

Classificação de Hortaliças Maduras a partir de Imagens Digitalizadas

Érika Kayoko Hamaguti

Instituto de Geociências e Ciências Exatas da Universidade
Estadual Paulista (UNESP)
Rio Claro-SP, Brasil
erika.k.hamaguti@unesp.br

Fabricio Aparecido Breve

Instituto de Geociências e Ciências Exatas da Universidade
Estadual Paulista (UNESP)
Rio Claro-SP, Brasil
fabricio.breve@unesp.br

Resumo—As hortaliças são importantes na alimentação para prevenir doenças e melhorar a saúde. Porém, se as hortaliças não forem colhidas no ponto de colheita, a qualidade será baixa e haverá uma grande perda de produtos. Para evitar isso, pode-se utilizar técnicas de inteligência artificial para a identificação de hortaliças maduras. Este trabalho tem como objetivo realizar vários testes em modelos de CNNs e de aprendizado semi-supervisionado para encontrar os modelos mais adequados para a tarefa de classificação de imagens de hortaliças maduras. Neste caso, o morango foi utilizado como um exemplo de hortaliça.

Área: Inteligência Computacional.

I. INTRODUÇÃO

O consumo de alimentos saudáveis e de forma equilibrada é essencial para ter uma boa saúde [1]. Com o tempo, os consumidores brasileiros vêm valorizando cada vez mais os produtos relacionados à qualidade de vida, e alguns deles são as hortaliças [2]. Porém, existe um grande problema com perdas elevadas de hortaliças. Um dos motivos dessa perda é a realização das colheitas antes ou depois do tempo ideal [1]. Essas perdas geram prejuízos no comércio e também afetam a saúde dos consumidores por conta da baixa qualidade das hortaliças [3]. Para esse problema é possível utilizar algoritmos de aprendizado de máquina e de aprendizado profundo que possam detectar automaticamente as hortaliças prontas para serem colhidas.

Wan *et al.* [4] propõem um método para detectar o nível de maturidade de tomates frescos das variedades Roma e Pera utilizando uma rede neural de retropropagação (BPNN). Hendrawan *et al.* [5] comparam quatro tipos de CNNs pré-treinadas (SqueezeNet, GoogLeNet, ResNet50 e AlexNet) para classificar o estágio de maturidade da pimenta verde grande. Psiroukis *et al.* [6] compararam algumas arquiteturas de detecção de objetos recentes e técnicas de aumento de dados para a classificação de maturidade de brócolis. Cui *et al.* [7] propõem o uso de uma CNN YOLOv4 aprimorada para obter a detecção em tempo real e precisa da maturidade de morango.

Este trabalho tem como objetivo encontrar os modelos mais adequados dentro de CNNs e modelos de aprendizado semi-supervisionado para o problema de identificação de hortaliças maduras utilizando imagens digitalizadas. Este tema foi escolhido, pois a primeira autora trabalhou em sua graduação

com uma estufa automatizada portátil, e poderia incluir na mesma a tarefa de verificação periódica de maturidade. Por conta de ser uma estufa pequena, foi escolhido o morango como uma das hortaliças a ser trabalhada.

II. CONCEITOS E TÉCNICAS

A. Redes Neurais Convolucionais

As redes neurais convolucionais, do inglês Convolutional Neural Network (CNN) [8], são baseadas no córtex visual do cérebro e têm sido muito eficientes no reconhecimento de imagens, incentivando o seu uso em várias áreas de pesquisa. Uma CNN é formada basicamente por camadas convolucionais, *pooling* e camadas totalmente conectadas para extrair as características dos dados de forma automática [9].

B. Competição e Cooperação entre Partículas

A Competição e Cooperação entre Partículas (PCC) [10] é um método de aprendizado semi-supervisionado baseado em grafos e inspirado pela natureza. Neste modelo, as partículas de uma mesma classe percorrem uma rede, cooperando entre si como se fossem um time, e competindo contra partículas de outras classes para conseguirem conquistar o maior número de nós não-rotulados possível. Portanto, as partículas de uma mesma classe caminham cooperativamente para espalhar seu rótulo, e as partículas de outras classes competem para definir os limites das classes.

III. METODOLOGIA DE DESENVOLVIMENTO

Neste trabalho, as imagens foram segmentadas em várias imagens de morango para serem rotuladas posteriormente como “Maduro” ou “Verde”. O conjunto de dados de imagem utilizado foi o StrawDI_Db1, que possui dados de imagem coletados de 20 plantações de morango em diferentes ambientes de iluminação, com sobreposições, oclusões e tamanhos desiguais no crescimento, com 3100 imagens de morango. O tamanho das imagens é 1008x756 pixels [7]. As imagens foram segmentadas separando apenas os morangos usando as máscaras fornecidas com o conjunto. Para isso foi utilizada a biblioteca *scikit-image*. A Fig. 1 ilustra o processo de segmentação realizado.




Figura 1 - Ilustração da segmentação de imagens.

Para a rotulagem, foi proposta, até o momento, uma abordagem combinando a rede convolucional VGG19 [11] com o PCC. Neste caso, a arquitetura VGG19 é empregada como extratora de características. Ela é usada sem a camada de classificação, com pesos pré-treinados no conjunto de dados ImageNet [12].

A Análise de Componentes Principais, ou em inglês Principle Components Analysis (PCA) [13] é utilizada para reduzir a dimensionalidade. Os componentes principais são usados para construir um grafo não ponderado e não direcionado, no qual cada imagem é um nó e as arestas conectam cada imagem aos seus k vizinhos mais próximos, de acordo com a distância euclidiana entre os componentes principais utilizados.

