

APLICAÇÃO DO DESCRITOR LPQ PARA EXTRAÇÃO DE CARACTERÍSTICAS DE IMAGENS DE LARANJAS PARA A CLASSIFICAÇÃO INDUSTRIAL

Rhuan Vinícius Bissoli (PIBIC/CNPq/FA /UEM), Igor Rossi Fermo (coorientador), Cid Marcos Gonçalves Andrade (Orientador, *In Memoriam*), Rafael Krummenauer (Orientador). E-mail: rkrummenauer2@uem.br

Universidade Estadual de Maringá (UEM), Maringá, PR.

Área e subárea do conhecimento: Engenharias / Engenharia Elétrica

Palavras-chave: LPQ, Visão computacional, processamento digital de imagens.

RESUMO

A indústria de suco de laranja no Brasil demanda métodos mais eficientes para a classificação dos frutos, dado o volume massivo de produção e a imprecisão do processo manual. Para tentar solucionar esses problemas, técnicas de visão computacional foram aplicadas com o descritor de textura *Local Phase Quantization* (LPQ) para a extração de características texturais das laranjas em diferentes espaços de cor. Através de algoritmos de aprendizagem de máquina como KNN, *Random Forest*, *MLP* e *SVM*, o sistema de automação apresentou uma acurácia de 95,29% com o classificador *KNN* no espaço de cor *HSV*. A implementação da Análise de Componentes Principais (PCA) também permitiu reduzir o tempo de processamento em 92%, sem comprometer a acurácia, tornando o método promissor para a implementação em classificação industrial.

INTRODUÇÃO

A produção de suco de laranja no Brasil, que é a maior do mundo, enfrenta desafios relacionados à eficiência na classificação das frutas. A classificação manual, embora amplamente utilizada, é trabalhosa, dispendiosa e altamente suscetível a erros, o que compromete a qualidade do produto final e aumenta os custos operacionais (NANNINI, 2022). Neste contexto, técnicas de visão computacional são desejáveis com o objetivo de automatizar o processo de classificação das laranjas. O descritor de textura *Local Phase Quantization* (LPQ) é uma das possibilidades para extrair características das imagens dos frutos (OJANSIVU; HEIKKILÄ, 2008). A aplicação dessas técnicas visa aumentar a precisão, reduzir o tempo de processamento e, consequentemente, os custos associados à classificação industrial de laranjas. A

abordagem utilizou classificadores como KNN, Random Forest, MLP e SVM (GÉRON, 2019), para avaliar o desempenho do sistema proposto.

MATERIAIS E MÉTODOS

O sistema foi desenvolvido em linguagem Python, utilizando as bibliotecas OpenCV, NumPy, Scikit-learn e SciPy. As imagens de laranjas foram adquiridas de um banco de dados contendo 11350 imagens provenientes da indústria de suco, divididas em cinco categorias (boa, casca grossa, podre, dano por praga e verde). As imagens foram convertidas para diferentes espaços de cor (RGB, Y'CbCr, tons de cinza e HSV) para terem seu desempenho analisado individualmente para características extraídas pelo descritor LPQ. O descritor gera histogramas que representam as características texturais de uma imagem. Esses histogramas foram então submetidos aos classificadores KNN, Random Forest, MLP e SVM, cujo desempenho foi avaliado nos diferentes espaços de cor utilizados.

Além dos testes multiclasse, foi realizada uma classificação binária em cascata, onde cada classe de laranja foi confrontada individualmente com uma mistura das demais, para verificar a capacidade dos algoritmos em distinguir uma única classe das outras. Para identificar as características mais relevantes e otimizar o tempo de processamento, a Análise de Componentes Principais (PCA) foi implementada (SCIKIT-LEARN, 2024).

RESULTADOS E DISCUSSÃO

Os testes realizados com os classificadores KNN, Random Forest, MLP e SVM mostraram que o espaço de cor HSV foi o que obteve resultados mais significativos para a classificação, no qual com o classificador KNN foi atingido a maior acurácia, com 95,29%. Os classificadores Random Forest, MLP e SVM também apresentaram bons desempenhos, com acurácias acima de 90%. A Tabela 1 apresenta os principais resultados de cada classificador.

Tabela 1 Acurácias de classificação por algoritmo.

