

# Imagens espectrais de fluorescência e redes neurais tipo perceptron múltiplas camadas para predição de sólidos solúveis em uvas cv. “Itália”

Rodolpho César dos Reis Tinini<sup>1</sup>, José Maia Neto<sup>2</sup>, Nelson Felipe Oliveros Mesa<sup>3</sup>, Julia Governici<sup>4</sup>, and Bárbara Janet Teruel Mederos<sup>3</sup>

<sup>1</sup> Instituto de Ciências Agrárias, Universidade Federal de Minas Gerais, Av. Universitária, 1000, Bairro Universitário, Montes Claros – MG, 39.404-547  
rodolphotinini@ica.ufmg.br

<sup>2</sup> Programa de Pós-Graduação em Engenharia Elétrica Universidade Federal de Minas Gerais Av. Antônio Carlos 6627, 31270-901 Belo Horizonte, MG, Brasil  
jmnt@ufmg.br

<sup>3</sup> Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas Av. Cândido Rondon, 501, Barão Geraldo, Campinas – SP, 13083-875  
nfoliverosm@gmail.com , barbara.teruel@feagri.unicamp.br

<sup>4</sup> Departamento de Engenharia Agrícola, Universidade Federal de Viçosa Avenida Peter Henry Rolfs, s/n, Campus Universitário, Viçosa - MG, 36570-900  
julia.governici@gmail.com

**Resumo** As imagens espectrais de fluorescência possuem potencial uso como base para o desenvolvimento de sistemas de detecção e avaliação de componentes químicos e características físicas, em produtos agrícolas nas diversas etapas da cadeia de produção. Este estudo tem o objetivo de prever sólidos solúveis em uvas cultivar “Itália” através de análise não destrutiva usando imagens espectrais de fluorescência e redes neurais artificiais. Foram analisados cultivares de uva “Itália” submetidos a desidratação parcial e análises físico químicas para determinação de sólidos solúveis. As imagens de fluorescência foram adquiridas com excitação de 405nm nos comprimentos de onda de 480 a 710nm com intervalo de 10nm. Posteriormente, uma rede neural tipo Perceptron de Múltiplas Camadas foi utilizada para prever o nível de sólidos solúveis contidos nas uvas à partir das imagens espectrais. Os resultados de  $R^2$  obtidos para treinamento, teste e validação foram de 0.96, 0.82 e 0.86 respectivamente. Dessa forma, observa-se que a determinação não destrutiva da quantidade de sólidos solúveis em uvas da cultivar Itália cv baseada em redes neurais artificiais é factível e apresenta grande potencial neste tipo de análise uma vez que apresenta resultados satisfatórios sem a necessidade de descarte do produto analisado.

**Palavras-chave:** Perceptron Múltiplas Camadas, Pós-Colheita, Análise não Destrutiva, *Vitis Vinífera L.*

## 1 Introdução

Recentemente, imagens espectrais vêm sendo utilizadas para avaliações não destrutivas de alimentos e produtos agrícolas. O crescente uso desta técnica se deve à sua vantagem em relação aos métodos convencionais de laboratório, que além de serem destrutivos (necessitando o descarte do produto após a análise), podem demorar muito tempo para gerar a resposta, o que resulta em altos custos e baixa efetividade na tomada de decisão dos produtores e comerciantes. Por isso, vários trabalhos têm abordado esta técnica para diferentes aplicações [31] [1] [19] [28] [17] [33] [34].

Dentre as técnicas baseadas em imagens espectrais, a espectroscopia de fluorescência tem apresentado um grande número de aplicações nos mais diversos ramos do conhecimento [24]. Em geral as aplicações desta técnica na agricultura permitem analisar a fluorescência emitida pelos pigmentos dos tecidos vegetais e estudar, indiretamente, os estados fotossintéticos da planta para, posteriormente, identificar a influência das condições ambientais sobre o seu processo de desenvolvimento e o rendimento final.

