

FUSÃO DE DADOS DE CONDUTIVIDADE ELÉTRICA E IMAGENS SENTINEL 2A PARA CARACTERIZAÇÃO DA TEXTURA DO SOLO

TIAGO R. TAVARES¹, MATEUS T. EITELWEIN², MAURÍCIO MARTELLO³, RODRIGO G. TREVISAN², JOSÉ P. MOLIN⁴

¹ Eng^o Agrônomo, Doutorando, Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas, USP/ESALQ, Piracicaba – SP , tiagosrt@usp.br.

² Eng^o Agrônomo, Smart Agri Soluções Tecnológicas, Av. Limeira, 1131, 3^a sala, 13414-018, Piracicaba -SP.

³ Eng^o Ambiental, Doutorando, Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas, USP/ESALQ, Piracicaba – SP .

⁴ Eng^o Agrícola, Professor, Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas, USP/ESALQ, Piracicaba – SP.

Apresentado no
Congresso Brasileiro de Agricultura de Precisão- ConBAP 2018
Curitiba, Paraná, 2 a 4 de outubro de 2018

RESUMO: Técnicas de sensoriamento do solo permitem a obtenção de dados em alta densidade espacial e podem auxiliar às técnicas tradicionais de mapeamento do solo para uma caracterização fidedigna de seus atributos. Atualmente, dentre as técnicas de sensoriamento, recebem destaque a condutividade elétrica aparente (CEa) e o imageamento utilizando sistemas sensores orbitais. Processos de fusão de dados permitem que essas técnicas sejam utilizadas de maneira complementar para caracterização de alguns atributos do solo. O objetivo deste trabalho é explorar o potencial preditivo de atributos texturais do solo utilizando dados de CEa, imagens orbitais de alta resolução, bem como por modelos de combinação de dados, explorando o sinergismo entre ambos sensores. O trabalho foi executado em duas áreas comerciais de produção de grãos e fibras no estado do Mato Grosso, foram obtidas informações de CEa, imagens do satélite Sentinel 2A, bem como da textura do solo via amostragem e análises laboratoriais. Ambas as técnicas (CEa e sensores orbitais) apresentaram desempenhos satisfatórios para o mapeamento da textura, apresentando resolução espacial da aquisição de dados adequada e boas relações entre a resposta do sensor e os atributos texturais. Além disso, a técnica de fusão de dados utilizada permitiu criar um modelo mais robusto, com menor erro em comparação aos modelos individuais, sugerindo a complementariedade destes sensores para predição da textura do solo.

PALAVRAS-CHAVE: sinergismo entre sensores; fertilidade do solo; sensoriamento do solo.

DATA FUSION OF ELECTRICAL CONDUCTIVITY AND SENTINEL 2A IMAGES FOR SOIL TEXTURE CHARACTERIZATION

ABSTRACT: Soil sensing techniques allow obtaining data in high spatial density and can aid the traditional techniques of soil mapping for a reliable characterization of soil attributes. Currently, among the sensing techniques, the apparent electrical conductivity (ECa) and the imaging using orbital sensor systems are highlighted. These techniques can work in a complementary way for soil characterization, in addition data fusion techniques allow to explore the synergism between sensors. The objective of this work is to explore the predictive potential for the soil textural attributes using ECa data, high-resolution orbital images, as well as data fusion models, exploring the synergism between both sensors. The work was carried out in two commercial fields of grains and fibers production in Mato Grosso state. ECa data, Sentinel 2A and PlanetScope images, likewise soil texture information were obtained. Both sensing techniques (ECa and orbital sensors) showed satisfactory performances to predict and map the spatial variability of sand and clay content, with a satisfactory spatial resolution of data acquisition and with good relationship between data and the soil texture. In addition, the data fusion technique allowed to create a more robust model, with less error compared to the individual models, suggesting the complementarity of these sensors to predict soil texture.

KEYWORDS: synergism between sensors; soil fertility; soil sensing

INTRODUÇÃO

Técnicas de sensoriamento (proximal e remoto) têm recebido grande destaque como alternativa prática e barata para a avaliação da variabilidade de atributos do solo (DEMATTÊ et al., 2015), pois permite a coleta de dados em escalas refinadas (ex.: > 20 amostras ha⁻¹), inexequíveis em métodos tradicionais de mapeamento de solo (VISCARRA ROSSEL e BOUMA, 2016). A obtenção de informações do solo em alta densidade espacial possibilita a execução de estratégias analíticas, tal como o uso de amostragens direcionadas (FORTES et al. 2015) associada a técnicas de cokrigagem (WEBSTER e OLIVER, 2007), que em alguns casos podem permitir o aumento da acurácia do mapeamento de seus atributos com reduzido número de amostras de solos a serem coletadas e enviadas a laboratório (MORAL et al., 2010; SANCHES et al. 2018).

