

Classificação de laranjas por meio de processamento digital de imagens

Wesley Esdras Santiago¹, Gustavo Dias Lopes¹, Angelo Danilo Faceto¹, Adalberto Rocha Lobo Júnior¹, Rafael Faria Caldeira²

¹Universidade Federal dos Vales do Jequitinhonha e Mucuri, Campus Unaí, MG. ²Universidade Estadual de Campinas – Faculdade de Engenharia Agrícola, Campinas, SP.

E-mail autor correspondente: welsey.santiago@ufvjm.edu.br

Artigo enviado em 31/01/2019, aceito em 25/06/2019.

Resumo: No processo pós colheita de laranjas, uma das maiores dificuldades consiste no método de seleção e padronização das frutas. Sistemas mecânicos baseados em peneiras com diferentes diâmetros são bastante utilizados pela indústria citrícola, entretanto devido a movimentação intensa das frutas, injúrias por danos mecânicos são bem comuns. No intuito de facilitar o processo de seleção de laranjas, este trabalho buscou através de técnicas de processamento de imagens e aprendizado de máquina, desenvolver e testar um algoritmo para classificação de laranjas a partir do calibre da fruta. Baseado na técnica de aprendizado supervisionado, 204 imagens de laranjas distribuídas em três classes (pequeno, médio e grande) foram testadas no algoritmo proposto, considerando um classificador de análise discriminantes (LDA) e outro de vizinhos mais próximos (k-NN). Com precisão global de 82% e coeficiente kappa de 0,66 o algoritmo de classificação de laranjas a partir do calibre teve melhor desempenho utilizando o classificador de análise discriminantes, enquanto a configuração baseada no classificador de vizinhos mais próximos alcançou 72,13% de precisão global e 0,53 de coeficiente kappa. Com perspectivas de melhorias, o desempenho do algoritmo para ambas configurações já atesta a viabilidade técnica para que a metodologia proposta seja aplicada em projetos de máquinas automatizadas na classificação de laranjas.

Palavras-chave: Aprendizado de máquina; visão computacional; pós colheita.

Classification of oranges by digital image processing

Abstract: In the post-harvest process of oranges, one of the greatest difficulties in the method of fruit selection and standardization. Mechanical systems in sieves with different diameters are widely used by the citrus industry, however due to the intense movement of the fruit injuries due to mechanical damages are very common. There is no intention to facilitate the process of selection of oranges, this work sought through techniques of image processing and machine learning, developed and test an algorithm for the classification of oranges from the caliber of the fruit. Based on the supervised learning technique, 204 images of oranges distributed in three classes (small, medium and large) were tested without a proposed algorithm, considering a discriminant analysis classifier (LDA) and one of nearest neighbors (kNN). With an overall accuracy of 82% and coefficient of 0.66 the classification algorithm for oranges from the gauge had better performance using the discriminant analysis classifier, since the configuration is not a closest neighbor classifier reached 72.13% of global precision and 0.53 kappa coefficient. With prospects for improvement, the performance of the algorithm for the

other parts is already available in automated machine designs in the classification of oranges.

Key words: machine learning, computer vision, post-harvest.

Introdução

Uma das frutas mais cultivadas e conhecidas no mundo, a laranja (*Citrus sinensis*) é uma planta de origem asiática que desde sua introdução no território brasileiro têm se destacado pela promoção do crescimento socioeconômico, contribuindo com a balança comercial brasileira e principalmente na geração de empregos diretos e indiretos na área rural (CAGED, 2015).

Segundo relatório da Fundecitrus (Fundo de Defesa da Citricultura), a safra de laranja 2017/18 do principal parque citrícola do Brasil – que engloba 349 municípios de São Paulo e Minas Gerais – deverá ser de 364,47 milhões de caixas de 40,8 kg. Esta produção que é 14% maior que a média histórica dos últimos dez anos garantirá que o país mantenha a liderança mundial na produção de laranja, processamento de suco e exportação.

