

Avaliação de redes neurais profundas no reconhecimento de doenças e pragas de plantas em dispositivos portáteis

Camila Ribeiro de Moraes (IC)

Hugo Vinicius Leão e Silva (PQ)

PIBITI
Câmpus Anápolis

r.camila@academico.ifg.edu.br

hugo.vinicius@ifg.edu.br

Palavras Chave: Processamento de Imagem Digital; Aprendizado de Máquina; Visão Computacional.

Introdução

Doenças e pragas são fatores determinantes na qualidade de plantas e, conseqüentemente, na produtividade das lavouras. Neste sentido, realizar um controle dessas pestes em plantas deve ser uma tarefa contínua na tentativa de diminuir as perdas; principalmente ao lidar com agricultura de pequena extensão, tal como a agricultura familiar, de subsistência e orgânicos.

Deste modo, conhecer sobre pragas e doenças em plantas é de suma importância para o desenvolvimento da agricultura. Sendo assim, buscar uma solução eficiente de visão computacional para identificar pragas e doenças, atribuída à tecnologia de baixo custo (e de forma portátil), pode auxiliar no controle e entendimento acerca dessas enfermidades, sendo este, o objetivo deste trabalho.

Metodologia

Considerando todo o arcabouço necessário para se aplicar determinada solução, utilizou-se de um cronograma para facilitar os estudos acerca da pesquisa.

- Realizar o levantamento e escolha de uma base de dados contendo fotos de doenças e pragas de plantas.
- Avaliar estratégias de criação de um modelo de visão computacional com base em redes neurais pré-treinadas.
- Utilização da biblioteca do TENSORFLOW para criação desses modelos.
- Avaliar o desempenho na aplicação e o esforço computacional.
- Adaptar o modelo de visão computacional ao TENSORFLOW LITE, para portabilidade, e avaliá-lo.
- Implementar o modelo final em um Raspberry Pi 4 e Coral AI.

Resultados e Discussão

Cada modelo de visão computacional foi avaliado mediante diferentes modos de processamento de

imagem. E desta forma, optando-se por métodos de normalização quanto a brilho, contraste e afins, chegou-se aos seguintes resultados, considerando a métrica da acurácia e o tempo de inferência com o Coral AI, acelerador para a tarefa.

Tabela 1. Resultados

Modelo	Acurácia	Inferência(ms)
CNN	83%	22,3
InceptionV3	90%	73
MobileNet	91%	11,2
MobileNetV2	87%	12,2
NasNetMobile	81%	14,5

Conclusões

Diante de todo o processo de análise da solução, chegou-se a um consenso de que a rede neural MobileNet obteve uma melhor proporção diante da sua taxa de acerto, 91%, e seu tempo de inferência, 11,2 milissegundos.

Agradecimentos

KAGGLE. Kaggle. Disponível em: <<https://kaggle.com>>

TENSORFLOW. TensorFlow. Disponível em: <<https://www.tensorflow.org>>

TENSORFLOW LITE. TensorFlow Lite. Disponível em: <<https://www.tensorflow.org/lite>>

GÉRON, Aurélien. Hands On Machine Learning with Scikit-Learn, Keras and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems.