

DETECÇÃO DE PLANTAS DE CITROS E *MURRAYA PANICULATA* UTILIZANDO IMAGENS HIPERESPECTRAIS COMO SUBSÍDIO PARA O CONTROLE DE GREENING

Érika Akemi Saito Moriya¹, Nilton Nobuhiro Imai¹, Antonio Maria Garcia Tommaselli¹, Eija Honkavaara²

¹Departamento de Cartografia- FCT UNESP, Rua Roberto Simonsen, 19060-900 - Presidente Prudente - SP, Brasil, erikaasaito@gmail.com; {nimai, tomaseli}@fct.unesp.br.

² Finnish Geospatial Research Institute; eija.honkavaara@fgi.fi

RESUMO

O Brasil é o principal produtor mundial de citros. No entanto, a produção de citros brasileira e mundial vem sofrendo grandes prejuízos com o *Greening*. As formas mais comuns de controle do *Greening* incluem a inspeção do pomar, pulverização de inseticida, erradicação de plantas doentes e também de plantas hospedeiras como a murta-de-cheiro ou falsa-murta (*Murraya paniculata*), independentemente de estarem infectadas ou de sua localização. Uma das demandas da indústria cítrica é a identificação e mapeamento dos locais com presença de plantas de citros e murta na vizinhança das plantações de citros incluindo a área urbana próxima às fazendas produtoras de citros. O objetivo deste trabalho foi desenvolver uma solução tecnológica para produzir informação georreferenciada para identificação de plantas de citros/murta utilizando imagens e técnicas de Sensoriamento Remoto que darão suporte a citricultura no combate ao *Greening*.

Palavras-chave — HLB, cubo hiperespectral, espectrorradiometria, classificação de imagens.

ABSTRACT

Brazil is the main worldwide citrus producer. However, the Brazilian and world citrus production has suffered great losses with greening disease. The most common ways of controlling greening include inspecting the orchard, spraying insecticide, eradicating diseased plants and also host plants such as sage myrtle or false myrtle (Murraya paniculata), regardless of whether they are infected or their localization. One of the demands of the citrus industry is the identification and mapping of places with the presence of citrus and myrtle plants in the vicinity of citrus plantations, including the urban area close to citrus producing farms. The objective of this work was to develop a technological solution to produce georeferenced information for the identification of citrus/myrtle plants using Remote Sensing images and techniques that will support citrus farming in the fight against greening.

Key words — HLB, hyperspectral cube, spectroscopy, image classification.

1. INTRODUÇÃO

O Brasil se destaca como sendo o principal produtor de citros no mundo [1]. A pior doença de citros no mundo é o *Greening* ou Huanglongbing (HLB), do chinês “doença do dragão amarelo” [2, 3]. O inseto vetor transmissor de *Greening* é o psílídeo *Diaphororina citri* transmissor da bactéria causadora da doença [4, 5]. As plantas infectadas tornam-se rapidamente improdutivas aumentando o custo de produção em razão do controle do vetor [3].

O manejo do *Greening* baseia-se na prevenção de novas infecções em plantas sadias com a redução da inoculação resultante de planta infectada e dos insetos vetores. O controle da doença também considera a erradicação não só das plantas doentes, mas também das plantas de murta-de-cheiro ou falsa-murta (*Murraya paniculata*), independentemente de estarem infectadas ou de sua localização [6]. A *Murraya paniculata* é muito utilizada como espécie ornamental em paisagismo no Brasil, e também é hospedeira dos tipos asiáticos e americano da bactéria causadora do *Greening* e do inseto vetor [7].

Devido ao potencial de devastação do *Greening* ações de controle também em áreas urbanas são necessárias. De acordo com a Fundecitrus são realizadas parcerias junto a prefeituras e empresas para a troca de murtas e plantas de citros que não recebiam controle químico adequado por outros tipos de árvores ornamentais e frutíferas. A conscientização e a mobilização da sociedade no combate ao *Greening* é fundamental para manter a cultura de citros no Brasil [8].

