

Aplicação de Técnicas de Processamento de Imagens e Reconhecimento de Padrões para Classificação de Laranjas para Indústria de Suco

Pablo Guilherme Florêncio Paes (PIBIC/CNPq/FA/UEM), Igor Rossi Fermo (Coorientador), Cid Marcos Gonçalves Andrade (Orientador), e-mail: ra115396@uem.br.

Universidade Estadual de Maringá / Centro de Tecnologia/Maringá, PR.

Engenharia Química/Processos Industriais de Engenharia Química

Palavras-chave: Processamento digital de imagens, Descritor Daisy, Classificação de frutos.

Resumo:

A laranja é uma fruta cítrica de origem asiática da espécie *citrus sinensis* L. Osbeck. Devido ao seu sabor, suas ricas propriedades e valores nutricionais, é a fruta mais consumida em todo o mundo. O sistema de classificação de laranjas na indústria pode tornar o sistema impreciso e suscetível a falhas, pois a decisão entre os parâmetros de qualidade varia entre os avaliadores. Tendo em vista que o Brasil é o maior produtor mundial de laranjas, e consequentemente onde se encontram os maiores produtores e as maiores indústrias de processamento de laranja, e que o sistema de classificação manual humano é susceptível a falhas, são desejáveis novos sistemas automatizados de classificação para os frutos. Neste trabalho é proposto o desenvolvimento de uma técnica via processamento digital de imagens que seja capaz de classificar laranjas com relação a aspectos relacionados a qualidade, em tempo real. Os resultados obtidos até o momento indicam 85,36% de acerto para o descritor Daisy e histograma de cor.

Introdução

O Brasil é o maior país produtor de laranjas do mundo. A laranja e seus subprodutos como suco, polpa, óleos essenciais e essências provêm um mercado rentável que constitui uma parte substancial da economia de muitos países (Maione et al., 2017). O crescimento da população e a sofisticação dos consumidores criaram uma expectativa por melhores produtos, e isto aumentou a necessidade por melhores padrões de qualidade e monitoramento. O processo de classificação das laranjas na produção citrícola de acordo com sua qualidade pode não ser preciso na avaliação dos parâmetros de qualidade do produto, pois depende do julgamento de avaliadores. Diante disso, tecnologias e o conhecimento de computação podem ajudar neste processo.

Uma das soluções para a classificação de frutos é o uso de métodos de Processamento de Imagens (Gonzalez, 2010). No caso deste trabalho, o processamento de imagens consistirá na retirada de atributos de imagens de

laranjas que serão utilizados para classifica-las. O processamento é dividido em etapas, iniciando pelo processo de aquisição das imagens, pré-processamento, que consiste em realizar operações básicas para segmentar a imagem e extrair as características que serão passadas ao descritor e, para finalizar, os algoritmos de aprendizagem de máquina (classificadores) são aplicados. Como representações de características a serem extraídas e representadas, tem-se: Local Binary Pattern (LBP) (Ahonen, 2006), Histograma de Gradientes Orientados (HOG) (Dalal, 2005) e descritor local DAISY (Tola, 2008). Tais descritores podem ser submetidos a diversos métodos de classificação tais como k-NN (Mitchell, 1997), SVM (Vapnik, 1995) e Árvores de Decisão (Quinlan, 1986).

O principal objetivo deste trabalho foi o desenvolvimento de uma técnica via processamento digital de imagens que seja capaz de classificar laranjas com relação a aspectos relacionados a qualidade, que deverá ser utilizado para classificação em tempo real.

Materiais e Métodos

Desenvolveu-se o projeto utilizando a linguagem de programação Python na versão 3.8.6, no ambiente de desenvolvimento Spyder. As principais bibliotecas utilizadas foram: OpenCV, Numpy, Scikit-image, Glob, Matplotlib e Scikitlearn.

Durante o projeto, aplicou-se o descritor Daisy em um banco de imagens de laranja já existente, tal banco de imagens é composto por 11350 imagens de laranjas provenientes da indústria de suco e pertencem as variedades: pêra e folha murcha. As imagens foram capturadas em ambiente controlado e divididas em 5 classes: boas, casca grossa, dano por praga, podres e verdes.

O descritor Daisy da biblioteca scikit image possui como função: `skimage.feature.daisy()`. A função retorna uma grade de descritores, que foi utilizada para a comparação das imagens, com a dimensionalidade de matriz (P, Q, R), onde P, Q e R dependem dos parâmetros de entrada e da dimensionalidade da imagem analisada.

Os testes com o descritor Daisy no banco de imagens com as 5 classes de frutas foram feitos inicialmente com 3 configurações a fim de obter qual teria a melhor resposta: Matriz de descritores: 1x1, 2x2 e 3x3, todas centralizadas na imagem a ser analisada. A Figura 1 mostra a configuração com Matriz de descritores 1x1.




