

CONTAGEM AUTOMÁTICA DE FRUTOS DO CAFEEIRO COM BASE EM IMAGENS DE CELULAR E DEEP LEARNING

Miquéias Henrique Pereira¹; Domingos Sárvio Magalhães Valente²; Gabriel Dumbá Monteiro de Castro³
Fome zero e agricultura sustentável
Pesquisa

Introdução

No estado de Minas Gerais - Brasil, grande parte do café é cultivado em áreas montanhosas, onde a colheita é manual ou semimecanizada, o que dificulta a identificação da variabilidade espacial da produtividade. Esse conhecimento é fundamental para a adoção de práticas de Agricultura de Precisão, especialmente na recomendação de fertilizantes em taxas variáveis, visando maior lucratividade, redução de custos e menor impacto ambiental.

Os métodos tradicionais de estimativa de produtividade, geralmente, demandam a contagem manual de frutos de café, sendo dispendiosos e limitados quanto à resolução espacial. Nesse contexto, técnicas de Deep Learning aplicadas a imagens capturadas por câmeras de celular surgem como alternativa promissora, permitindo a contagem automática de frutos de forma rápida, precisa e de baixo custo.

Objetivos

Desenvolver, avaliar e comparar modelos de Deep Learning usando Detectron2 e YOLOv8n para contagem automática de frutos de café com base em imagens digitais obtidas por câmeras de celular.

Material e Métodos ou Metodologia

O estudo foi conduzido no viveiro de café da Universidade Federal de Viçosa (UFV), localizado no município de Viçosa-MG, na região cafeeira das Matas de Minas, em uma área cultivada com café arábica (*Coffea arabica* L.).

Entre fevereiro e março de 2024, foram coletadas 80 imagens de ramos plagiotrópicos contendo do 1º ao 5º internódio produtivo. Os frutos presentes nas imagens foram segmentados manualmente, e o conjunto foi dividido em 80% para treinamento e 20% para validação dos modelos. O treinamento foi realizado por meio das bibliotecas Detectron2 e Ultralytics (YOLOv8n), ambas baseadas em redes neurais profundas voltadas à detecção de objetos. A avaliação dos modelos foi realizada por meio das métricas de desempenho: precisão média (AP), precisão média a 50% (AP50), precisão média de 50 a 95% (AP50-95), recall e F1-score.

Resultados e/ou Ações Desenvolvidas

Após o treinamento dos modelos, foram geradas imagens de teste com as detecções de ambos os modelos (Detectron2 e YOLOv8n) para verificação visual dos resultados (Figura 1).

Figura 1. Imagem com detecções dos modelos Detectron2 e YOLOv8n.



Fonte: O autor.

O modelo treinado com o Detectron2 apresentou AP de 93,98% e AP50 de 96,90%, indicando bom desempenho em sobreposições permissivas. No entanto, a AP50-95 foi de 81,70%, sugerindo perda de desempenho sob critérios mais rigorosos. O recall foi de 84,60%, e o F1-score, que combina precisão e recall, atingiu 89,02%. Já o modelo YOLOv8n superou o Detectron2 em todas as métricas: AP de 99,88%, AP50 de 98,30% e AP50-95 de 82,69%. O recall foi de 94,95% e o F1-score alcançou 97,35%, evidenciando maior equilíbrio entre acertos e abrangência.

Conclusões

Os resultados indicam que o YOLOv8n realiza detecções mais precisas e identifica um maior número de frutos corretamente, o que é fundamental para a contagem automática voltada à estimativa de produtividade. Dessa forma, embora ambos os modelos apresentem resultados promissores, o YOLOv8n destacou-se com melhor desempenho geral, sendo mais indicado para aplicações em Agricultura de Precisão, por aliar acurácia elevada, velocidade e menor risco de erros na detecção.

Apoio Financeiro