O sensoriamento remoto (SR) permite o diagnóstico da variabilidade espacial e temporal de grandes extensões agrícolas (SEELAN et al., 2003), avaliando a variabilidade de atributos de solos por meio de variações em sua resposta espectral (WARREN e METTERNICHT, 2005). Esta forma de sensoriamento apresenta boas correlações com atributos texturais (DEMATTÊ et al., 2007). Recentemente imagens orbitais têm recebido destaque na agricultura de precisão (AP) devido aos avanços em resolução espacial e temporal de sistemas sensores orbitais, assim como pelo aumento da oferta de imagens orbitais por empresas comerciais (HOUBORG et al., 2016). Dentre as técnicas de sensoriamento proximal do solo, os sensores de condutividade elétrica aparente (CEa) se destacam por sua praticidade de uso e difusão no mercado de AP. Estes sensores avaliam a capacidade do solo conduzir carga elétrica, mensurando esta grandeza em mS m⁻¹, a qual reflete alterações nas propriedades físicas e químicas do solo, tal como textura, umidade e salinidade (ADAMCHUK et al. 2004). Em solos nacionais, a resposta deste sensor está associada principalmente à variabilidade de textura e umidade (MACHADO et al., 2006; MOLIN e RABELO, 2011).

Sensores com princípios de funcionamento distintos - tal como CEa e SR - apresentam potencial para trabalharem de maneira integrada, explorando sua sinergia, o que pode promover incrementos satisfatórios em modelos de predição de atributos do solo (O'ROURKE et al., 2016). Para tal, devem ser empregadas técnicas analíticas de fusão de dados (GRANGER e RAMANATHAN, 1984).

Assim, a motivação para execução deste trabalho se baseou no potencial de utilização de imagens orbitais de alta resolução para avaliação da variabilidade do solo, as quais foram pouco exploradas nacionalmente; assim como a possível sinergia entre estas informações e as de CEa para caracterização da textura em solos tropicais. Desta forma, os objetivos deste trabalho foram explorar a utilização de imagens do satélite Sentinel 2A para a caracterização da textura do solo, comparando seu potencial com sensores de CEa; bem como avaliar o sinergismo entre sensores orbitais e de CEa para determinação da textura do solo, através de modelos de predição utilizando fusão de dados.

MATERIAL E MÉTODOS

As avaliações foram conduzidas em duas áreas comerciais de produção de grãos e fibras. A primeira área (Área 1) se localiza no município de Campo Novo do Parecis - MT, com coordenadas centrais de 14° 6' 9" S e 57° 45' 46" O, abrangendo um talhão de 138 hectares de solo classificado como Latossolo Vermelho de textura oscilando entre franco argilosa e franco argilo-arenosa. A segunda área (Área 2) se localiza no município de Campo Verde - MT, envolve dois talhões que somam 345 hectares e apresenta coordenadas centrais de 15° 14' 45" S e 54° 58' 9" O. O solo predominante nesta segunda área é o neossolo quartzarênico de textura arenosa. Segundo a classificação de Köppen-Geiger, o clima na região de ambas as áreas é do tipo Aw: clima tropical com estação úmida e seca, neste caso, a estação seca ocorre durante o inverno.

Na Área 1 os dados de CEa da camada de 0-30 cm foram coletados utilizando a plataforma multisensores Veris MSP® (Veris Technologies, Salina, Kansas, USA). Esta coleta foi realizada no mês de março de 2016, logo após a colheita de soja, e após a estação chuvosa, portanto, com baixo teor de umidade no solo. A frequência de coleta foi de 1 Hz, a uma velocidade média de deslocamento de 5 m s⁻¹ e distância entre passadas de 20 m, resultando em uma coleta de dados com resolução espacial de 100 m² (5 x 20m) e uma densidade de aproximadamente 260 pontos ha⁻¹. Na Área 2, os dados de CEa de 0-30 cm foram coletados em janeiro de 2015, também após a colheita de soja, utilizando o equipamento Veris 3100® (Veris Technologies, Salina, Kansas, USA). A distância entre passadas foi de 12 m, a uma velocidade de 4 m s⁻¹ e taxa de aquisição de 1 Hz, totalizando em 48 m² (4 x 12m) de resolução espacial e cerca de 200 pontos ha⁻¹. Os dados brutos de CEa foram filtrados para remoção de erros, utilizando o software MapFilter (SPEKKEN et al., 2013) e interpolados por krigagem, usando o software Vesper 1.63 (MINASNY et al., 2005). Buscou-se respeitar a resolução espacial da aquisição de dados para gerar a malha para krigagem, sendo que para a Área 1 o pixel apresentou 10 m e para a Área 2, 7 m.

