

SENSORES HIPERESPECTRAIS IMAGEADORES E NÃO-IMAGEADORES NO MAPEAMENTO DE ATRIBUTOS FÍSICOS E MATÉRIA ORGÂNICA EM SOLOS TROPICAIS

Marcos Rafael Nanni ¹, José Alexandre Melo Demattê ², Marlon Rodrigues ³, Glaucio Lebozo Alemparte Abrantes dos Santos ⁴, Amanda Silveira Reis ⁵, Karym Mayara de Oliveira ⁶, Everson Cezar ⁷, Renato Herring Furlanetto ⁸, Luís Guilherme Teixeira Crusiol ⁹, João Vitor Ferreira Gonçalves ¹⁰, Caio Almeida de Oliveira ¹¹

¹Universidade Estadual de Maringá - UEM, Maringá, PR, mrnanni@uem.br; ²Universidade de São Paulo – USP, Piracicaba, SP, jamdemat@usp.br; ³Instituto Federal do Paraná – IFPR, União da Vitória, PR, marlon.rodrig@hotmail.com; ⁴UEM, Maringá, PR, glaucio@agronomo.eng.br; ⁵Universidade Estadual do Norte do Paraná – UENP, Bandeirantes, PR, reisamanda89@gmail.com; ⁶UEM, Maringá, PR, eng.karymoliveira@gmail.com; ⁷Universidade do Estado de Minas Gerais – UEMG, Passos, MG, eccarpejani@gmail.com; ⁸Universidade da Flórida, Estados Unidos, renatohfurlanetto@hotmail.com; ⁹Embrapa Soja (Empresa Brasileira de Pesquisa Agropecuária), Londrina, PR, luisguilherme_crusiol@hotmail.com; ¹⁰UEM, Maringá, PR, joaofergo@gmail.com; ¹¹UEM, Maringá, PR, caio_fck@outlook.com.

RESUMO

Avaliamos o uso de reflectância VIS-NIR-SWIR obtida por imagens aéreas hiperespectrais e por sensor hiperespectral não-imageador, na predição da fração granulométrica (areia, silte e argila) e teor de matéria orgânica (MO) de solos tropicais. Foram obtidas imagens aéreas da área experimental com solo descoberto pelo sensor aerotransportado AisaFENIX e coletadas 66 amostras de solo superficial ao longo da área, das quais foram obtidas reflectância espectral utilizando espectrorradiômetro Fieldspec 3 JR. Foi utilizada Partial Least Square Regression (PLSR) para estimativa das frações granulométricas e MO baseada na reflectância do solo, e o modelo resultante foi aplicado a imagem hiperespectral para elaboração de mapas de predição destes atributos. Os modelos PLSR desenvolvidos apresentaram R^2 entre 0,54 e 0,7 para areia, argila e MO, nos dados de ambos os sensores, na etapa de predição. Não obtivemos ajuste para silte. Este estudo gerou com sucesso mapas detalhados de predição de atributos do solo.

Palavras-chave — Análise multivariada, atributos do solo, espectroscopia de solos, PLSR, sensoriamento remoto.

ABSTRACT

We evaluated the use of VIS-NIR-SWIR reflectance obtained by hyperspectral aerial images and by a non-imaging hyperspectral sensor, in the prediction of granulometric fraction (sand, silt and clay) and organic matter (OM) content of tropical soils. Aerial images of the experimental area with bare soil were obtained by the AisaFENIX airborne sensor and 66 samples of topsoil were collected along the area, from which spectral reflectance was obtained using a Fieldspec 3 JR spectroradiometer. Partial

Least Square Regression (PLSR) was used to estimate granulometric fractions and OM based on soil reflectance, and the resulting model was applied to a hyperspectral image for the elaboration of prediction maps of these attributes. The developed PLSR models presented R^2 between 0.54 and 0.7 for sand, clay and OM, in the data of both sensors, in the prediction step. We did not get adjustment for silt. This study successfully generated detailed soil attribute prediction maps.

Key words — Multivariate analysis, soil attributes, soil spectroscopy, PLSR, remote sensing.