Neste sentido, uma importante aplicação é a correlação entre os compostos físico químicos e os dados espectroscópicos [32]. Diversos estudos utilizam métodos baseados em análise estatística multivariada com o objetivo de descobrir tais correlações [30] [22] [9] [33]. . Entretanto, frequentemente estas abordagens não apresentam resultados satisfatórios, quando aplicadas à problemas mais complexos e com pouca informação a priori.

Uma alternativa a se seguir é a utilização de modelos baseados em redes neurais artificiais, já utilizados tanto para imagens espectrais [20] [8] [18], quanto para outras técnicas de espectroscopia em diversas aplicações na agricultura e outras áreas da indústria química [13] [4].

A rede neural artificial, que é um dos métodos mais comuns de aprendizado de máquina para regressão e classificação, trata-se de uma técnica de aprendizado supervisionado que reproduz o funcionamento do cérebro humano. A principal vantagem desta técnica está relacionada com fato de que as redes não necessitam de informações prévias detalhadas acerca dos processos físicos do sistema a ser modelado [15] [26].

Portanto, este trabalho tem por objetivo utilizar redes neurais artificiais para prever valores de sólidos solúveis totais (SST) em uvas cultivar Itália através de análise não destrutiva com imagens espectrais de fluorescência.

O trabalho está organizado da seguinte forma...

## 2 Materiais e Métodos

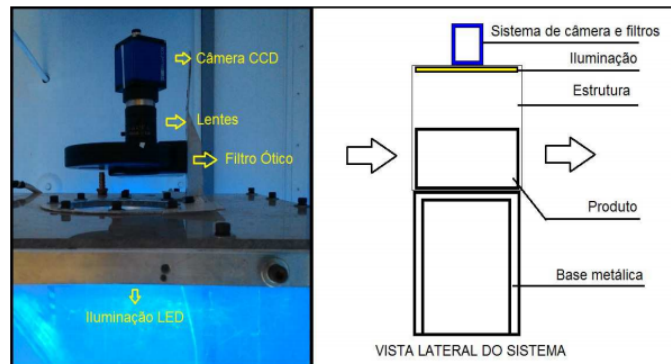
### 2.1 Amostras e análises de caracterização

Foram utilizadas como amostras, imagens espectrais de uvas de mesa branca da cultivar Itália (*Vitis vinífera* L.). As amostras foram adquiridas em um centro de distribuição de frutas e hortaliças (CEASA) na região de Campinas – SP, e

foram utilizadas para o experimento um total de 5 Kg de produto. Para obter amplitude dos valores de sólidos solúveis, as uvas foram submetidas a uma desidratação parcial em 5 diferentes tempos (0, 6, 12, 18 e 24 horas) em estufa de circulação de ar forçado a 65°C. A temperatura de 65°C foi utilizada com base no método padrão [12] de medida de umidade em produtos perecíveis (alto teor de umidade, como a uva) esta é a temperatura adotada para retirar água e não modificar as características físico-químicas do produto. Desta forma, realizou-se a medida a cada 6 horas durante 24 horas para observar diferentes níveis de concentração de açúcar no produto em um range largo de pontos para analisar a generalização da regressão. As medições de sólidos solúveis, foram feitas através de um refratômetro digital (Artago – PR101), e foram coletadas em triplicata repetições por amostras por tratamento.

## 2.2 Instrumentação e Procedimentos Espectrais

O sistema de imagens espectrais utilizado é composto por: sistema de câmera e filtros (com uma câmera CCD, lentes e filtro ótico), sistema de iluminação (LEDs emissores de alta potência no comprimento de onda de 405nm), caixa para acondicionamento do produto, e uma base metálica de sustentação (Figura 1).



**Figura 1.** Sistema de Aquisição de Imagens [23].

No sistema de aquisição de imagens foi utilizada uma câmera CCD científica da marca mvBlueFox 223G (Matrix Vision, Alemanha), com resolução de 1360 x 1024 pixels na área ativada do sensor e um sistema de lentes de 25mm da marca Edmund Optics, além de uma roda de filtros motorizada da marca Thorlabs, modelo FW102C com capacidade para 6 filtros, onde foram colocados os filtros com os comprimentos de onda de interesse, entre 480 a 710nm (comprimento de onda do azul ao vermelho).