A identificação e mapeamento dos locais com presença de plantas de citros e murta na vizinhança das plantações de citros incluindo área urbana próxima a regiões em que há produção de citros são medidas importantes para o controle do *Greening*. A utilização de tecnologias de sensoriamento remoto, fotogrametria e geoprocessamento, quando associadas a parâmetros que caracterizam a vegetação, contribuem para a discriminação de culturas agrícolas, identificação e quantificação das diferenças espectrais na vegetação [9,10]. O objetivo principal deste trabalho é a partir de técnicas de sensoriamento remoto identificar plantas de citros/murta de outras espécies baseado nas propriedades espectrais da vegetação auxiliando como um subsídio no controle de *Greening* de citros.

2. MATERIAL E MÉTODOS

A área de estudo apresentada na Figura 1, localiza-se na Faculdade de Ciências e Tecnologia (FCT)-Universidade Estadual Paulista (Unesp) em Presidente Prudente. E esta área foi selecionada pois apresenta um pomar com plantas frutíferas, citros e plantas de murta, condições que simulariam uma vistoria em ambiente urbano. A Figura 1 apresenta a distribuição das plantas de citros (azul) e plantas de murta (vermelho). Para este experimento foi realizado um levantamento de campo no dia 15 de dezembro de 2018 para coleta de espectros de plantas de citros, murta e espécies de vegetação diversas e um voo para aquisição de imagens hiperespectrais.



Figura 1. Localização da área de estudo.

No levantamento radiométrico foram realizadas medições com um espectrorradiômetro ASD FieldSpec HandHeld® modelo UV/NIR, obtendo-se espectros no intervalo espectral de 325 nm a 1075 nm, com intervalo amostral de 1,6 nm e FOV de 10° [11]. Para cada amostra foram coletadas dez medidas das amostras, de plantas de citros e murta e algumas espécies arbóreas frutíferas como acerola, banana, caju, caqui, calabura, goiaba, jabuticaba, jaca, manga, pera, e pinha; e em espécies arbóreas não frutíferas e arbustos como capim, palmeira, araucária, barba de bode e ixora. A Figura 2 apresenta exemplares de plantas de citros (Figura 2.a) e murta (Figura 2.c), sendo que a planta de citros apresentava sintomas de *Greening* (Figura 2.b). Um filtro de média móvel foi aplicado nos espectros para eliminar efeitos de ruídos da eletrônica do instrumento. Os espectros da estimativa do Fator de Reflectância Hemisférico Cônicos (FRHC) das amostras foram obtidos e utilizados como biblioteca espectral nos processamentos da imagem hiperespectral.



Figura 2. Exemplares de plantas de citros e murta. (a) Citros. (b) Citros com sintomas de *Greening*. (c) Murta.

A aquisição de imagens hiperespectrais foi realizada com a câmara hiperespectral Rikola modelo DT-0014 com Interferômetro Fabry-Perot (FPI) utilizando um VANT modelo UX4. A câmara hiperespectral tem capacidade de adquirir imagens no intervalo espectral de 500 a 900 nm e possibilidade de obter até 25 bandas espectrais [12]. Durante o voo para aquisição de imagens hiperespectrais foram colocados alvos (Figura 3) para a correção radiométrica (Figura 3.a e 3.b) (alvos: cinza claro, cinza escuro e preto) e correção geométrica (Figura 3.b). Os alvos para correção geométrica das imagens hiperespectrais foram posicionados com receptor GNSS.

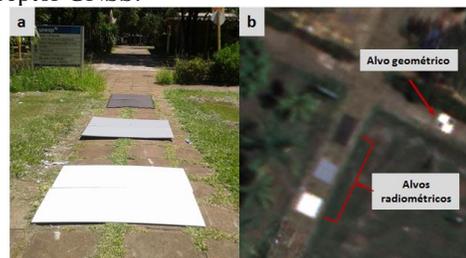


Figura 3. (a) Alvos Radiométricos. (b) Vista aérea de alvos radiométricos e alvo geométrico.