Algoritmo	Formato de Cor	Acurácia (%)
KNN	HSV	95,29
Random Forest	HSV	93,04
MLP	HSV	90,48
SVM	HSV	91,37

Além da classificação geral, também foram realizados testes de classificação binária, onde cada classe de laranja (Boa, Casca Grossa, Dano Praga, Podre, Verde) foi comparada individualmente com uma classe única, composta pela mistura das demais classes balanceadas. O objetivo desses testes foi observar a capacidade dos algoritmos em distinguir uma única classe de laranjas das demais. Os resultados desses testes binários são apresentados na Tabela 2 e expressam a acurácia final da classificação em cascata, o algoritmo SVM não foi utilizado.

Tabela 2 Acurácia final dos algoritmos binários em cascata

Algoritmo	Acurácia em Cascata (%)
KNN	88,37
Random Forest	88,27
MLP	88,06

Nos testes binários, o KNN continuou a se destacar, com uma acurácia em cascata final de 88,37%. Os algoritmos Random Forest e MLP também obtiveram resultados consistentes, com acurácias de 88,27% e 88,06%, respectivamente. Os resultados indicam que todos os classificadores foram capazes de lidar com a classificação binária de forma satisfatória, embora o KNN tenha mantido uma leve vantagem.

O algoritmo PCA foi aplicado apenas nos resultados com maior relevância nas classificações realizadas (KNN). O algoritmo PCA proporcionou ganhos substanciais na classificação ao reduzir o número de atributos necessários para a classificação. Originalmente, o descritor LPQ gerava vetores de 768 atributos por imagem, originados dos três canais do espaço de cor HSV (256 por canal). Ao aplicar o PCA, o número de componentes principais foi gradualmente reduzido até que se atingisse uma representação onde o desempenho da classificação se mantivesse equivalente ao cenário anterior. Utilizando apenas 20 componentes principais, o tempo de processamento para o classificador mais eficiente (KNN) no espaço de cor HSV foi reduzido de 112,42 minutos para 8,83 minutos, uma economia de 92% no tempo de execução, sem perda de acurácia.

CONCLUSÕES

O presente estudo demonstrou que o uso do descritor de textura LPQ, em conjunto com algoritmos de aprendizagem de máquina e o algoritmo de redução de dimensionalidade PCA, é uma solução altamente promissora para a automatização da classificação de laranjas na indústria de suco. O sistema atingiu uma acurácia acima de 90%, aliada a uma significativa redução no tempo de processamento de

92%. Os resultados comprovam a viabilidade da solução para aplicações industriais, sugerindo que o método pode ser implementado em linhas de produção para aumentar a eficiência e a precisão na classificação das frutas. Futuros estudos podem explorar melhorias adicionais, como o uso de maiores resoluções de imagem e aquisição de imagem em tempo real e em condições controladas.

AGRADECIMENTOS

Meus sinceros agradecimentos ao CNPq, à Fundação Araucária e à Universidade Estadual de Maringá por viabilizarem este projeto de pesquisa, proporcionando um ambiente que permitiu a expansão dos meus conhecimentos na área de estudo. Um agradecimento especial aos meus orientadores ao longo desse projeto, Prof. Dr. Cid Marcos Gonçalves Andrade (*in memoriam*) e Prof. Dr. Rafael Krummenauer, e ao meu coorientador, Prof. Dr. Igor Rossi Fermo, pelo suporte técnico e acadêmico fundamental para o sucesso deste trabalho.

REFERÊNCIAS

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**, 2 ed. O'Reilly Media, Inc., 2019.

GONZALEZ, R. C.; WOODS, R. C. **Processamento Digital de Imagens**. São Paulo: Pearson, 2010.

NANNINI, G. Brasil tem liderança mundial na produção de laranja e suco de laranja. Canal Rural, 2022. Disponível em: <https://www.canalrural.com.br/radar/brasil-tem-lideranca-mundial-na-producao-de-laranja-e-suco-de-laranja/>. Acesso em: 26 ago. 2024.

OJANSIVU, V.; HEIKKILÄ, J. (2008). Blur Insensitive Texture Classification Using Local Phase Quantization. In: Elmoataz, A., Lezoray, O., Nouboud, F., Mammass, D. (eds) **Image and Signal Processing**. ICISP 2008. Lecture Notes in Computer Science, vol 5099. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-540-69905-7_27

SCIKIT-LEARN. Principal Component Analysis (PCA). Disponível em: <https://scikit-learn.org>.