O modelo dos filtros e da câmera foram utilizados para a normalização das imagens de acordo com a curva de resposta da câmera CCD e da curva de trans-

missão do filtro ótico. Esta normalização consiste em multiplicar as imagens pelas funções de resposta de ambos os equipamentos nos comprimentos de onda em que foram adquiridas as imagens. Em seguida, aplica-se às imagens a eliminação da informação do tempo de exposição, removendo-se assim, a saturação das imagens normalizadas (Equação 1, Equação 2 e Equação 3).

$$E = T_c \times T_f \quad (1)$$

$$I_s(\lambda) = \frac{I(\lambda)}{E_n(\lambda)} \quad (2)$$

$$I_{te}(\lambda) = I_s(\lambda) \times \frac{t_{min}}{t(\lambda)} \quad (3)$$

Em que:

$E$  – Curva de resposta após multiplicação das curvas de resposta;

$T_c$  – Curva de resposta da CCD;

$T_f$  – Curva de resposta do filtro ótico;

$I_s$  – Imagem com eliminação da informação espectral;

$I$  - Imagem original;

$E_n$  – Função E normalizada;


$I_{te}$  – Imagem com eliminação da informação do tempo de exposição;

$t_{min}$  – Tempo de exposição mínimo (ms);

$t$  – Tempo de exposição no comprimento de onda específico (ms);

$\lambda$  – Comprimento de onda (nm);

O método de aquisição das imagens foi baseado no sistema descrito por [29], em que primeiro excita-se o produto por dois minutos com a fonte de iluminação UV (405nm) e procede-se a aquisição da imagem para cada espectro de interesse. Um exemplo de imagem obtida pode ser visualizado na Figura 2.



**Figura 2.** Imagem espectral no comprimento de onda de 480nm, com aplicação de tratamento de alto contraste para possibilitar a visualização

A partir da obtenção das imagens foi realizada a preparação dos dados da imagem espectral, para geração das características de entrada do modelo de regressão [32]. Primeiramente foi feita a normalização das imagens de acordo com a curva de resposta da câmera CCD e da curva de transmissão do filtro ótico, afim de evitar efeitos de saturação que podem ter ocorrido durante a captura das imagens.

Em seguida realizou-se a segmentação através do método de Otsu [21] [7] [17]. Extraíu-se os valores de pixels em escala de cinza (0 a 255), em seguida calculou-se a fluorescência relativa através da relação entre o valor de cada pixel e a soma dos pixels para cada comprimento de onda obtendo, assim a resposta espectral relativa de fluorescência para cada comprimento de onda em estudo [7]. Por fim, os dados de entrada para o modelo de regressão foram organizados em uma matriz *Dataset*. Nessa matriz, as linhas são os valores de resposta espectral relativa de fluorescência para cada amostra e as colunas representam cada comprimento de onda (Equação 4)

$$Dataset = \begin{bmatrix} x_{1,\lambda_1} & \dots & x_{1,\lambda_m} \\ \vdots & \ddots & \vdots \\ x_{n,\lambda_1} & \dots & x_{n,\lambda_m} \end{bmatrix} \quad (4)$$

