

# Aprendizado de Máquina Aplicado a Avaliação da Qualidade de Frutos

## *Machine Learning Applied to Fruit Quality Assessment*

Armano. Barros Alves Junior<sup>1</sup> e Warley Gramacho da Silva<sup>1</sup>

<sup>1</sup> Universidade Federal do Tocantins, Campus Palmas, Tocantins, Palmas

Data de recebimento do manuscrito: 30/08/2023

Data de aceitação do manuscrito: 02/10/2023

Data de publicação: 16/10/2023

**Resumo**— O presente trabalho teve como objetivo explorar o uso de técnicas de visão computacional e aprendizado de máquina para a análise e classificação de frutas, com foco na qualidade e controle pós-colheita. Através da utilização de algoritmos de segmentação e extração de características, foi possível identificar atributos importantes das frutas, como cor, forma e textura, permitindo uma avaliação do fruto. A aplicação de redes neurais artificiais, como o MultiLayer Perceptron e Convolutional Neural Network, possibilitou a classificação automática das frutas com base em suas características físicas, o que facilita a detecção de defeitos. Os resultados obtidos demonstraram o potencial dessas técnicas para a automação do processo de seleção e classificação de frutas, contribuindo para a melhoria da eficiência e qualidade da produção na seleção de frutos.

**Palavras-chave**—Redes Neurais, Aprendizado profundo, Classificação

**Abstract**— *The present research project aimed to explore the use of computer vision and machine learning techniques for the analysis and classification of fruits, focusing on quality and post-harvest control. By employing segmentation and feature extraction algorithms, it was possible to identify important attributes of fruits, such as color, shape, and texture, enabling a more objective and precise evaluation. The application of artificial neural networks, such as the MultiLayer Perceptron and Convolutional Neural Network, allowed for the automatic classification of fruits based on their physical characteristics, facilitating the detection of defects and separation of fruits at different stages of ripeness. The results obtained demonstrated the potential of these techniques for automating the fruit selection and classification process, contributing to the improvement of agricultural production efficiency and quality.*

**Keywords**—*Neural Networks, Deep Learning, Classification*

## I. INTRODUÇÃO

Para garantir a qualidade dos alimentos oferecidos aos consumidores, o Ministério da Agricultura, Pecuária e Abastecimento (MAPA) estabelece padrões de identidade e qualidade para diversas frutas, como laranja, banana, uva e maçã [1]. Esses padrões visam garantir critérios como aparência, tamanho, peso e teor de sólidos solúveis das frutas.

Os autores como [2] e [3] apontam que a seleção e a classificação de frutas é algo que precisa ser desenvolvido em âmbito nacional, pois a decisão humana é subjetiva e pode apresentar falhas, culminando na procura pela automatização pós-colheita. Assim, o desenvolvimento de máquinas e sistemas de classificação tem sido cada vez mais explorado, para atender as exigências do mercado em relação

à qualidade dos produtos alimentícios.

Uma das técnicas de classificação que vem se destacando pela eficiência apresentada na extração e quantificação de modo não destrutivo das características relacionadas à qualidade e controle dos frutos é a visão computacional. Seu objetivo é promover a classificação de produtos de forma mais objetiva. Como destacado por [4], "A visão computacional é um campo interdisciplinar que se concentra em tornar as máquinas capazes de interpretar e entender o mundo visual". Essa ciência estuda as teorias e algoritmos que permitem a extração automática de informações úteis a partir de imagens de objetos ou cenas específicas.

Sistemas de visão computacional podem proporcionar a solução dos mais variados problemas a partir da extração e análise de informações de uma imagem. No caso da aplicação em frutos com atributos de qualidade como cor, forma e textura, o sistema consegue reconhecer esses atributos e relatar irregularidades como doenças, distúrbios e até mesmo o grau de maturação.