Com tamanha expressão comercial, a citricultura brasileira desempenha um importante papel social nas regiões produtoras. Segundo a Caged (2015), entre todos os segmentos do agronegócio a citricultura foi o segmento com maior número de contratações diretas no ano, ultrapassando 50 mil admissões.

Dentre as diversas variedades disponíveis no Brasil, as variedades Pêra Rio e Valência são as mais importantes quando se trata do mercado interno para frutas frescas ou industrial para produção de suco. Suas excelentes características de rendimento e qualidade físico-química de suco, além de oferta mais ampla fizeram com que se tornassem as variedades mais consumidas no país (Donadio, 1999).

Nos últimos anos o Brasil tem produzido em torno de 53% da produção mundial de suco de laranja, sendo ainda responsável por 80% do comércio internacional desse produto. Em relação à produção de frutas, a laranja representa aproximadamente 49% da produção brasileira de frutas (Rezzadori e Benedetti, 2009).

Qualquer indivíduo, variando sua região, estado, cidade, atribui diferentes padrões no momento de escolha, ou classificação de frutas de laranja, na hora de comprar a fruta no mercado para consumo *in natura*. Alguns optam em escolher através de um padrão de homogeneidade de tamanho, outros buscam um tamanho pequeno, médio ou grande. E outros já optam em escolher através da cor o grau de maturação da fruta. Ambos os meios de classificação estão relacionados pela estética da fruta, ou seja, a escolha é realizada pela aparência do produto.

Enquanto as laranjas destinadas à indústria são avaliadas conforme teor de suco, acidez, brix, vitaminas, ácidos, compostos nitrogenados, porcentagem da polpa e teor de óleo (Borges e Toledo, 1999), as destinadas ao consumo *in natura* têm como características desejáveis a estética e homogeneidade das frutas, pois a aparência do produto afeta consideravelmente a decisão do consumidor.

Portanto, para atender o anseio de um mercado consumidor exigente e cada vez mais competitivo, o Grupo Brasileiro de Citros de Mesa desenvolveu a Norma de Classificação da Laranja (CEAGESP, 2000). Nesta norma é definido que as frutas sejam classificadas quanto à coloração, calibre

(diâmetro equatorial da fruta) e intensidade de defeitos.

Apesar de existirem meios mecânicos, em muitas empresas beneficiadoras de laranjas o processo de inspeção e seleção de frutas é feito manualmente. Este método de seleção permite a ocorrência de problemas de qualidade quanto aos padrões estabelecidos, principalmente quanto à cor. Além disso, a exigência de um elevado número de colaboradores eleva os custos de produção. Segundo Zhang et al. (2014) e Ma (2014), características como as descritas anteriormente fundamentam a implementação de ferramentas automáticas para a tarefa de buscar, identificar e classificar padrões.

O exercício de classificar, pode ser explicado como a arte de obter informações através de imagens para padronizar ou distinguir itens no qual será ponderado. Sendo assim Brosnan e Sun (2004) manifesta que a eficiência de um método computacional para interpretação de uma imagem tende a ser utilizada, ainda mesmo, com a prática de interpretação visual ser bem empregada.

O uso do processamento de imagens digitais como estratégia para seleção e classificação de frutas tem se tornado um importante aliado de indústrias de beneficiamento (Rasekhi e Raoufat, 2013; Flores et al., 2014; Jhawar, 2016). A seleção do atributo que melhor descreve o produto associado ao interesse do consumidor/mercado possibilita redução de custos no

$$\text{Equação 1} \left\{ \begin{array}{l} P \Leftrightarrow A \leq (\bar{X} - \frac{1}{2}\sigma) \\ M \Leftrightarrow A > (\bar{X} - \frac{1}{2}\sigma) \Leftrightarrow A < (\bar{X} + \frac{1}{2}\sigma) \\ G \Leftrightarrow A \geq (\bar{X} + \frac{1}{2}\sigma) \end{array} \right.$$

Onde P representa o grupo pequeno, M o grupo médio, G o grupo grande, A a área da secção equatorial da

beneficiamento, garantia de qualidade do processo e segurança alimentar.