1. INTRODUÇÃO

O Brasil possui uma grande diversidade de solos devido a variedade de topografia, biota, clima e materiais de origem que possui, os quais estão entre os fatores de formação do solo. A agricultura está dentre as principais atividades econômicas do Brasil, e o conhecimento dos processos pedogenéticos e classificação de solos são essenciais para otimização do manejo e produtividade do solo [1].

A granulometria e matéria orgânica (MO) são atributos que refletem e influenciam na fertilidade do solo. Estes atributos do solo são convencionalmente determinadas por análise laboratorial. Os resultados são confiáveis, mas onerosos devido a demanda de mão de obra e reagentes, que também podem ser prejudiciais ao meio ambiente. Neste contexto, técnicas de sensoriamento remoto vem sendo estudadas para estimativa destes atributos do solo, método este que proporciona resposta rápida em comparação a análises laboratoriais convencionais, além de não consumir reagentes [2].

Numerosos estudos foram realizados utilizando espectroscopia de reflectância VIS-NIR-SWIR para diferenciar tipos de solo, estimar atributos do solo como

granulometria, matéria orgânica, cor do solo e composição mineral, propriedades bioquímicas, físicas e mineralógicas do solo [3, 4]. Inicialmente, esta técnica era limitada a estudos de laboratório devido às características dos sensores, no entanto, o uso de sensores de campo e aerotransportados aumentou consideravelmente nos últimos tempos [5].

Reflectância espectral de solo coletada por sensores hiperespectrais aerotransportados têm se mostrado promissora para a compreensão de atributos do solo e padrões espaciais [5]. Além disso, permite elaboração de mapas de solo em escala adequada para auxiliar na tomada de decisão de procedimentos agrícolas. Assim, o uso de modelos matemáticos obtidos utilizando dados de sensores hiperespectrais, chamado de mapeamento digital de solo (MDS), é uma técnica alternativa aos mapas de solo tradicionais que podem derivar informações quantificadas de atributos do solo de forma rápida e menos honerosa.

O uso da espectroscopia de solos para predição das características e propriedades do solo tem demonstrado desafios como grande conjunto de dados, efeitos de instabilidade espectral e interferência atmosférica [6], exigindo, portanto, mais investigações científicas. Neste contexto, este trabalho tem como objetivo avaliar o uso de reflectância VIS-NIR-SWIR obtida por imagens aéreas hiperespectrais e por sensor hiperespectral não-imageador, na predição da fração granulométrica (areia, silte e argila) e teor de matéria orgânica (MO) de solos tropicais.

2. MATERIAL E MÉTODOS

A área de estudo se localiza próxima ao município de Piracicaba, estado de São Paulo, Brasil, (coordenadas 22°42'39,16"S, 47°30' 59,3"W), é utilizada para cultivo de cana-de-açúcar e apresenta aproximadamente 135 hectares. O clima é Cwa-úmido subtropical (Köppen), com temperatura média anual de 21,6°C e precipitação anual de 1278 mm (estação meteorológica ESALQ/USP). Os solos existentes na área são: Latossolos, Argissolos e Neossolo, com textura variando de arenosa até argilosa, derivados de rochas sedimentares de argilito, siltito e arenito.

Foram obtidos dados de areia, silte, argila e matéria orgânica (MO) do solo nas camadas de 0 a 20 cm de profundidade em 66 pontos amostrais georreferenciados em grid com espaçamento de 100 m. As amostras de solo foram analisadas quanto ao tamanho das partículas pelo método de pipeta e peneiramento utilizando NaOH 0,1 mol L⁻¹ como agente dispersante. A MO foi obtida pela determinação do teor de carbono orgânico (método de Walkley-Black) e posterior multiplicação pelo fator 1,724 [7].

Para a análise espectral em laboratório, amostras de terra fina seca ao ar (TFSA) foram distribuídas em placas de Petri e submetidas a medidas espectrais utilizando o sensor não-imageador (SNI) hiperespectral ASD Fieldspec 3 Jr (ASD, Boulder, CO, EUA), com o auxílio do acessório Pistol grips, conectado ao Fieldspec por um cabo de fibra óptica, para leituras radiométricas, e a iluminação foi padronizada

utilizando uma lâmpada halógena de 650 W com feixe não colimado, localizada a 35 cm da amostra e um ângulo de 30° em relação ao plano horizontal. A calibração inicial do sensor foi realizada com auxílio da placa Spectralon (Labsphere®). O espectrorradiômetro foi programado para fazer 30 leituras para cada amostra, resultando em uma curva espectral média. Foram realizadas três medidas espectrais por amostra e calculada média aritmética simples das três medidas. O dados foram pré-processados pelo método multiplicative scatter correction (MSC).