O cubo de imagens hiperespectrais foi processado conforme metodologia de Honkavaara (2013) [13]. Foram selecionadas três bandas para serem fototrianguladas no software Metashape com base no método de ajuste por feixes de raios (Bundle block adjustment). O processo de correção radiométrica das imagens hiperespectrais foi realizado no software desenvolvido por Honkavaara (2013) [13] no qual se faz uma transformação para uma geometria de aquisição padrão com a consequentemente minimização do efeito da Reflectância Bidirecional (Bidirectional Reflectance Distribution Function - BRDF). Esta etapa foi baseada no modelo de Walthall (1985) [14] com a normalização das cenas para minimização dos efeitos de variação de iluminação produzindo um ortofotomosaico. Para realizar essa correção utilizam-se parâmetros de orientação exterior e interior, Modelos Digitais de Superfície (MDS), sendo o modelo com o mesmo Ground Sample Distance (GSD) do cubo de imagens hiperespectrais de 0,10 m, e outro modelo com resolução espacial de 1 m; e parâmetros de correção radiométrica (ângulos azimutal e zenital solares) [13, 15].

A partir de alvos considerados como referência radiométrica nas cenas (Figura 3) foi realizada a calibração radiométrica do ortofotomosaico de imagens hiperespectrais através da linha empírica. A calibração por linha empírica é um método baseado na regressão linear, onde se calcula os fatores de transformação dos números digitais (NDs) em valores físicos [16]. Neste caso os pixels foram transformados para valores de FRHC baseando-se em espectros de referência da biblioteca espectral coletada.

Como as copas de citros não atingiam alturas maiores que onze metros, utilizando o MDS e o software Lastools foi determinado o *Canopy height model* (CHM) que fornece a

altura das copas de árvores. Dessa forma, as árvores com altura maior que 11 metros foram retiradas da imagem hiperespectral através da criação de uma máscara que foi aplicada nas imagens hiperespectrais.

As plantas de citros/murta foram classificadas com base nas imagens hiperespectrais utilizando os seguintes algoritmos de classificação: Constrained Energy Minimization (CEM) [17], Mahalanobis Distance [18], Minimum Distance [19], Orthogonal Subspace Projection (OSP) [20], Parallelepiped [19], Random Forest (RF) [21], Spectral Information Divergence (SID) [22], Spectral Angle Mapper (SAM) [23], e Support Vector Machine (SVM) [24]. O objetivo foi verificar o potencial para discriminação de citros/murta de outras espécies arbóreas. No modelo de classificação foram consideradas as classes: citros, murta e vegetação, que corresponde a outros de tipos de espécies de plantas arbóreas. O controle de qualidade desses mapas foi realizado com base em referência de campo para verificar a acurácia do mapeamento das plantas de citros/murta no qual aplicou-se a matriz de confusão e estatística do coeficiente kappa [25, 26, 27].

3. RESULTADOS

Os espectros coletados são apresentados na Figura 4, e mostram características típicas de vegetação verde, com diferenças sutis na região de 500 a 700 nm, e diferenças maiores na região do infravermelho próximo. Os espectros de citros e murta serão apresentados em dois diferentes grupos, sendo um formado por plantas frutíferas (Figura 4.a) e outro formado por plantas não frutíferas (Figura 4. b). Ainda assim nota-se a complexidade em identificar diferenças espectrais principalmente na região espectral do visível. Nestes gráficos é difícil separar o espectro das plantas de citros (linha preta) e murta (linha vermelha).