Considerando o exposto acima, o presente trabalho buscou desenvolver um algoritmo para classificação do calibre de frutas de laranja usando técnicas de processamento de imagens e aprendizado de máquina.

Material e Métodos

Aquisição e logística do material

Laranjas do tipo Pêra Rio foram adquiridas aleatoriamente no comércio local, armazenadas e transportadas em sacolas plásticas para as dependências do Laboratório de Máquinas Agrícolas da Universidade Federal dos Vales do Jequitinhonha e Mucuri – Campus Unaí (LMA – UFVJM). Logo após as frutas foram limpas com pano umedecido e selecionadas manualmente conforme seu aspecto visual.

Informação do Calibre

As laranjas devidamente identificadas tiveram seu calibre (diâmetro equatorial) mensurado por meio de um paquímetro digital (ZAAS, Modelo STAINLESS HARDENED) e em seguida seus valores registrados. Com a informação do calibre foi obtida a área circular da secção equatorial da fruta.

Na sequência, foi calculado a média e desvio padrão das áreas e segundo a Equação 1 realizada a distribuição das laranjas em três grupos (P – pequeno, M – médio e G – grande), conforme a área apresentada.

laranja, \bar{X} a média das áreas e σ o desvio padrão das medidas de área.

Sistemática de Classificação

As etapas para a classificação observaram o proposto por Gonzalez e Woods (2000), iniciando pela etapa de aquisição da imagem de forma padronizada, pré-processamento para remoção de ruídos, segmentação

visando destacar área de interesse, extração de atributos que descrevem o objeto de interesse e finalmente a etapa de classificação por meio de classificadores supervisionados (Figura 1).



Figura 1. Etapas do sistema de classificação.

As técnicas de programação, armazenamento e análise de imagens foi efetivada num computador Intel Core i3 CPU, 2.4 GHz e 8Gb Ram, em plataforma operacional Windows. As operações de processamento de imagem foram desenvolvidas no ambiente de programação do Matlab 9.0 R2015 (Mathworks) por meio do uso da Toolbox de Processamento de Imagens.

Aquisição de imagem

Utilizou-se uma estrutura retangular em MDF branco nas dimensões de 22,6 cm por 14 cm (Figura

2) a qual as laranjas foram inseridas. Essa estrutura suportava em altura fixa de 20cm e perpendicular a laranja amostrada, uma câmera webcam (*Genius, Modelo FaceCam 322*). Foram tomadas duas imagens para cada laranja amostrada (102 amostras), resultando num total de 204 imagens armazenadas no espaço de cores RGB com 24 bits, resolução de 640x480 pixels e em extensão de arquivo JPEG. Estas imagens foram selecionadas, identificadas e catalogadas, e armazenadas para integrar a base do banco de imagens do algoritmo.

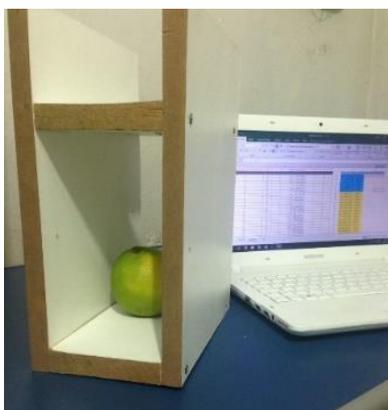


Figura 2. Estrutura para aquisição de imagens.

Pré-processamento e segmentação

Durante o pré-processamento, informações sobre os componentes de cor da imagem foram separados e o método de limiarização (Otsu, 1979) aplicado na componente de cor azul de modo a destacar as características do

objeto de interesse, no caso a laranja (Figura 3). Operações morfológica de fechamento com formato de disco foram aplicadas de modo a minimizar interferências ou falhas do processo de segmentação.