Imagens aéreas VIS-NIR-SWIR foram obtidas pelo sensor imageador (SI) hiperespectral AisaFENIX, acoplado a uma aeronave. A área experimental estava desprovida de cobertura vegetal na data de obtenção da imagem. As imagens foram pré-processadas quanto a correção geométrica e radiométrica utilizando o software CaliGeo PRO®. Após a correção atmosférica, realizada pelo software ATCOR-4, as imagens foram transformadas em reflectância. Em seguida foram coletados dados de reflectância espectral nos locais correspondentes a amostragem de solo por meio do software ENVI 5.1. O algoritmo de filtragem e suavização Savitzky-Golay (polinômio de 2ª ordem) foi aplicado aos dados utilizando o mesmo software.

Para ambos os sensores, foram removidos os comprimentos de onda marginais (350–399 e 2361–2500 nm para SNI) e (380–467 e 2128–2500 nm para SI), devido ao ruído [5]. Além disso, para o SI também foram removidos comprimentos de onda entre 1350 e 1400 nm e entre 1800 e 2000 nm devido à interferência nos valores de refletância causada pelo vapor de água atmosférico [8].

A partir do software Unscrambler® (Software CAMO), foi realizada a Análise de Componentes Principais (ACP) para agrupar amostras e identificar outliers. Em seguida, modelos de predição dos teores de areia, silte, argila e MO foram ajustados utilizando o método estatístico Partial Least Square Regression (PLSR). Para tanto, as 66 amostras foram divididas aleatoriamente em subconjuntos para calibração e validação cruzada (46 amostras) e predição de dados (20 amostras). Os parâmetros para avaliação do ajuste do modelo foram o coeficiente de determinação (R²) e RMSE (Root Mean Square Error). Os métodos foram aplicados aos dados de ambos os sensores, individualmente.

Para obter informações visuais qualitativas, também foram elaborados mapas de estimativa dos teores de areia, argila e MO aplicando o modelo matemático gerado pela PLSR (etapa de calibração) à imagem original, por meio da calculadora raster, do software QGIS (QGIS Development Team).

3. RESULTADOS

3.1. Análise estatística descritiva

A Tabela 1 apresenta os resultados da estatística descritiva dos atributos areia, silte, argila e MO. Os coeficientes de variação (CV) apresentaram valores elevados para todos os

atributos avaliados, caracterizando-se como altos para MO, argila e silte e moderados para areia [9].

Atributos	Mínimo	Média	Máximo	DP ⁽¹⁾	CV ⁽²⁾
Areia (g kg ⁻¹)	360	589,8	860	14,1	23,9
Silte (g kg ⁻¹)	20	50,4	180	2,9	58
Argila (g kg ⁻¹)	110	359,5	610	13,7	58
MO (g dm ⁻³)	2,5	8,5	15,2	0,3	41,2

¹Desvio Padrão; ²Coefficiente de Variação (%).

Tabela 1. Estatística descritiva dos atributos do solo.

A alta variabilidade da fração granulométrica é explicada pela influência de diferentes materiais de origem nos solos da região. Já para MO, o alto CV é devido à alta variação da fração granulométrica na área, uma vez que a MO está diretamente ligada ao teor de argila [10].

3.2. PLSR na estimativa da granulometria e MO

A Tabela 2 apresenta os parâmetros de desempenho do modelo obtido para estimativa dos atributos do solo utilizando PLSR, para ambos os sensores. Na etapa de validação cruzada, os dados do SNI e SI apresentaram R² de 0,82 e 0,70 para argila, de 0,73 e 0,69 para areia e de 0,81 e 0,67 para MO, respectivamente, considerados satisfatórios [11]. Além disso, esses resultados corroboram com autores que obtiveram R² acima de 0,61 estudando a capacidade da reflectância espectral obtida por SI, na estimativa de areia, silte e argila [5] e R² de 0,44 para MO, 0,89 e 0,92 para argila e areia, respectivamente, utilizando dados obtidos por SNI [12]. Para silte não foi possível estabelecer um modelo satisfatório, possivelmente porque essa fração, em solos intemperizados, possui diversos minerais, que se confundem com argila, óxidos de Fe e Al, e que podem formar agregados com matéria orgânica [12].