A utilização de técnicas de aprendizado de máquina tem

Dados de contato: Armano. Barros Alves Junior, armano.alves@uft.edu.br

se mostrado promissora na análise de frutos, permitindo a identificação de atributos de qualidade como cor, forma e textura, bem como a detecção de doenças e distúrbios. De acordo com [2], "é possível utilizar técnicas de aprendizado de máquina para a classificação automática de frutas com base em suas características físicas". De forma combinatória, as técnicas de visão computacional juntamente com o aprendizado de máquina podem ser aplicadas em diversos contextos, como na produção agrícola e no varejo, melhorando a eficiência do processo de seleção e classificação de frutas.

## II. MATERIAIS E MÉTODOS

Nesta seção, serão apresentados de forma detalhada os materiais e métodos empregados no desenvolvimento e avaliação do modelo de Classificação de Frutos.

### a. Coletar dados e escolha de frutos

A maçã é uma das frutas mais consumidas em todo o mundo, produzida em grande escala em diversas regiões. Isso significa que há muitas informações disponíveis sobre as características e os defeitos das maçãs, o que permite que sejam criados conjuntos de dados ricos e diversificados para o treinamento e validação de algoritmos de Aprendizado de Máquina. Com isso, a maçã será tomando como objeto de pesquisa para avaliação da qualidade, pois utilizando uma determinada fruta será possível obter resultados mais consolidados, além de ser algo que se mostrou uma opção muito interessante e vantajosa, com base na produção [5], a utilização de uma fruta específica, auxilia na catalogação de características para a classificação.

### b. Pré-processamento de imagem

Foram utilizados algoritmos responsáveis pela extração de características e segmentação dos objetos a serem classificados [6]. Tais objetos serão considerados no passo seguinte para o reconhecimento de defeitos. Um dos algoritmos de segmentação utilizados será o *JESG* [6], apropriadamente aplicado para reconhecer os padrões de deterioramento das frutas analisadas. A segmentação por deterioração será realizada através do algoritmo *K-means*, que está entre os algoritmos mais usados para esta finalidade, aperfeiçoado por [7]. Já a segmentação por crescimento de região passará por dois estágios principais, a quantização do espaço de cores (processo de redução de número de cores distintas em uma determinada imagem) onde cada píxel será rotulado pela sua correspondente classe, criando um mapa de classes da imagem e a segmentação espacial responsável por pegar o mapa das classes e aplicar o crescimento de região, conforme descrito por [3]. Enquanto a segmentação utilizando o *JESG* será realizada utilizando o software elaborado por [6].

A Figura 1 mostra o resultado da imagem ao executar algoritmos de segmentação por *K-means*, com a definição de limites entre os segmentos e qualidade dependente dos parâmetros e dados de entrada. Entretanto, a Figura 2 mostra o resultado utilizando o algoritmo *JESG*, os resultados englobam a segmentação multimodal levando em consideração cores, texturas e luminosidade, a possibilidade



**Figura 1:** Imagem da maçã ao passar pelo algoritmo de segmentação por *K-means*.



**Figura 2:** Imagem da maçã ao passar pelo algoritmo *JESG*.

de hierarquia de segmentação, segmentos mais semânticos e representativos, bem como a redução de ruído e resultados mais suaves.

### c. Classificação da imagem

Nesta seção dedicada à classificação de imagens, foram empregados métodos avançados de aprendizado de máquina, mais especificamente, a utilização das redes neurais [8]. A abordagem adotada baseia-se na segmentação prévia dos objetos e na subsequente aplicação de técnicas de aprendizado de máquina para realizar a classificação automática.

Inicialmente, é essencial definir um conjunto completo de classes que abranja todas as possíveis categorias de defeitos que podem ser identificadas. Essas classes e suas representações correspondentes nas imagens formam a base do processo de treinamento da rede neural. A rede neural é então alimentada com um algoritmo de treinamento que ajusta os pesos das conexões entre os neurônios, possibilitando que a rede aprenda a reconhecer padrões distintivos associados aos diferentes defeitos e, por conseguinte, classificá-los nas categorias corretas.

A etapa subsequente engloba a aplicação de uma Rede Neural Artificial (RNA) para executar a classificação das imagens. Nesse contexto, o processo assume um caráter supervisionado de aprendizado, uma vez que a rede é treinada utilizando exemplos de imagens previamente classificadas. Duas técnicas notáveis utilizadas são a *MultiLayer Perceptron* (MLP) e a *Convolutional Neural Network* (CNN), ambas amplamente reconhecidas em aplicações de visão computacional e processamento de imagens.