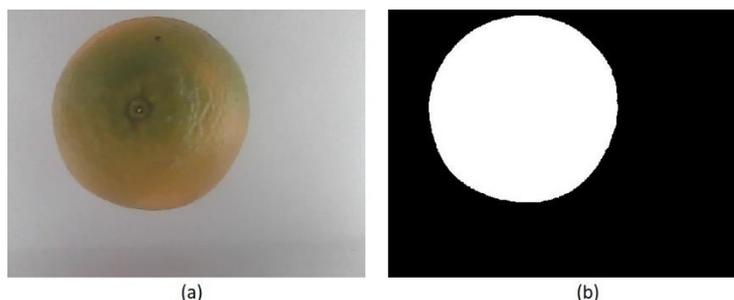


Figura 3. Segmentação. (a) Imagem original; (b) Objeto de interesse segmentado.

Extração de atributos

Com a imagem segmentada, o calibre da laranja na imagem foi obtido por meio da informação da área ocupada pela amostra na imagem. Em seguida este valor de área em pixels é armazenado para ser utilizado na etapa de treinamento e teste dos classificadores propostos.

Classificação

Para esta etapa, os dados foram agrupados em treinamento e teste na proporção de 40 e 60%, respectivamente. De acordo com o estudo de Robinson et al. (2010), se entende que os elementos destinados ao treino consistem em abastecer o classificador com dados acerca de um padrão definido, permitindo seu aprendizado quanto à atributos marcantes dos três diferentes tamanhos sugeridos. Já os destinados ao teste são para indicar em qual grupo está indicada as novas imagens.

Neste trabalho, devido ao baixo custo computacional, optou-se em utilizar os classificadores k-Vizinhos Mais Próximos (k-NN) e Análise de Discriminantes Lineares (LDA). No

classificador KNN, para cada padrão desconhecido determinam-se os k vizinhos mais próximos, sendo que a classe assumida é aquela que possui a maioria desses vizinhos (DAEL et al., 2016). Já no classificador de Análise Discriminante, Ferreira (2015), explica que ele tenta encontrar uma transformação linear por meio da potencialização da distância entre classes e redução da intra-classe, buscando descobrir a menor distância quadrática entre o centro de um grupo/classe e o dado observado.

Desempenho dos classificadores

Através de métodos de medição do erro obtemos números que indicam quais foram os desempenhos obtidos pelos classificadores utilizados (Arakeri, 2016). Em ambos classificadores, o desempenho do algoritmo foi medido através da sensibilidade, especificidade, exatidão global, e índice de Kappa referentes à uma porcentagem calculada como o número de imagens destinadas ao teste.

Medidas de desempenho adicionais como sensibilidade e especificidade foram calculados para

cada classe de ambos os classificadores (Veer e Sharma, 2016). As classes atribuídas para definir a especificidade e sensibilidade são apresentadas a seguir:

- Verdadeiro positivo (TP): Número de laranjas de determinado grupo classificadas corretamente;
- Verdadeiro negativo (TN): Número de laranjas não pertencentes a determinado grupo classificadas corretamente dentro de seu respectivo grupo;
- Falso positivo (FP): Número de laranjas de grupos opostos classificadas como pertencente ao grupo correto;

- Falso negativo (FN): Número de laranjas de determinado grupo classificadas como pertencente aos grupos opostos.

Resultados e Discussão

O desempenho do algoritmo de classificação de laranjas proposto foi avaliado por meio da comparação com imagens rotuladas manualmente conforme a Equação 1, descrita anteriormente.

As Tabelas 1 e 2 reportam os resultados do algoritmo proposto considerando a classificação por análise discriminante e k vizinhos mais próximos, respectivamente.

