

**USO DE REDES NEURAS CONVOLUCIONAIS PARA A IDENTIFICAÇÃO
DE TIPOS DE FRUTOS CÍTRICOS**

Jade Signorelli (jade.signorelli@hotmail.com)

Anderson Gomide Costa (andersongc7@gmail.com)

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

Pedro Hugo Costa Cruz (phcruz9@gmail.com)

O avanço da computação em nuvem e o acesso a computadores pessoais com maior capacidade de processamento têm impulsionado a aplicação de redes neurais convolucionais (CNNs) em tarefas complexas de visão computacional, especialmente no processamento de imagens para classificação de objetos. No setor de fruticultura, a utilização de CNNs representa uma alternativa promissora frente aos métodos manuais de classificação, oferecendo maior precisão, rapidez e padronização. Este estudo teve como objetivo implementar e comparar o desempenho das arquiteturas AlexNet e MobileNet na identificação e classificação de frutos cítricos (laranja, limão e tangerina), com base em um banco de 300 imagens públicas, distribuídas igualmente entre as três classes. As imagens foram selecionadas de forma a contemplar diferentes condições de iluminação, ambiente e variações visuais dos frutos, visando à robustez do treinamento. A metodologia incluiu o pré-processamento dos dados, separação dos conjuntos de treino e teste, normalização das dimensões das imagens e implementação dos modelos em Python, com uso de bibliotecas como TensorFlow, Keras e OpenCV. Durante o treinamento, foram utilizadas

métricas como acurácia, precisão, recall e f1-score, extraídas a partir da matriz de confusão, além do monitoramento das curvas de loss e acurácia para avaliação da convergência e overfitting. A AlexNet apresentou acurácia de validação máxima de 71%, com bom desempenho na classe "Limão" (21 acertos e 0 erros de classificação) e desempenho intermediário na classe "Tangerina" (23 acertos e 4 erros de classificação), mas apresentou dificuldades significativas na correta identificação da classe "Laranja" (6 acertos e 16 erros de classificação), o que resultou em um f1-score médio de 0,68. A curva de loss demonstrou indícios de overfitting a partir da 20ª época, com oscilação crescente nas perdas de validação. Já a CNN MobileNet alcançou acurácia de validação de 84% e apresentou melhor equilíbrio entre as classes, melhorando a identificação das imagens da classe "Laranja" (14 acertos e 8 erros de classificação). A matriz de confusão da MobileNet também indicou baixa taxa de erro e consistência nas classificações na classificação das imagens da classe "Tangerina" (25 acertos e 2 erros de classificação) e da classe "Limão" (20 acertos e 1 erro de classificação), que mantiveram altas taxas de acerto. Apesar de apresentar oscilação na resposta do loss do conjunto de dados de validação, a MobileNet manteve f1-score médio de 0,84, refletindo melhor capacidade de generalização. Em termos computacionais, mesmo com exigência um pouco maior de tempo de treinamento, a MobileNet mostrou-se mais eficiente, apresentando desempenho superior em todos os aspectos avaliados. Assim, os resultados indicaram que embora ambas as arquiteturas de CNN sejam capazes de aprender os padrões dos dados de treino, a MobileNet demonstrou maior eficácia na classificação de frutas com características visuais semelhantes, sendo mais adequada para aplicações práticas no contexto agrícola. Conclui-se que a escolha da arquitetura da CNN mais adequada ao conjunto de dados impacta diretamente na performance do modelo, especialmente em cenários com classes visuais muito próximas. Aplicações das arquiteturas em conjuntos de dados mais robustos e balanceados, além da adoção de estratégias como aumento de dados (data augmentation) e validação cruzada podem reduzir a tendência de overfitting e aumentar a capacidade de generalização dos modelos.

Palavras-chave: imagens digitais; deep learning; fruticultura.