O algoritmo *JESG* pode ser empregado em conjunto com as redes neurais mencionadas anteriormente, proporcionando um aprimoramento na precisão e eficiência da classificação. Para avaliar a eficácia da abordagem proposta, os resultados obtidos com o *JESG* são comparados com outras soluções disponíveis na literatura, permitindo uma análise crítica do desempenho.

No desenvolvimento das técnicas de redes neurais para este artigo, utilizamos as bibliotecas TensorFlow (v2.13), PyTorch (v2.0), K-Means(v1.3.0) e Pandas(v2.1.0). Essas ferramentas são cruciais para construir, treinar e avaliar redes neurais eficazes. As operações essenciais incluem, cálculos de ativação onde funções como sigmoide, ReLU e tangente hiperbólica introduzem não-linearidade nas redes, permitindo que elas aprendam relações complexas nos dados. Em outro momento, são aplicadas funções de perda, como entropia cruzada e erro quadrático médio, avaliam o desempenho do modelo, medindo a diferença entre as previsões e os valores reais dos dados. E por fim, algoritmos foram implementados os SGD, Adam e RMSprop ajustam os pesos da rede para minimizar a função de perda durante o treinamento e realizando assim, a otimização dos modelos.

#### d. Testes computacionais

Nesta seção, é descrito os testes computacionais conduzidos para avaliar a eficácia do sistema proposto de avaliação da qualidade de frutos. Os testes foram desenvolvidos com o intuito de comparar os resultados gerados pelo sistema em relação a uma base de dados estabelecida. Como ponto de partida, os testes foram executados após a conclusão do treinamento da rede. Nessa fase, um conjunto de imagens previamente processadas e tratadas, foram inseridas no sistema. As imagens foram então processadas e classificadas com base no conhecimento adquirido pela rede durante o treinamento. A saída resultante das classificações foi registrada para posterior análise.

Os testes foram conduzidos em duas configurações distintas: uma usando imagens que passaram por um algoritmo de segmentação baseado no *K-means* e outra que utilizou o algoritmo *JESG*. Os Teste com Segmentação pelo Algoritmo *K-means*, inicialmente, foram aplicados no MLP, que foi treinado usando 70% do conjunto de dados de que consiste nas características extraídas das regiões segmentadas das imagens de maçãs. O treinamento envolveu a otimização dos pesos da rede neural para minimizar a função de perda, e a validação cruzada foi utilizada para avaliar o desempenho do modelo.

A CNN também foi treinada utilizando as mesmas regiões segmentadas das imagens de maçã como entrada e com os mesmos 70% do conjunto de dados. A rede neural convolucional foi projetada com camadas convolucionais, camadas de pooling e camadas totalmente conectadas. O treinamento incluiu a minimização da função de perda e a validação cruzada para avaliação. No teste com o Algoritmo *JESG* foi realizado o mesmo processo nas imagens de maçã, desta vez utilizando as características extraídas das regiões segmentadas pelo algoritmo *JESG*. O treinamento e a validação cruzada foram realizados da mesma forma que no primeiro conjunto de testes.

### III. RESULTADOS

Durante o processo de análise de imagens de frutos, foram utilizados algoritmos de extração de características e segmentação de objetos. Foram avaliados diferentes algoritmos de segmentação, sendo um deles o *JESG*, que foi aplicado para reconhecer padrões de deterioração das frutas

analisadas. Além disso, foi utilizado o algoritmo *K-means* para a segmentação por clusterização, que é amplamente utilizado para esse fim.