Tabela 1. Desempenho do algoritmo proposto usando o classificador LDA

		Classes preditas pelo algoritmo			Sensibilidade e	Especificidade e
		Pequeno	Médio	Grande		
Classes verdadeiras	Pequeno	34 (34)	0 (34)	0 (34)	1,00	1,00
	Médio	4 (8)	0 (8)	4 (8)	0,00	0,87
	Grande	3 (19)	0 (19)	16 (19)	0,84	0,93
Exatidão global = 82,0%				Kappa = 0,66		

Números fora do parêntesis se referem ao resultado obtido pelo algoritmo, números entre parêntesis se referem a quantidade de laranjas existentes nesta classe.

Uma vez que a sensibilidade mede a fração de imagens identificadas corretamente como sendo de determinada classe ($TP/[TP+FN]$), os valores obtidos para as classes Pequeno (1,00) e Grande (0,84) indicam que o algoritmo é bastante sensível na identificação destas classes, entretanto para a classe Médio (0) há a preocupação com o desempenho do algoritmo, pois fica claro que há

bastante dificuldade para reconhecer laranjas nesta classe.

Similar aos resultados de sensibilidade, os valores de especificidade, isto é, a fração de amostras negativas identificadas corretamente sobre o grupo de amostras negativas ($TN/[TN+FP]$) demonstram que o algoritmo proposto erra menos quando analisa laranjas pertencentes aos grupos Pequeno e Grande.

Tabela 2. Desempenho do algoritmo proposto usando o classificador k-NN

		Classes previstas pelo algoritmo			Sensibilidade	Especificidade
		Pequeno	Médio	Grande		
Classes verdadeiras	Pequeno	28 (34)	5 (34)	1 (34)	0,82	0,82
	Médio	2 (8)	3 (8)	3 (8)	0,38	0,91
	Grande	2 (19)	4 (19)	13 (19)	0,68	0,88
Exatidão global = 72,13%				Kappa = 0,53		

Números fora do parêntesis se referem ao resultado obtido pelo algoritmo, números entre parêntesis se referem a quantidade de laranjas existentes nesta classe.

Em k-NN, os valores encontrados na especificidade das três Classes propostas, relatam que o classificador detecta bem as laranjas que não pertence à classe pré-estabelecida. O modelo, deixa a desejar na sensibilidade para Classe M, com certo grau de dificuldade para reconhecer frutas pertencentes a esse grupo. Acredita-se que o fato do grupo M obter valores de sensibilidade tão baixos, se dá pela proximidade dos parâmetros de secção equatorial das laranjas usadas para essa classe em semelhança com as laranjas da classe P e G (Extremos). Igualmente Rudorff e Gherardi (2008) reconhecem que a existência de classes intermediárias compromete muitos classificadores, uma vez que os parâmetros que diferem esta classe das demais normalmente possuem faixa de diferenciação bastante estreita.

A alta ocorrência de falso positivo e falso negativo na classe Médio afetou negativamente os indicadores de desempenho. Resultados alcançados na Exatidão Global (82,0 e 72,13%) em LDA e k-NN respectivamente, estão fora do patamar estabelecido por Jensen (1986), de no mínimo 85%. No entanto, Delfino et al. (2010) apontam em seu trabalho que para um primeiro estudo um percentual de acerto superior a 50% é satisfatório. Isso cria um universo motivacional nesta pesquisa, que cativa

o potencial investigativo para continuidade dos experimentos. Outrossim, Davis e Goadrich (2006), informam que altas taxas de acerto não significam necessariamente que o classificador seja realmente bom para determinado função. O mesmo é considerado na análise de concordância Kappa (0,66 - 0,53) em k-NN e LDA respectivamente, ilustrando um grau de acordo “muito bom” e “bom” para os classificadores. Congalton (1991), afirma que o uso do índice de Kappa é satisfatório na avaliação da precisão de uma classificação temática pelo fato de levar em consideração toda a matriz de confusão no seu cálculo.

