nano apresentou menor mediana quando comparado com X-large, com maior variação das métricas. Esses resultados refletem em maior número de épocas que o modelo precisa para realizar o treinamento. Ou seja, apesar da rápida convergência inicial o reduzido número de camadas profundas (Yolov8 nano) faz o modelo necessitar de maior número de épocas (aproximadamente 100) para extrair informações precisas dos alvos. Por outro lado, modelos com maior número de camadas profunda conseguem extrair maior número de informações (10 épocas) e rapidamente apresentam convergência. Portanto, a arquitetura X-large apresentou considerável melhor performance quando comparado ao Nano refletindo no seu potencial para uso na tomada de decisão do momento ideal de colheita, principalmente quando associado a imagens de alta resolução.

Palavras-Chave: Deep learning, calêndula, agricultura de precisão.

Instituição de Fomento: CAPES, CNPQ e FAPEMIG

Link do pitch: <https://youtu.be/YU52tjXm59k>