Após a elaboração dos mapas de CEa, alocou-se os pontos para amostragem de solo (0 a 15 cm de profundidade) em ambas as áreas. Estas amostras foram posteriormente enviadas a laboratório para quantificação da porcentagem de argila e areia, determinada por densímetro em solução dispersante. Na Área

2, foram alocados 20 pontos de modo que representassem toda a variabilidade exibida na CEa, seguindo metodologia de Portz et al. (2012). Já na Área 1, foi selecionada no interior do talhão uma região de 18,26 ha com expressiva variabilidade de CEa para amostragem de solo em alta densidade. Nesta região foram alocados 347 pontos de amostragem (Figura 1), as quais foram coletadas em distância média de 22 m na linha e 20 m entre linhas (~22 amostras ha⁻¹); amostras utilizadas para a calibração dos modelos de predição. Também foram coletadas 10 amostras aleatórias ao longo da Área 1 (Figura 1) utilizadas posteriormente para a validação dos modelos de predição gerados.

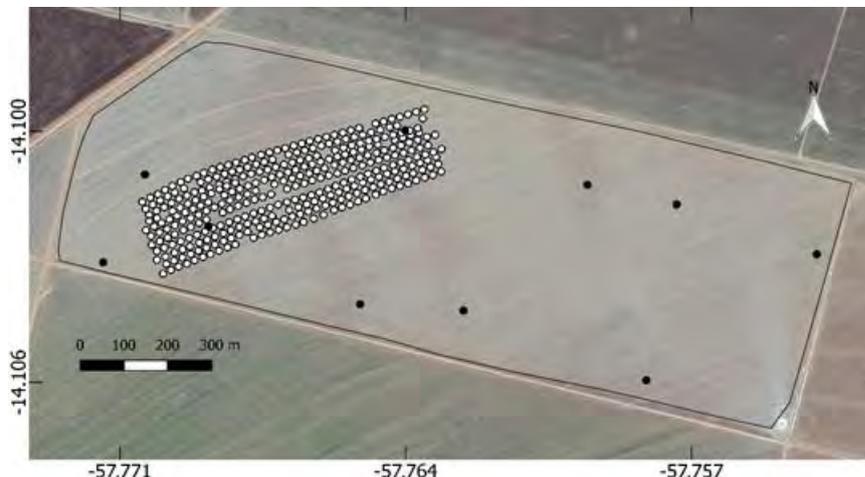


FIGURA 1. Pontos de amostragem na Área 1. Em branco, os 347 pontos amostrados para calibração dos modelos; em preto, os 10 pontos amostrados para validação dos modelos.

Para caracterização da textura via sensoriamento remoto, foram obtidas imagens do satélite Sentinel-2A. Foram obtidas imagens Sentinel dos dias 25/05/2016 e 15/11/2017 para a Área 1 e 2, respectivamente. Em ambas as imagens as áreas não se encontravam com cultura e para confirmação da presença de solo exposto foi realizada análise da linha do solo para todas as imagens, seguindo metodologia adaptada de Shabou et al. (2015). Pontos discrepantes da linha de solo foram filtrados e o valor dos pixels recalculado utilizando geoestatística.

As imagens Sentinel adquiridas correspondem ao produto “Level-1C”: imagens ortorretificadas na projeção UTM/WGS84, com informação de reflectância do topo da atmosfera. Foi executada a correção atmosférica DOS1 (Dark Object Subtraction) utilizando o plugin Semi-Automatic Classification Plugin (CONGEDO, 2016) do software QGIS. Foram utilizadas as bandas 2 (azul: 490 nm), 3 (verde: 560 nm e 10 m), 4 (vermelho: 665 nm e 10 m), 5 (*red-edge* 1: 705 nm e 20 m), 6 (*red-edge* 2: 740 nm e 20 m), 7 (*red-edge* 3: 783 nm e 20 m) e 8 (NIR: 842 nm e 10 m), 11 (SWIR 1: 1610 nm e 20 m) e 12 (SWIR 2: 2190 nm e 20 m). A resolução espacial de todas as bandas foi padronizada em 20 m, o que representa uma densidade espacial de 25 pixels ha⁻¹.

Foi avaliada a estatística descritiva, bem como as correlações entre os dados texturais de laboratório e os obtidos com os métodos de sensoriamento. As análises de correlação foram realizadas com Modelos de regressão foram calibrados para predição do teor de areia e argila utilizando a CEa e as informações espectrais. A calibração dos modelos foi realizada com 70% das amostras - escolhidas aleatoriamente - e a validação com as demais. Para a CEa utilizou-se regressão linear simples. Para os dados espectrais avaliou-se modelos de regressão simples com cada banda individualmente e regressões múltiplas com as bandas que obtiveram correlação significativa com os atributos a serem estimados.