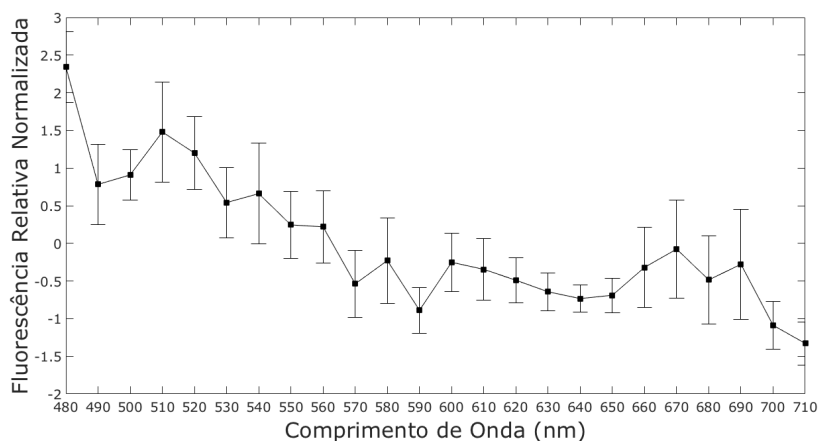
Após a obtenção desta matriz com os valores de fluorescência relativa para cada amostra, realizou-se a normalização dos dados utilizando o SNV (Standard Normal Variate) [17]. Finalmente foi calculada a média e o desvio padrão de cada comprimento de onda gerando o espectro médio para cada amostra de uva e para cada fonte de excitação (fluorescência 405nm).

A saída desejada para a regressão foi obtida através de análise da quantidade de sólidos solúveis em laboratório. Foram analisados o teor de sólidos solúveis presente em todas as amostras de uvas cv. “Itália”, conforme apresentado na Tabela 1. A partir dos dados da tabela pode-se verificar os valores de sólidos solúveis obtidos após cada tratamento e que foram posteriormente relacionados com o espectro de fluorescência. A Tabela 1 mostra que os valores de sólidos solúveis da cultivar “Itália” após a aplicação dos tratamentos, são similares aos apresentados por [1] e [25].

**Tabela 1.** Caracterização físico-química para concentração de sólidos solúveis totais (°Brix) e seus respectivos desvios padrões para uva cv. “Itália” submetida a diversos tempos de desidratação.

<i>Tratamentos</i>	<i>Sólidos Solúveis (°Brix)</i>	<i>Desvio Padrão</i>
<i>T1 (Produto fresco)</i>	20.12	0.46
<i>T2 (6h a 65° C)</i>	21.17	0.23
<i>T3 (12h a 65° C)</i>	23.83	0.53
<i>T4 (18h a 65° C)</i>	25.28	1.12
<i>T5 (24h a 65° C)</i>	29.18	2.56

Verificado os valores de sólidos solúveis no produto após a aplicação dos tratamentos, foram analisados a fluorescência relativa média para o espectro visível como mostra a Figura 3.



**Figura 3.** Espectro médio de fluorescência relativa a 405nm de uvas (cv. “Itália”) com seus respectivos desvios padrões

Os dados da Figura 3 mostra na presença de dois picos um na região de 400-600nm (fluorescência azul/verde ) e outro pico na região de 600-750nm (fluorescência vermelha).O primeiro intervalo de emissão de fluorescência ocorre basicamente pela presença de flavonoides nos tecidos vegetais do produto , normalmente situa-se entre 450 e 500nm e são um indicativo de qualidade da fruta [16] [6] [3] [10]. Já o segundo intervalo apresenta uma região de emissão após o comprimento de onda de 660nm que para clorofila, corresponde à fluorescência entre 680 e 740 nm. Esta intensidade pode não ter sido muito alta pois alguns autores ligam o decaimento da intensidade de fluorescência com a degradação de componentes presentes nos tecidos vegetais [5] [14] [27]. De modo geral, estes dados indicam que é possível relacionar a qualidade do fruto com a quantidade de sólidos solúveis e o seu comportamento espectral o que motiva o desenvolvimento deste trabalho.

### 2.3 Modelo de Regressão

Para o modelo de regressão foi utilizado uma rede neural artificial Perceptron de Múltiplas Camadas (MLP) com 10 neurônios na camada escondida e com algoritmo de treinamento Levenberg-Marquardt[11] [2]. Esta arquitetura foi escolhida após uma busca em grid e sendo a que apresentou melhores resultados. O treinamento da rede foi repetido 50 vezes, com o objetivo de se ter uma estimativa confiável do desempenho. A cada treinamento, foi realizada uma partição

aleatória dos dados, dividindo-os em 70% para treinamento, 15% para validação e 15% para teste. O resultado da regressão foi avaliado segundo o coeficiente  $R^2$  e a raiz quadrada do erro quadrático médio (RMSE). Todos os testes foram executados no software Matlab 2016a.