**TABELA 1:** ALGORITMOS, PORCENTAGENS DOS TREINAMENTOS E TESTES

Algoritmo	Treinamento	Teste
MLP + Segmentação por K-Means	96.87%	94.30%
CNN + Segmentação por K-Means	97.14%	94.65%
MLP + Algoritmo JESG	97.46%	95.32%
CNN + Algoritmo JESG	97.85%	96.02%

Na Tabela 1, é possível observar o percentual de precisão dos algoritmos de classificação implementados. E o *MultiLayer Perceptron* (MLP) utilizando o algoritmo de Segmentação por *K-Means*, obteve um resultado menor de 96.87% de acurácia no caso de treinamento e 94.30% em teste quando comparado ao algoritmo *JESG* que obteve 97.17% de acurácia no treinamento do algoritmo e 94.65% na seção de teste, assim, demonstrando toda a capacidade que o modelo *Convolutional Neural Network* (CNN) possui.

Por outro lado, ao aplicar ambos os modelos com a utilização do algoritmo *JESG* para a segmentação das imagens, observaram-se resultados ainda mais significativos. Notavelmente, nos casos de teste, o desempenho do MLP melhorou de 94.30% para 95.32%, enquanto o CNN aumentou a acurácia de 94.65% para 96.02%. Essa constatação evidencia que a escolha de um algoritmo de segmentação de alta qualidade exerce uma influência substancial sobre os resultados da classificação das imagens.

### IV. CONCLUSÃO

Este estudo explorou a aplicação do aprendizado de máquina na avaliação da qualidade de frutos. Nesse contexto, implementou-se os modelos MLP e CNN, que demonstraram a capacidade de identificar características e atributos das frutas, como cor, forma e textura, com resultados satisfatórios.

A análise comparativa dos algoritmos revelou que o MLP, quando utilizado com o algoritmo de segmentação por K-Means, apresentou um desempenho ligeiramente inferior em termos de acurácia, tanto no treinamento quanto no teste, em comparação com o algoritmo *JESG*. Este último, aplicado tanto ao MLP quanto ao CNN, demonstrou uma capacidade superior de classificação, ressaltando o potencial do modelo CNN.

Além disso, ao empregar o algoritmo *JESG* para a segmentação de imagens em ambos os modelos, os resultados foram aprimorados ainda mais. A acurácia do MLP aumentou de 94.30% para 95.32%, enquanto a do CNN subiu de 94.65% para 96.02%. Essa constatação enfatiza a importância da seleção adequada do algoritmo de segmentação, pois ele desempenha um papel fundamental no resultado da classificação de imagens.

Em síntese, os resultados apontam que a escolha criteriosa do algoritmo de segmentação e a adoção do modelo CNN podem contribuir substancialmente para a melhoria da precisão na classificação de frutos, tornando esse processo mais confiável e eficaz.

## V. AGRADECIMENTO

O presente trabalho foi realizado com o apoio da Universidade Federal do Tocantins e Fundação de Amparo à Pesquisa do Tocantins – FAPT/ Governo do Tocantins.

## REFERÊNCIAS

- [1] “Ministério fixa padrões visuais de qualidade para frutas, legumes e verduras.” [Online]. Available: <https://www.gov.br/agricultura/pt-br/assuntos/noticias/ministerio-fixa-padrees-visuais-de-qualidade-para-frutas-e-verduras>
- [2] Z. Li, R. Guo, M. Li, Y. Chen, and G. Li, “A review of computer vision technologies for plant phenotyping,” *Computers and Electronics in Agriculture*, vol. 176, p. 105672, 2020.
- [3] J. Sanches and A. C. L. Lino, “Uso de imagem digital para seleção e classificação de frutas e hortaliças,” *Infobibos–Informações Tecnológicas*, 2010.
- [4] Z. He, H. Li, Z. Wang, S. Xia, and W. Zhu, “Adaptive compression for online computer vision: An edge reinforcement learning approach,” *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, vol. 17, no. 4, pp. 1–23, 2021.
- [5] A. L. d. Rosa *et al.*, “Classificação de imagens de frutas utilizando aprendizado de máquina,” 2019.
- [6] Y. Deng and B. S. Manjunath, “Unsupervised segmentation of color-texture regions in images and video,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 23, no. 8, pp. 800–810, 2001.
- [7] G. A. Baxes, *Digital image processing: principles and applications*. John Wiley & Sons, Inc., 1994.
- [8] C. M. Bishop, *Neural networks for pattern recognition*. Oxford university press, 1995.