O grafo é passado para o PCC com algumas imagens rotuladas e ele rotula as imagens não-rotuladas. A implementação do PCA é usada com seus parâmetros padrões, e com três componentes até o presente momento. O PCC é implementado com os seus parâmetros padrões, mudando somente o *early_stop* como falso. A Fig. 2 ilustra o *framework* usando VGG19 como extrator de características e o PCC como classificador semi-supervisionado.

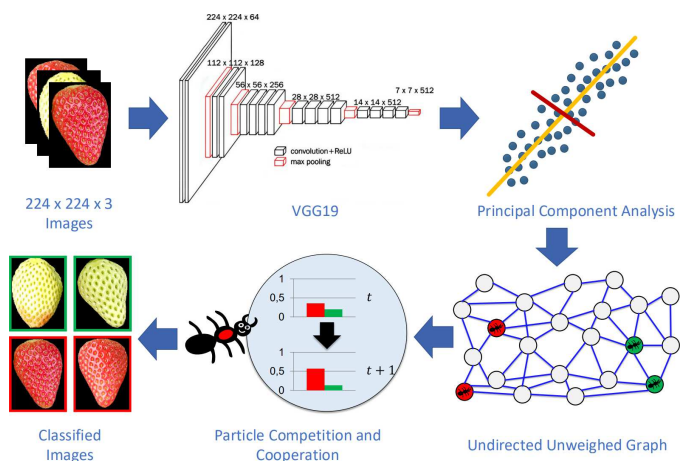


Figura 2 - O framework proposto usando PCC para rotular imagens com VGG19 como extrator de características.

A plataforma Google Colab foi utilizada na programação dos modelos. Ela utiliza como linguagem de programação o Python versão 3 e executa os códigos em nuvem do Google.

IV. RESULTADOS PRELIMINARES

Os resultados obtidos até o momento são promissores. A maioria das imagens de morango que são evidentes de serem

classificadas como maduro ou verde, como morangos totalmente vermelhos vibrantes ou morangos totalmente brancos ou verdes, foram rotuladas de forma correta. Porém, as rotulagens realizadas nos morangos com uma coloração rosa ou morangos com coloração verde e vermelha ficaram divididas entre as duas classes, o que é previsível que iria ocorrer, pois até mesmo as pessoas não sabem distinguir com clareza o que está maduro ou não.

V. CONSIDERAÇÕES FINAIS

Os próximos passos deste trabalho são a rotulagem das imagens, os testes de quantos componentes precisam ser selecionados no PCA para encontrar o melhor resultado, a realização de vários testes com outros CNNs como extratores de características e comparar modelos de CNNs e de aprendizado semi-supervisionado na classificação para que seja possível encontrar os modelos mais adequados para esta tarefa.

REFERÊNCIAS

- [1] BEVILACQUA, H. E. C. R. Classificação das hortaliças. In: CASTANHEIRO, ALM; BEVILACQUA, HECR; SHIRAKI, JN (Coords.). **Horta: cultivo de hortaliças**. São Paulo: Prefeitura do Município de São Paulo, Secretaria Municipal do Verde e do Meio Ambiente, 2006, p. 1039-1042.
- [2] VIEIRA, D. F. A. **Catálogo brasileiro de hortaliças**: saiba como plantar e aproveitar 50 das espécies mais comercializadas no país. Brasília: Embrapa Hortaliças: SEBRAE, 2010. p. 59.
- [3] LANA, M. M.; NASCIMENTO, E. F.; MELO, M. F. **Manipulação e comercialização de hortaliças**. Brasília: Embrapa-SPI/Embrapa-CNPH, 1998. p. 47.
- [4] WAN, P. *et al*. A methodology for fresh tomato maturity detection using computer vision. **Computers and electronics in agriculture**, 2018. v. 146, p. 43-50.
- [5] HENDRAWAN, Y. *et al*. Classification of large green chilli maturity using deep learning IOP Conf. Ser.: **Earth Environ**, 2021.
- [6] PSIROUKIS, V. *et al*. Assessment of Different Object Detectors for the Maturity Level Classification of Broccoli Crops Using UAV Imagery. **Remote Sens**. 2022, 14, 731. <https://doi.org/10.3390/rs14030731>.
- [7] CUI, M. *et al*. Research on Strawberry Maturity Detection Technology Based on Improved YOLOv4. In: **Journal of Physics: Conference Series**. IOP Publishing, 2021. p. 012012.
- [8] LECUN, Y. *et al*. Object Recognition with Gradient-Based Learning. In: Shape, Contour and Grouping in Computer Vision. **Lecture Notes in Computer Science**, 1999. v. 1681. Springer, Berlin, Heidelberg. https://doi.org/10.1007/3-540-46805-6_19.
- [9] ALZUBAIDI, L. *et al*. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. **Journal of big Data**, v. 8, n. 1, p. 1-74, 2021.
- [10] BREVE, F. *et al*. Particle competition and cooperation in networks for semi-supervised learning, **IEEE Transactions on Knowledge and Data Engineering**, v. 24, n. 9, p. 1686-1698, set. 2012.
- [11] SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **Computational and Biological Learning Society**, p. 1-14, 2015.
- [12] RUSSAKOVSKY, O. *et al*. ImageNet Large Scale Visual Recognition Challenge. **International Journal of Computer Vision (IJCV)**, v. 115, n. 3, p. 211-252, 2015.
- [13] JOLLIFFE, I. Principal Component Analysis. 2. ed. Springer Series in Statistics. **Springer**, 2002.