### 3 Resultados e Discussões

Após a análise do espectro médio, foi feita a construção do modelo de regressão para correlação entre os dados extraídos das imagens e os valores de sólidos solúveis no produto através de uma rede neural. Na Tabela 2 são apresentados os resultados da regressão utilizando a rede neural MLP.

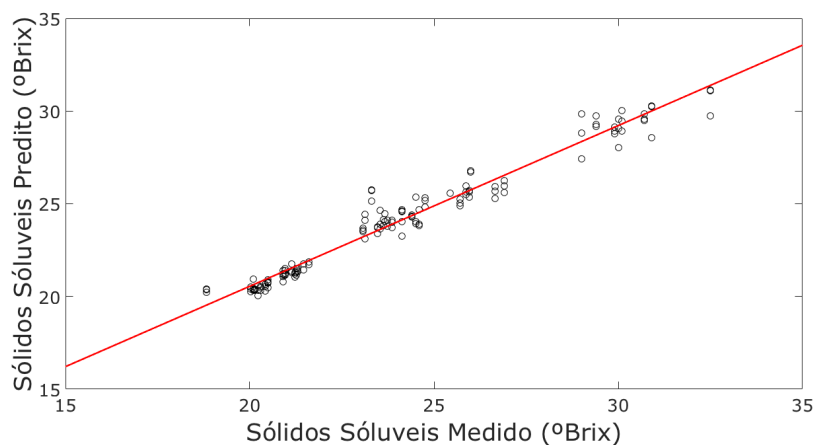
**Tabela 2.** Resultados

<i>Etapa</i>	<i>RMSE</i>	<i>R<sup>2</sup></i>
<i>Treinamento</i>	0.0919	0.9570
<i>Teste</i>	3.7333	0.8179
<i>Validação</i>	3.3606	0.8595

A Tabela 2 demonstra que a rede neural MLP apresentou valores de RMSE (raiz quadrada do erro quadrático médio) satisfatórios para o treinamento e teste. Os resultados obtidos foram muito similares ao encontrado na literatura. Com relação ao coeficiente de regressão ( $R^2$ ), observamos valores próximos aos encontrados em trabalhos para os modelos de PLSR (regressão por mínimos quadrados), mais utilizados pela literatura como observado por [1] que se encontram na entre 0.05 e 0.94 respectivamente para predição de sólidos solúveis em diferentes variedades de uvas. Estes resultados são próximos quando observamos o treinamento para o coeficiente de regressão, já em questão de teste e validação estes valores são melhores demonstrando melhor ajuste do modelo e portanto melhor capacidade preditiva.

Estes dados mostram que a utilização de técnicas espectroscópicas de fluorescência através de imagens aliado a modelagem de regressão baseada em redes neurais MLP, pode atingir índices de regressão com excelentes respostas para a análise não destrutiva de uvas a diferentes concentrações de sólidos solúveis e diferentes tempos de secagem (Figura 4).

Verificou-se, portanto, que diferentes níveis de secagem e conseqüentemente concentração de sólidos solúveis, se correlacionam com a resposta espectral das uvas. Além disso, como foi mostrado na seção 2.2, é possível se estabelecer uma relação entre a qualidade da uva (baseado nos níveis de emissão de clorofila e flavonóides) e a predição da quantidade de sólidos solúveis, criando condições favoráveis para o uso da modelagem aqui proposta na estimação da qualidade de frutas baseado em imagens espectrais.



**Figura 4.** Regressão entre os valores de sólidos solúveis medido e os valores de sólidos solúveis predito para uvas cv. “Itália” em fluorescência a 405nm.