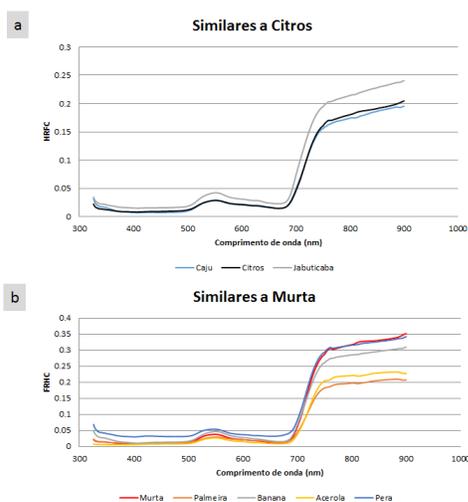


Figura 4. (a) Espectros de plantas similares ao espectro de citros. (b) Espectros de plantas similares ao espectro da murta.

A Figura 5 apresenta o resultado dos algoritmos de classificação.

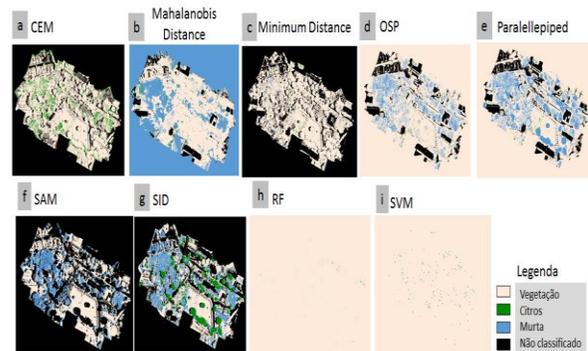


Figura 5. Resultados da Classificação.

A Tabela 1 apresenta a performance dos classificadores de acordo com as referências de campo. Em todas as análises estatísticas baseadas no coeficiente kappa, o resultado não foi satisfatório. Os algoritmos de classificação que apresentaram um melhor desempenho, analisando-se a acurácia, foram o Random Forest (99,414%) e o SVM (98,6221%). No entanto, ao observar cada exemplar de citros e murta presente na área de estudo, o resultado obtido pelo algoritmo SVM apresentou um acerto maior na detecção das plantas de interesse.

Classificadores	Acurácia (%)	Kappa
CEM	85,6606	-0,003
Mahalanobis Distance	66,1124	-0,0004
Minimum Distance	84,0945	0,0031
OSP	66,1243	0,0037
Parallelepiped	40,9461	-0,0001
Random Forest	99,414	0,058
SAM	25,6322	0,0001
SID	28,8486	-0,0028
SVM	98,6221	0,0485

Tabela 1: Performance dos classificadores de acordo com a referência de campo.

4. DISCUSSÃO

No resultado do algoritmo CEM, embora as plantas de citros tenham sido detectadas corretamente, observa-se que houve detecção excessiva de plantas de citros, confundindo-as com outras espécies de vegetação, e nenhuma planta de murta foi detectada corretamente. Das nove plantas de murta, o algoritmo Mahalanobis Distance, detectou apenas cinco delas. O algoritmo Mahalanobis Distance das nove plantas de murta, detectou corretamente cinco plantas de murta. Os algoritmos OSP e Parallelepiped não detectaram apenas uma planta de murta do total de plantas na área de estudo. Em relação aos algoritmos SAM e SID, que são baseados nos espectros dos alvos, observa-se que o SAM detectou consideravelmente as plantas de murta, apesar da confusão na

deteção excessiva de plantas de murta com outras espécies de vegetação. Das nove plantas de murta, sete foram detectadas corretamente, e das duas plantas de citros, foi detectada corretamente uma planta. O algoritmo SID detectou corretamente apenas três plantas de murta do total de plantas, somente uma foi corretamente detectada.

5. CONCLUSÕES

No experimento foi verificado o potencial de imagens hiperespectrais para a discriminação de plantas de citros/murta em ambiente urbano. Dentre os algoritmos de classificação para deteção de citros e murta o que apresentou um desempenho melhor foi o Random Forest, com uma acurácia de 99,414%. Nos resultados dos outros classificadores observou-se a alta confusão na classificação de plantas de citros e murta com outros tipos de espécies de vegetação. Para trabalhos futuros, recomenda-se a inserção de uma nuvem de pontos obtidos com varredura a LASER, o que poderia contribuir para o refinamento do resultado da classificação e parametrização mais adequada dos algoritmos de classificação.