Na etapa de predição dos dados do SNI, os valores de r e R² para argila e MO permaneceram altos (acima de 0,70), para areia foram de 0,84 e 0,54, respectivamente. Estes resultados foram inferiores aos encontrados por autores [5] que obtiveram R² de 0,87, 0,73, 0,67 e 0,95 para modelos de determinação de argila, silte, areia e MO, respectivamente. Para o SI, os modelos para argila, areia e MO apresentaram R² de 0,62, 0,66 e 0,67, respectivamente, corroborando os dados obtidos por autores que também buscaram estimar estes atributos [13, 14].

O RMSE apresentou baixos valores na etapa de predição para todos os atributos avaliados e ambos os sensores, indicando que os modelos apresentam alta capacidade de predição [15] e potencial para serem aplicados em áreas com características geológicas e edafoclimáticas semelhantes. As métricas estatísticas mostraram que, na etapa de predição, o SI apresentou resultados semelhantes ao SNI. Este resultado pode ser considerado promissor, pois a utilização de um sensor imageador permite coleta de maior quantidade de informações da área de estudo, visto que a reflectância espectral pode ser coletada pixel a pixel da imagem.

Atributos	PLSR ⁽¹⁾	r	R ²	RMSE ⁽²⁾
Areia (g kg ⁻¹)	Validação cruzada	0,84	0,73	77,23
	Predição	0,84	0,54	76,04
	Validação cruzada	0,84	0,69	71,48
	Predição	0,82	0,66	81,85
Silte (g kg ⁻¹)	Validação cruzada	0,44	0,21	15,53
	Predição	0,49	0,18	27,08
	Validação cruzada	-0,46	0,05	24,99
	Predição	-0,18	0,06	39,72
Argila (g kg ⁻¹)	Validação cruzada	0,90	0,82	61,13
	Predição	0,92	0,72	66,33
	Validação cruzada	0,84	0,70	81,00
	Predição	0,80	0,62	81,61
MO (g dm ⁻³)	Validação cruzada	0,89	0,81	1,61
	Predição	0,85	0,70	1,74
	Validação cruzada	0,80	0,67	1,78
	Predição	0,85	0,67	2,16

¹Partial Least Square Regression. ²Root Mean Square Error. Os dados sombreados em cinza são referentes ao sensor não-imageador ASD FieldSpec 3 JR e sem sombreado são referentes ao sensor imageador AisaFENIX.

Tabela 2. Parâmetros de desempenho dos modelos PLSR na estimativa de atributos do solo.

3.3. Mapas de atributos do solo obtidos por modelos PLSR

Na Figura 1 são apresentados os mapas de distribuição espacial de atributos do solo elaborados utilizando modelos de regressão PLS. Como os atributos do solo (argila, areia e MO) apresentaram forte correlação com os dados do SI (Tabela 2), foi possível elaborar mapas de estimativa dos atributos do solo, aplicando o modelo PLSR pixel a pixel.

Podemos observar na Figura 1 que os maiores teores de argila foram encontrados nas porções mais altas (e planas) da paisagem e as áreas das porções mais baixas (e mais íngremes) possuem maiores teores de areia. Esses resultados estão de acordo com os resultados encontrados nas amostras analisadas em laboratório e também estão de acordo com autores [16] que, trabalhando na mesma área, encontraram teores de argila no horizonte A variando de 16 a 58%.

Os maiores teores de MO foram encontrados em porções da paisagem com maiores teores de argila. De fato, espera-se que teores de MO estejam relacionados com a textura do solo e apresentem correlação positiva com teores de argila [10].

4. CONCLUSÕES

Os dados de reflectância hiperespectral obtidos por SI e SNI foram capazes de estimar os teores de areia, argila e MO, com precisão (R²) > 0,54, > 0,62 e > 0,67, respectivamente. Não houve ajuste de modelo para silte.