Em ambos classificadores, a facilidade em identificar e determinar as frutas para as Classes P e G é apropriada para construção de um protótipo que permita identificar e separar essas frutas automaticamente. Vale ressaltar que para implementar estes modelos, se faz necessário abastecê-los com mais informações e imagens, para que alguma diferença seja identificada principalmente para classe M, vendo que esta obteve os menores resultados de desempenho em ambos os classificadores.

Há ainda que se considerar que a obtenção de maiores taxas de acerto pode ter sido limitada pela falta de iluminação controlada na estrutura

construída para aquisição de imagem. Em trabalho similar, Delfino et al. (2010) ressaltam que, a iluminação do ambiente em sua pesquisa não foi totalmente controlada, formando sombras em algumas imagens e afetando o desempenho da classificação. Lamm et al. (2002), reconhecem que a influência da intensidade luminosa no decorrer do dia seja um dos desafios para classificação de imagens em operações externas.

Acredita-se que o aprimoramento fino com iluminação controlada no suporte superior da estrutura de aquisição de imagem contribuirá com a redução do número de falsos negativos e falsos positivos. Entretanto, Lowe (2004) e Santiago (2015) destacam que em situações onde a iluminação não pode ser controlada é possível utilizar descritores de características que sejam invariantes a iluminação.

Embora não seja específico, o bom desempenho do algoritmo proposto pode ser visto ainda por seu tempo de processamento que foi de apenas 0.090874 segundos para processar cada uma das 61 imagens da etapa de teste.

Conclusões

Os resultados alcançados, demonstram que o algoritmo é bastante promissor na classificação de laranjas acerca do calibre, tendo como melhores respostas de classificação as classes P e G. Assim a viabilidade técnica da metodologia proposta é atestada, podendo ser implementada em projetos de máquinas automatizadas que fazem a classificação de laranjas, necessitando somente que o algoritmo seja alimentado com mais imagens, e que a estrutura de obtenção de imagens seja aperfeiçoada para as novas condições.

Referências

ARAKERI, M.P. Computer Vision Based Fruit Grading System for Quality

Evaluation of Tomato in Agriculture industry. **Procedia Computer Science**. Volume 79, Pages 426-433, 2016.

BORGES, A, G., DE TOLEDO, J.C. **O processo para obtenção da qualidade do suco de laranja concentrado congelado brasileiro**, Gest. Prod., 1999, vol.6, n.2, pp.97-110.

BROSNAN, T.; SUN, DW. **Improving quality inspection of food products by computer vision**—a review. Journal of Food Engineering. Volume 61, Issue 1, Pages 3-16, 2004.

CEAGESP, Companhia de Entrepósitos e Armazéns Gerais de São Paulo. **Normas de Classificação de Citros de Mesa**. São Paulo: CEAGESP, 2000.

Congalton, R. G. **A review of assessing the accuracy of classifications of remotely sensed data**. Remote Sensing of Environment, v. 49 n. 12, p. 1671-1678, 1991.

DAEL, MV.; LEBOTSA, S.; HERREMANS, E.; VERBOVEN, P.; SIJBER, J.; OPARA, U.L.; Cronje, P.J.; Nicolai, B.M. A segmentation and classification algorithm for online detection of internal disorders in citrus using X-ray radiographs. **Postharvest Biology and Technology**. Volume 112, Pages 205-214, 2016.

DONADIO, L. **C. Laranja pêra**. Jaboticabal: Editora Funep, 1999. 56p.

FERNANDES, B. C. **Desenvolvimento histórico da citricultura**. 49p. Monografia (Graduação) – Universidade Estadual Paulista, Araraquara, 2010.

FERREIRA, A.M. Introdução ao Cloud Computing. **Lisboa: FCA-Editora de Informática, Lda**, 2015.