6. AGRADECIMENTOS

A primeira autora agradece pelo apoio financeiro em forma de Bolsa de Pós- doutorado (151486/2018-2) ao CNPQ e à Fundunesp (2530/2016), e), e à FAPESP (processos n. 2013/50426-4 e 2021/06029-7).

7. REFERÊNCIAS

[1] CONAB- Companhia Nacional de Abastecimento. *Levantamentos de safra: laranja. 2015.* Disponível em: <http://www.conab.gov.br/OlalaCMS/uploads/arquivos/13_12_12_09_53_25_boletim_de_laranja.pdf>. Acesso em: abril de 2016.

[2] FUNDECITRUS- Fundo de Defesa da Citricultura. *Manual técnico: Greening.* 12 p., 2009.

[3] E. Feichtenberg; R. B. Bassanezi; M. B. Spósito and J. Belasque Jr. Doenças dos citros. In: H. Kimati, L. Amorim; J. A. M. Rezende; A. Bergamin Filho and L. E. A. Camargo. *Manual de Fitopatologia: doenças das plantas cultivadas.* São Paulo: Ceres, 2005, v. 2, 663 p. (ISBN 85-318.0043-9).

[4] S. Jagoueix; J. M. Bove and M. Garnier. The phloem-limited bacterium of *Greening* disease of citrus is a member of the α subdivision of the proteobacteria. *International Journal of Systematic Bacteriology*, v. 44, n. 3, p. 379-386, 1994.

[5] D. C. Teixeira; J. L. Danet; S. Eveillard; E. C. Martins; W. C. Jr. Jesus; P. T. Yamamoto; A. S. Lopes; R. B. Bassanezi; A. J. Ayres; C. Saillard and J. M. Bové. Citrus huanglongbing in São Paulo State, Brazil: PCR detection of the ‘candidatus’ *Liberibacter* species associated with the disease. *Molecular and Cellular Probes*, n. 19, p. 173-179, 2005.

[6] Jr. J. Belasque; P. T. Yamamoto; M. P. Miranda; R. B. Bassanezi; A. J. Ayres; J. M. Bové. Controle do huanglongbing no estado de São Paulo, Brasil. Citrus research & Technology, v. 31, n. 1, p. 53-64, 2010.

[7] J. Belasque, Jr; A. Bergamin Filho; R. B. Bassanezi; J. C. Barbosa; N. G. Fernandes; P. T. Yamamoto; S. A. Lopes; M. A. Machado; R. P. Leite Jr.; A. J. Ayres and C. A. Massari. Base científica para a erradicação de plantas sintomáticas e assintomáticas de huanglongbing (HLB, *Greening*) visando o controle efetivo da doença. *Tropical Plant Pathology*, v. 34, n. 3, pp. 137-145, 2009.

[8] FUNDECITRUS- Fundo de Defesa da Citricultura. *Controle na área urbana é fundamental para evitar avanço do Greening na área rural.* 2017. Disponível em: <<http://www.fundecitrus.com.br/comunicacao/noticias/integracao/controle-na-area-urbana-e-fundamental-para-evitar-avanco-do-greening-na-area-rural/600>>. Acesso em fevereiro de 2018.

[9] M. Mirik; R. J. Ansley; J. A. Price and F. Workneh; C. Rush. Remote monitoring of wheat streak mosaic progression using sub-pixel classification of Landsat 5 TM imagery for site specific disease management in winter wheat. *Advances in Remote sensing*, v. 2, p. 16-28, 2013.

[10] H. Yao; L. Tang; L. Tian; R. L. Brown.; D. Bhatnagar and T. E. Cleveland. Using hyperspectral data in precision farming applications. In: P. S. Thenkabail and J. G. Lyon; A. Huete. *Hyperspectral remote sensing of vegetation.* New York: CRC Press Taylor & Francis Group, p. 309-327, 2012.