## 4 Conclusões

O trabalho apresentou uma metodologia baseada em redes neurais MLP para a predição da quantidade de sólidos solúveis em uvas da cultivar Itália baseado em imagens espectrais. Os resultados obtidos para as métricas de RMSE e  $R^2$  mostraram que a abordagem é promissora para tal aplicação. Além disso, o desenvolvimento de tal metodologia apresenta contribuições para a área de análises físico-químicas da uva ao passo que é uma alternativa não destrutiva para medição rápida de componentes físico químicos. Trabalhos futuros serão realizados no sentido de se utilizar outros métodos de regressão e aumentar a base de dados utilizada com o objetivo de obter resultados mais representativos para uma maior gama de uvas da cultivar Itália e generalizar a metodologia para uma maior gama de problemas.

## Agradecimentos

A Fapesp pelo financiamento da pesquisa através do processo n.2013/0878-2.

## Referências

1. Baiano, A., Terracone, C., Peri, G., Romaniello, R.: Application of hyperspectral imaging for prediction of physico-chemical and sensory characteristics of table grapes. *Computers and Electronics in Agriculture* 87, 142–151 (sep 2012), <http://linkinghub.elsevier.com/retrieve/pii/S0168169912001433>
2. Balabin, R.M., Safieva, R.Z., Lomakina, E.I.: Comparison of linear and non-linear calibration models based on near infrared (NIR) spectroscopy data for



- gasoline properties prediction. *Chemometrics and Intelligent Laboratory Systems* 88(2), 183–188 (sep 2007), <http://linkinghub.elsevier.com/retrieve/pii/S0169743907000925>
3. Bauriegel, E., Herppich, W.: Hyperspectral and Chlorophyll Fluorescence Imaging for Early Detection of Plant Diseases, with Special Reference to Fusarium spec. *Infections on Wheat. Agriculture* 4(1), 32–57 (2014), <http://www.mdpi.com/2077-0472/4/1/32/>
  4. Binetti, G., Coco, L.D., Ragone, R., Zelasco, S., Perri, E., Montemurro, C., Valentini, R., Naso, D., Fanizzi, F.F.P., Schena, F.F.P., Del Coco, L., Ragone, R., Zelasco, S., Perri, E., Montemurro, C., Valentini, R., Naso, D., Fanizzi, F.F.P., Schena, F.F.P.: Cultivar classification of Apulian olive oils: Use of artificial neural networks for comparing NMR, NIR and merceological data. *Food Chemistry* 219 (2017), <http://dx.doi.org/10.1016/j.foodchem.2016.09.041>
  5. Chappelle, E.W., Wood, F.M., McMurtrey, J.E., Newcomb, W.W.: Laser-induced fluorescence of green plants. for the remote detection of plant stress and species differentiation. *Applied Optics* 23(1), 1–5 (1984)
  6. Crupi, P., Coletta, A., Milella, R.A., Palmisano, G., Baiano, A., La Notte, E., Antonacci, D.: Carotenoid and chlorophyll-derived compounds in some wine grapes grown in Apulian region. *Journal of Food Science* 75(4), 191–198 (2010)
  7. Diezma, B., Lleó, L., Roger, J.M., Herrero-Langreo, A., Lunadei, L., Ruiz-Altisent, M.: Examination of the quality of spinach leaves using hyperspectral imaging. *Postharvest Biology and Technology* 85, 8–17 (2013), <http://dx.doi.org/10.1016/j.postharvbio.2013.04.017>
  8. ElMasry, G., Wang, N., Vigneault, C.: Detecting chilling injury in Red Delicious apple using hyperspectral imaging and neural networks. *Postharvest Biology and Technology* 52(1), 1–8 (apr 2009), <http://linkinghub.elsevier.com/retrieve/pii/S0925521408003220>
  9. ElMasry, G.M., Nakauchi, S.: Image analysis operations applied to hyperspectral images for non-invasive sensing of food quality - A comprehensive review. *Biosystems Engineering* 142, 53–82 (2016), <http://dx.doi.org/10.1016/j.biosystemseng.2015.11.009>
  10. Georgiev, V., Ananga, A., Tsoлова, V.: Recent advances and uses of grape flavonoids as nutraceuticals. *Nutrients* 6(1), 391–415 (2014)
  11. Haykin, S.: *Neural Networks: A Comprehensive Foundation*. Prentice Hall PTR, Upper Saddle River, NJ, USA, 2nd edn. (1998)
  12. International, A., Latimer, G.: *Official Methods of Analysis of AOAC International*. No. v. 1 in *Official Methods of Analysis, AOAC International* (2012), <https://books.google.com.br/books?id=kPe4NAEACAAJ>
  13. Janik, L.J., Cozzolino, D., Damberg, R., Cynkar, W., Gishen, M.: The prediction of total anthocyanin concentration in red-grape homogenates using visible-near-infrared spectroscopy and artificial neural networks. *Analytica Chimica Acta* 594(1), 107–118 (2007)
  14. Jiang, L., Shen, Z., Zheng, H., He, W., Deng, G., Lu, H.: Noninvasive evaluation of fructose, glucose, and sucrose contents in fig fruits during development using chlorophyll fluorescence and chemometrics. *Journal of Agricultural Science and Technology* 15(2), 333–342 (2013)
  15. Kurtulmus, F., Lee, W.S., Vardar, A.: Immature peach detection in colour images acquired in natural illumination conditions using statistical classifiers and neural network. *Precision Agriculture* 15(1), 57–79 (2014), <https://link.springer.com/content/pdf/10.1007/s11119-013-9323-8.pdf>