Figura 1 – Matriz 1x1 de descritores Daisy.

Extraiu-se o descritor de cada canal da imagem (R, G e B), e posteriormente foram concatenados, formando um único vetor de atributos para cada uma das 11350 laranjas que compõe o banco.

Os histogramas de cores são a representação da distribuição das cores de cada canal em uma imagem. Para este trabalho, foram gerados histogramas de cor no espaço de cores HSV para cada uma das laranjas que compõe o banco.

Durante o teste dos classificadores, foram concatenados os vetores de descritores Daisy com os vetores de histogramas de cor em espaço de cores HSV, formando um único vetor de atributos para cada laranja.

Para a análise dos dados, os vetores de atributos, organizados por classe, foram divididos em treinamento e validação, seguindo uma proporção 90/10, sendo 90% das imagens utilizadas para treinamento e 10% para validação, processo conhecido como validação cruzada. Com a validação cruzada pode-se detectar a não generalização de um padrão, já que todos subconjuntos serão testados de perspectivas diferentes.

Durante os testes, notou-se que o algoritmo poderia durar cerca de 8 horas para fazer o treinamento com todas as 11350 imagens, desse modo, fez-se uso do fatiamento de imagens (*downsampling*), implementado com o uso da biblioteca Numpy.

O *downsampling* reduziu o tamanho das imagens sem uma perda significativa de informação. Para atestar que a perda de informação não foi significativa, testou-se diferentes taxas de fatiamento e os resultados comparados com a acurácia do classificador, concluiu-se que além do tempo ser drasticamente reduzido, de 8 horas para 2,5 minutos, a eficiência do classificador também aumentou (com uma taxa de fatiamento igual a 10).

Os atributos foram submetidos a classificadores como k-NN, SVM e Árvores de Decisão.

Resultados e Discussão

Os resultados presentes na Tabela 1 foram alcançados com parâmetros do descritor Daisy: radius igual a 50% do tamanho da imagem, rings = 2, histograms = 5, orientations = 3, taxa de fatiamento das imagens igual a 6, número de vizinhos é igual a 3. O peso entre os atributos Daisy e histograma de cor foi fixado em 80/20 respectivamente. O classificador KNN foi restado com k=3 com validação cruzada.

Tabela 1 – Resultados do classificador utilizando KNN e descritores Daisy concatenados com histogramas de cores em espaço de cor HSV.

Classe	Acurácia
Boas	75,95%
Casca Grossa	93,17%
Dano Praga	78,65%
Podre	80,57%
Verde	98,33%

Os resultados evidenciam uma maior sensibilidade do algoritmo à classificação de laranjas da classe Verde e Casca grossa, porém apresentam números significativos para as classes Boa e Dano por praga.

Conclusões

Analizando os resultados do descritor no algoritmo KNN, pode-se notar que o método de classificação de laranja a partir de descritores Daisy e histogramas de cor foi satisfatório. Como era esperado, o descritor Daisy se mostrou promissor para a classificação de frutos quando combinado com outros atributos. Em trabalhos futuros pretende-se analisar o comportamento do descritor Daisy com outros descritores e outros classificadores.

Agradecimentos

Agradeço à Fundação Araucária por essa oportunidade de iniciação científica com bolsa durante esses 12 meses e ao meu professor, Igor Rossi Fermo, por me instruir durante todo esse tempo.

Referências

- AHONEN, T.; HADID, A.; PIETIKAINEN, M. (2006). Face description with local binary patterns: Application to face recognition. *IEEE Transaction Pattern Analysis and Machine Intelligence*, 28:2037–2041
- DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). [S.l.: s.n.], 2005. v. 1, p. 886–893 vol. 1.
- TOLA, E.; LEPETIT, V.; FUA, P. A fast local descriptor for dense matching. In *Conference on Computer Vision and Pattern Recognition (CVPR08)*, pages 1–8. IEEE, 2008.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento digital de imagens*. tradução: Cristina Yamagami e Leonardo Piamonte. [S.l.]: Pearson Prentice Hall, São Paulo, 2010.
- MAIONE, C.; TURRA, C.; FERNANDES, E. A. D. N.; BACCHI, M. A.; JÚNIOR, F. B.; BARBOSA, R. M. "Finding the most significant elements for the classification of organic oranges leaves: A data mining approach", *Analytical Letters*, Vol. Ed. pp. , junho 2017.
- MITCHELL, T. *Machine Learning*. McGraw-Hill, 1997.
- QUINLAN, J. R. (1986). Induction of decision trees. *Machine Learning*, 1(1):81–106.
- VAPNIK, V.; CORTES, C. *Support-Vector Networks*. *Machine Learning*, v. 20, p. 273-297, 1995.