- FLORES, D.W.M.; CASTRO, T.F.; LABEGALINI, A.M.; FERREIRA, M.D.; COLNAGO, L.A. **Classificação de laranja pêra *Citrus sinensis* L. Osbeck por teor de sólidos solúveis através de análise não invasiva por ressonância magnética nuclear no domínio do tempo.** In: Anais da VI Jornada Científica – Embrapa São Carlos – 05 e 06 de Junho de 2014.
- FUNDECITRUS. **Comunicação:** Safra da laranja 2017/2018 é estimada em 364,47 milhões de caixas. 2017. Disponível em: <www.fundecitrus.com.br>. Acesso em: 05 jan. 2018.
- GONZALEZ, Rafael C.; WOODS, Richard E. **Processamento de imagens digitais.** Edgard Blucher, 2000.
- JENSEN, J. R. **Introductory digital image processing.** Englewood Cliffs: Prentice - Hall, 1986. 51 p.
- JHAWAR, J. Orange Sorting by Applying Pattern Recognition on Colour Image. **Procedia Computer Science.** Volume 78, Pages 691-697, 2016.
- LAMM, R.D.; SLAUGHTER, D. C.; GILES, D. K. Precision weed control system for cotton. **American Society of Agricultural and Biological Engineers,** v.45, n.1, p.231-238, 2002.
- LOWE, David G. **Method and apparatus for identifying scale invariant features in an image and use of same for locating an object in an image.** U.S. Patent n. 6,711,293, 23 mar. 2004.
- MA, J.; SUN, DW.; QU, JH.; LIU, D.; PU, H.; GAO, WH.; ZENG, XA. Applications of Computer Vision for Assessing Quality of Agri-food Products: A Review of Recent Research Advances, **Critical Reviews in Food Science and Nutrition,** 56:1, 113-127, 2014. DOI: 10.1080/10408398.2013.873885
- OTSU, N. A threshold selection method from gray-level histograms. **IEEE transactions on systems, man, and cybernetics,** v. 9, n. 1, p. 62-66, 1979.
- PORTALFAT. **Fundo de Amparo ao Trabalhador:** Cadastro Geral de Empregados e Desempregados (CAGED). 2015. Disponível em: <portalfat.mte.gov.br/programas-e-aco-es-2/caged-3/>. Acesso em: 05 jan.2018.
- RASEKHI, R.; RAOUFAT, M.H. Design, Development and Evaluation of an Orange Sorter Based on Machine Vision and Artificial Neural Network Techniques. **Iran Agricultural Research,** Vol. 32, No. 2, 2013.
- REZZADORI, K.; BENEDETTI, S. Proposições para valorização de resíduos do processamento do suco de laranja. In: **International Workshop Advances in Cleaner Production.** 2009. p. 1-11.
- ROBINSON, MARK D.; MCCARTHY, D. J.; SMYTH, G. K. EdgeR: a Bioconductor package for differential expression analysis of digital gene expression data. **Bioinformatics,** v. 26, n. 1, p. 139-140, 2010.
- RUDORFF, F.M.; GHERARDI, D.F.M. Coral reef detection using SAR/RADARSAT-1 images at Costa dos Corais, PE/AL, Brazil. **Brazilian Journal of Oceanography,** v. 56, n. 2, p. 85-96, 2008.
- SANTIAGO, W. E. **Identificação de plantas daninhas em cana-de-açúcar por meio de processamento de imagens.** 82p. Tese (Doutorado) –

Universidade Estadual de Campinas,
2015.

VEER, K.; SHARMA, T. A novel feature extraction for robust EMG pattern recognition. **Journal of Medical Engineering & Technology**. Volume 40, Issue 4, 2016.

ZHANG, B.; HUANG, W.; LI, J.; ZHAO, C.; FAN, S.; WU, J.; LIU, C. Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review. **Food Research International**. Volume 62, Pages 326-343, 2014.