16. Lai, A., Santangelo, E., Soressi, G.P., Fantoni, R.: Analysis of the main secondary metabolites produced in tomato (*Lycopersicon esculentum*, Mill.) epicarp tissue during fruit ripening using fluorescence techniques. *Postharvest Biology and Technology* 43(3), 335–342 (2007)
17. Mishra, P., Herrero-Langreo, A., Barreiro, P., Roger, J., Diezma, B., Gorretta, N., Lleó, L.: Detection and quantification of peanut traces in wheat flour by near infrared hyperspectral imaging spectroscopy using principal-component analysis. *Journal of Near Infrared Spectroscopy* 23(1), 15 (2015), [http://www.impublications.com/content/abstract?code=J23{\\\_}0015](http://www.impublications.com/content/abstract?code=J23{\_}0015)
18. Mollazade, K., Omid, M., Akhlaghian Tab, F., Rezaei Kalaj, Y., Mohtasebi, S.S.: Data Mining-Based Wavelength Selection for Monitoring Quality of Tomato Fruit by Backscattering and Multispectral Imaging. *International Journal of Food Properties* 18(4), 880–896 (2015), <http://www.scopus.com/inward/record.url?eid=2-s2.0-84961292077{\&}partnerID=tZ0tx3y1>
19. Nogales-Bueno, J., Hernández-Hierro, J.M., Rodríguez-Pulido, F.J., Heredia, F.J.: Determination of technological maturity of grapes and total phenolic compounds of grape skins in red and white cultivars during ripening by near infrared hyperspectral image: a preliminary approach. *Food chemistry* 152, 586–91 (jun 2014), <http://www.ncbi.nlm.nih.gov/pubmed/24444979>
20. Noh, H.K., Lu, R.: Hyperspectral laser-induced fluorescence imaging for assessing apple fruit quality. *Postharvest Biology and Technology* 43(2), 193–201 (feb 2007), <http://linkinghub.elsevier.com/retrieve/pii/S0925521406002316>
21. Otsu, N.: THRESHOLD SELECTION METHOD FROM GRAY-LEVEL HISTOGRAMS. (1979), <http://www.scopus.com/inward/record.url?eid=2-s2.0-0018306059{\&}partnerID=tZ0tx3y1>
22. Pu, Y.Y., Feng, Y.Z., Sun, D.W.: Recent progress of hyperspectral imaging on quality and safety inspection of fruits and vegetables: A review. *Comprehensive Reviews in Food Science and Food Safety* 14(2), 176–188 (2015)
23. dos Reis Tinini, R.C.: Avaliação Não Destrutiva de Sólidos Solúveis por meio de Imagens Espectrais de Uvas Submetidas à Desidratação Parcial. Ph.D. thesis, Universidade Estadual de Campinas (2015)
24. Sankaran, S., Mishra, A., Ehsani, R., Davis, C.: A review of advanced techniques for detecting plant diseases. *Computers and Electronics in Agriculture* 72(1), 1–13 (jun 2010), <http://linkinghub.elsevier.com/retrieve/pii/S0168169910000438>
25. da Silva, L.C., dos Santos, H.P., Fialho, F.B., Marodin, G.A.B., Bergamaschi, H., Flores, C.A.: Maturação tecnológica e qualidade da uva ‘Itália’ em cultivo protegido sob distintos manejos hídricos. *Ciência Rural* 45(2), 252–259 (feb 2015), [http://www.scielo.br/scielo.php?script=sci{\\\_}arttext{\&}pid=S0103-84782015000200252{\&}lng=pt{\&}tlng=pt](http://www.scielo.br/scielo.php?script=sci{\_}arttext{\&}pid=S0103-84782015000200252{\&}lng=pt{\&}tlng=pt)
26. Suárez, M.H., Dopazo, G.A., López, D.L., Espinosa, F.: Identification of relevant phytochemical constituents for characterization and authentication of tomatoes by General Linear Model linked to Automatic Interaction Detection (GLM-AID) and Artificial Neural Network Models (ANNs). *PLoS ONE* (2015)
27. Ullah, R., Khan, S., Bilal, M., Nurjis, F., Saleem, M.: Non-invasive assessment of mango ripening using fluorescence spectroscopy. *Optik* 127(13), 5186–5189 (2016), <http://dx.doi.org/10.1016/j.ijleo.2016.03.049>
28. Vélez Rivera, N., Gómez-Sanchis, J., Chanona-Pérez, J., Carrasco, J.J., Millán-Giraldo, M., Lorente, D., Cubero, S., Blasco, J.: Early detection of mechanical damage in mango using NIR hyperspectral images and machine learning. *Biosystems Engineering* 122, 91–98 (2014)