Este estudo gerou com sucesso mapas de predição de atributos do solo com nível de detalhamento pixel a pixel. Considerando o Brasil como país fortemente agrícola e a extensão de áreas agricultáveis que compõem a área total do

país, a possibilidade de gerar mapas detalhados de predição de atributos do solo em larga escala pode ser de grande valor à tomada de decisão quanto ao manejo do solo, em busca da diminuição de custos em insumos e aumento no rendimento de culturas.




Figura 1. Mapa de predição de atributos do solo utilizando modelo PLSR aplicado a imagem hiperespectral.

5. REFERÊNCIAS

[1] E. Cezar, M.R. Nanni, J.A.M. Demattê, M.L. Chicati, R.B. Oliveira, Estimativa de atributos do solo por meio de espectrorradiometria difusa. *Rev. Bras. de Ciênc. do Solo*, 37:858-868, 2013.

[2] J.G. Sousa Junior, J.A.M. Demattê, S.R. Araújo. Modelos espectrais terrestres e orbitais na determinação de teores de atributos dos solos: Potencial e custos. *Bragantia*, 70:610-621, 2011.

[3] J.A.M. Demattê, M.R. Alves, B.C. Gallo, C.T. Fongaro. Detecção de limites de solos por dados espectrais e de relevo. *Rev. Bras. Ciênc. Solo*, 38:718-729, 2014.

[4] R. A. Viscarra Rossel, C. R. Lobsey, C. Sharman, P. Flick, G. McLachlan. Novel proximal sensing for monitoring soil organic C stocks and condition. *Environmental Sci. & Technol.*, 51:5630-5641 2017.

[5] T. Paz-Kagan, E. Zaady, C. Salbach, A. Schmidt, A. Lausch, S. Zacharias, G. Natesco, E. Ben-Dor, A. Karnieli. Mapping the spectral soil quality index (SSQI) using airborne imaging spectroscopy. *Remote Sens*, 7:15748-15781, 2015.

[6] E. Ben-Dor, R.G. Taylor, J. Hill, J.A.M. Dematte, M.L. Whiting, S. Chabrilat, S. Sommer. Imaging spectrometry for soil applications. *Adv. Agron*, 97:321-392, 2008.

[7] P.C. Teixeira, G.K. Donagemma, A. Fontana, W.G. Teixeira. *Manual de Métodos de Análise de Solos*. Embrapa Solos (3ª Ed). Embrapa, Brazil, 2017.

[8] D. Summers, M. Lewis, B. Ostendorf, D. Chittleborough. Visible near-infrared reflectance spectroscopy as a predictive indicator of soil properties. *Ecol. Indic.*, 11:123-131, 2011.

[9] M.E. Harr. *Reliability-based design in civil engineering*. New York: McGraw-Hill, United States, 1987.

[10] C. Palm, P. Sanches, S. Ahamed, A. Awiti. Soils: A Contemporary Perspective. *Annu. Rev. Environ. Resour.*, 32:99-129, 2007.

[11] B. Minasny, A. McBratney. *Why you don't need to use RPD*. Pedometron, 2013.

[12] M.R. Nanni, E. Cezar, C.A.D. Silva Junior, G.F.C. Silva, A.A.S. Gualberto. Partial least squares regression (PLSR) associated with spectral response to predict soil attributes in transitional lithologies. *Arch. of Agron. and Soil Sci.*, 64:682-695, 2017.

[13] C. Gomez, R. Oltra-Carrió, S. Bacha, P. Lagacherie, X. Briottet. Evaluating the sensitivity of clay content prediction to atmospheric effects and degradation of image spatial resolution using Hyperspectral VNIR/SWIR imagery. *Remote Sensing of Environ.*, 164:1-15, 2015.

[14] W. Schwanghart, T. Jarmer. Linking spatial patterns of soil organic carbon to topography: a case study from south-eastern Spain. *Geomorphology*, 126:252-263, 2011.

[15] R. S. Boschi, F.F. Bocca, M.L.R.C. Lopes-Assad, E.D. Assad. How accurate are pedotransfer functions for bulk density for *Brazilian soils*. *Sci. Agric.*, 75:70-78, 2018.

[16] P. Vidal-Torrado, I.F. Lepsch. Relações material de origem/solo e pedogênese em uma sequência de solos predominantemente argilosos e latossólicos sobre psamitos na Depressão Periférica Paulista. *Rev. Bras. de Ciên. do Solo*, 23:357-369, 1999.