

RESUMO - CIÊNCIAS AGRÁRIAS - ENGENHARIA AGRÍCOLA

**USO DE REDES NEURAIS CONVOLUCIONAIS PARA O
DESENVOLVIMENTO DE UMA CÂMARA SELETORA DE FRUTOS
APLICADA A CLASSIFICAÇÃO TOMATES**

Pedro Hugo Costa Cruz (phcruz9@gmail.com)

João Célio Luna De Carvalho (joaocelio1301@gmail.com)

Maria Eduarda Penha Ferris (mariapenha@ufrj.br)

Marcus Vinicius Moraes De Oliveira (oliveiraufrj@gmail.com)

Juliana Lobo Paes (juliana.lobop@gmail.com)

Anderson Gomide Costa (andersongc7@gmail.com)

A utilização da visão computacional no setor agrícola, tornou-se uma ferramenta aplicada para otimizar os processos produtivos e aumentar a produtividade agrícola. A Rede Neural Convulacional (CNN) é um dos recursos da visão computacional que possibilita a classificação de produtos agrícolas em função de parâmetros de qualidade, como o estágio de maturação. Este trabalho teve como objetivo desenvolver um dispositivo ótico baseado em um microprocessador Raspberry Pi 5 e CNNs para a classificação de frutos de tomate quanto ao nível de maturação. Os frutos foram classificados nos estágios de maturação: verde, colorido e maduro, sendo utilizadas 300 imagens de frutos de tomates divididas nas 3 classes definidas. Para a aquisição de imagens, foi desenvolvido uma câmara seletora com dimensões de 0,52m de altura e 0,35m de comprimento, contendo no interior um suporte à

uma altura de 0,32m para fixar o Raspberry Pi 5 8Gb, junto a um módulo de câmera, um monitor touch screen e lâmpadas LED no interior da câmara. Para controle da câmara seletora (aquisição e processamento das imagens) foi desenvolvido um algoritmo e interface operacional em linguagem Python. Às CNNs utilizadas para classificação, foram a AlexNet e a MobileNet treinadas por meio da transferência dos dados. Os parâmetros para mensuração do desempenho das CNNs, foram a Acurácia, Loss, Precisão, Sensibilidade (Recall), f1-score e tempo de processamento. Os resultados demonstraram que a câmara seletora em conjunto ao software desenvolvido, provou-se aplicável e eficiente para a classificação dos frutos de tomate quanto ao seu estado de maturação. Em relação ao parâmetro Loss, para a arquitetura AlexNet, houve uma redução gradual até estabilizar os valores próximos de zero nos dados de treinamento, obtendo o menor valor na época 26 (0,027). Já para os dados de teste, o loss acompanhou a curva do treinamento convergindo para valores baixos, o que indica que este apresenta boa capacidade de generalização. Na arquitetura MobileNet, o Loss manteve-se baixo ao longo das épocas durante o treinamento, obtendo o menor valor na época 27 (0,16) indicando aprendizado eficiente. Para os dados de teste, observou-se oscilações e picos elevados, indicando tendência ao overfitting com o modelo ajustando-se bem ao treino, mas sem eficiência na generalização. Em relação a acurácia, para a arquitetura AlexNet foi observado um aumento gradual até 100% tanto para dados de treinamento quanto os de teste, reafirmando a boa capacidade de generalização desta arquitetura. Já para a arquitetura CNN MobileNet foi observado uma estabilização próxima a 100% para os dados de treinamento, porém oscilações ao longo das épocas para as amostras de teste, reafirmaram a tendência de instabilidade desta arquitetura. Neste caso, optou-se pela seleção dos modelos gerados em épocas em que a acurácia foi 100% e o Loss apresentou valores baixos tanto para os dados de treinamento quanto para os dados de teste. Ao analisar às métricas de desempenho da matriz de confusão constatou-se que ambas as CNNs, apresentaram 100% de acerto de classificação das 3 classes, demonstrando boa capacidade de generalização dos modelos selecionados. A AlexNet possibilitou o processamento dos dados em menor tempo (Tempo da AlexNet = 4 min 35 s; Tempo da MobileNet = 7 min 45 s). Concluiu-se que a câmara seletora desenvolvida apresentou capacidade de obter as imagens dos frutos de tomates e classificá-las com 100% de êxito em ambas CNNs, se mostrando como uma alternativa acessível e de fácil operação para classificação de frutos. A CNN AlexNet foi considerada

a arquitetura mais adequada tanto pela análise de capacidade de generalização ao longo das épocas quanto pelo tempo de processamento.

Palavras-chave: palavras chaves: processamento de imagens; visão computacional; pós-colheita.