29. Wetterich, C.B., Kumar, R., Sankaran, S., Belasque Junior, J., Ehsani, R., Marcassa, L.G.: A Comparative Study on Application of Computer Vision and Fluorescence Imaging Spectroscopy for Detection of Huanglongbing Citrus Disease in the USA and Brazil. *Journal of Spectroscopy* 2013(Ccm), 1-6 (2013), <http://www.hindawi.com/journals/jspec/2013/841738/>
30. Wu, D., Sun, D.W.: Colour measurements by computer vision for food quality control – A review. *Trends in Food Science & Technology* 29(1), 5-20 (jan 2013), <http://www.sciencedirect.com/science/article/pii/S0924224412001835>
31. Yang, C.C., Kim, M.S., Kang, S., Tao, T., Chao, K., Lefcourt, A.M., Chan, D.E.: The development of a simple multispectral algorithm for detection of fecal contamination on apples using a hyperspectral line-scan imaging system. *Sensing and Instrumentation for Food Quality and Safety* 5(1), 10-18 (2011)
32. Zhang, Y., Wang, S., Ji, G., Phillips, P.: Fruit classification using computer vision and feedforward neural network. *Journal of Food Engineering* 143, 167-177 (2014), <http://dx.doi.org/10.1016/j.jfoodeng.2014.07.001>
33. Zhao, Y.R., Li, X., Yu, K.Q., Cheng, F., He, Y.: Hyperspectral Imaging for Determining Pigment Contents in Cucumber Leaves in Response to Angular Leaf Spot Disease. *Scientific Reports* 6(November 2015), 27790 (2016), <http://www.nature.com/articles/srep27790>
34. Zhu, Z., Chen, Y., Zhang, X., Li, M.: Effect of foliar treatment of sodium selenate on postharvest decay and quality of tomato fruits. *Scientia Horticulturae* 198, 304-310 (2016), <http://dx.doi.org/10.1016/j.scienta.2015.12.002>