[11] ASD. *FieldSpec@UV/VNIR: HandHeld Spectroradiometer. User’s Guide*, pp.72, 2003.

[12] SENOP LTD. *Rikola Hyperspectral Imager Manual*, 37 p., 2014.

[13] E. Honkavaara; H. Saari; J. Kaivosoja; I. Pölonen; T. Hakala; P. Litkey; J. Mäkinen and L. Pesonen. Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV Spectral Camera for Precision Agriculture. *Remote Sensing*, n. 5, p. 5006-5039, 2013.

[14] C.L. Walthall; J.M. Norman; J.M. Welles; G. Campbell and B.L. Blad. Simple equation to approximate the bidirectional reflectance from vegetative canopies and bare soil surfaces. *Applied Optics*, n. 24, p. 383-387, 1985.

[15] E. Honkavaara; J. Kaivosoja.; J. Mäkinen; I. Pellikka; L. Pesonen; H. Saari.; H. Salo; T. Hakala and L. Markelin; T. Rosnell. Hyperspectral reflectance signatures and point clouds for precision agriculture by light weight UAV imaging system. In: ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Sciences, v. 1-7, 2012, XXII ISPRS Congress, 25 august-01 september, Melbourne, p.353-358, 2012.

[16] R. N. Sahoo, S. Pargal, S. Pradhan, G. Krishna and V. K. Gupta. *Processing of hyperspectral remote sensing data.* New Delhi: Division of Agriculture Physics, Indian Agriculture Research Institute, 72, 2013.

[17] Q. Du and C.I. Chang. A linear constrained distance-based discriminant analysis for hyperspectral image classification. *Pattern recognition*, v. 34, p. 361-373, 2001.

[18] P. C. Mahalanobis. On the generalised distância in statistics. *Proceedings of the National Institute of Sciences of India*, v.2, n. 1, p.: 49-55, 1936.

[19] J. A. Richards AND X. Jia. *Remote Sensing Digital Image Analysis: An Introduction.* [S.I.]: Ed. Springer, 363 p., 1999.

[20] J. C. Harsanyi and C.I. Chang. Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach. *IEEE Transactions on Geoscience and Remote Sensing*, v. 32, n. 4, 1994.

[21] V.F. Rodriguez-Galiano, M. Chica-Olmo, F. Abarca-Hernandez, P. M. Atkinson, C. Jeganathan. Random forest classification of mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. *Remote Sensing of Environment*, n. 121, p. 93-107, 2012.

[22] C. I. Chang. Na information-theoretic approach to spectral variability, similarity, and discrimination for hyperspectral image analysis. *IEEE Transactions on information*, v. 46, n. 5, p. 1927-1932, 2000.

[23] F. A. Kruse, A. B. Lefkoff and J. B. Dietz. Expert System-Based Mineral Mapping in Northern Death Valley, California/Nevada, Using the Airbone Visible/Infrared Imaging Spectrometer (AVIRIS). *Remote Sensing of Environment*, n. 44, 309-336, 1993.

[24] T.F. Wu, C.J. Lin and R. C. Weng. Probability estimates for multi-class classification by pairwise coupling. *Journal of Machine Learning Research*, v. 5, p.975-1005, 2004.

[25] J. A. Cohen. Coeficiente of agrément for nominal scales. *Educational and Psychological Measurement*, v. 20, p. 37-46, 1960.

[26] W. D. Hudson and C. W. Ramm. Correct formulation of the kappa coeficiente of agrément. *Photogrammetric Engineering e Remote Sensing*, v.53, n. 4, p. 421-422, 1987.

[27] R. G. Congalton and K. Green. *Assessing the accuracy of Remotely sensed data: principles and practices.* Lewis publishers, Boca Raton, Florida, 137 p., 1999.