O sinergismo entre sensores foi explorado utilizando o método de fusão de dados de Granger e Ramanathan (GRANGER e RAMANATHAN, 1984). Este método é relativamente simples em comparação às demais abordagens de modelagem conjunta disponíveis na literatura, porém têm apresentado resultados igualmente eficientes (DIKS e VRUGT, 2010, HORTA et al., 2015). Para esta modelagem conjunta são utilizados os valores das predições feitas por cada um dos sensores e o valor real do atributo predito, criando um modelo de regressão linear múltipla com estas informações (Equação 1).

$$Y = W_0 + (W_{CEa} * X_{CEa}) + (W_{imagem} * X_{imagem}) \quad (1)$$

em que: Y é a propriedade de solo a ser estimada; X_{CEa} e X_{imagem} são as predições realizadas pelos dois modelos previamente calculados; e W₀, W_{CEa} e W_{imagem} são os parâmetros da regressão múltipla a serem determinados

pelos métodos dos quadrados mínimos, onde o primeiro parâmetro é o valor do intercepto da reta e, os demais, os pesos dos modelos de predição de ambos os sensores.

As figuras de mérito (R^2 e RMSE) foram calculadas e avaliadas para todos os modelos de predição. A fusão de dados foi realizada com as predições de areia e argila da regressão linear simples de CEa e a regressão do modelo com as imagens orbitais que apresentou maior R^2 e menor RMSE. Por fim, buscando avaliar o desempenho dos modelos calibrados para Área 1, estes foram extrapolados para os dados de sensoriamento (CEa e imagens) de todo o talhão, onde para sua avaliação, comparou-se o valor predito com a análise textural de laboratório com as 10 amostras coletadas para validação.

RESULTADOS E DISCUSSÃO

Variabilidade espacial da textura

Ambas as áreas apresentaram coeficiente de variação de argila acima de 15% (Tabela 2). A Área 1 apresentou amplitude dos teores de argila oscilando entre 175 e 352 g dm^{-3} e a Área 2 entre 51 e 164 g dm^{-3} , evidenciando que nas áreas estão presentes solos de diferentes classes texturais. A assimetria dos dados de argila, para ambas as áreas, foi ligeiramente positiva (0,20) - indicando uma menor frequência de valores próximos ao máximo. A amplitude de variação de areia foi semelhante ao de argila para ambas as áreas, marcado pelo desvio padrão próximos.

TABELA 2. Estatística descritiva dos atributos texturais, CEa e bandas dos satélites utilizados para a Área 1 e 2.

	Areia*	Argila*	CEa*	Sentinel 2A*								
				B2	B3	B4	B5	B6	B7	B8	B11	B12
----- Área 1 -----												
Mínimo	618	150	0,68	0,037	0,057	0,108	0,109	0,122	0,135	0,132	0,269	0,192
Média	719	256	1,39	0,041	0,065	0,121	0,123	0,137	0,151	0,146	0,291	0,214
Máximo	810	353	2,75	0,048	0,078	0,149	0,154	0,171	0,187	0,178	0,320	0,234
Desvio pad.	40	41	0,38	0,003	0,004	0,007	0,007	0,009	0,009	0,008	0,012	0,009
CV (%)	6	16	27	6	7	6	6	6	6	6	4	4
Assimetria	-0,21	0,19	0,54	0,35	0,48	0,79	0,71	0,76	0,71	0,64	0,15	-0,02
----- Área 2 -----												
Mínimo	733	51	0,29	0,043	0,059	0,106	0,115	0,124	0,145	0,142	0,277	0,256
Média	849	100	1,39	0,055	0,076	0,132	0,142	0,157	0,181	0,184	0,398	0,335
Máximo	912	164	5,27	0,092	0,119	0,190	0,200	0,224	0,261	0,260	0,505	0,439
Desvio pad.	45	30	0,45	0,005	0,007	0,013	0,013	0,016	0,018	0,017	0,024	0,027
CV (%)	5	30	32	9	9	9	9	10	10	9	6	8
Assimetria	-1,00	0,25	0,91	1,46	1,21	1,13	1,08	0,94	0,94	0,95	1,02	1,13

* Teores de argila e areia expressos em g dm^{-3} , CEa expressa em $mS\ m^{-1}$, valores das bandas do satélite Sentinel expressos em fator de reflectância; e CV corresponde ao coeficiente de variação, também em porcentagem.

Avaliação de solo exposto nas imagens orbitais

O conceito de linha de solo é amplamente utilizado para a avaliação de solo exposto em imagens orbitais (BARET et al., 1993) e foi utilizada neste trabalho como estratégia analítica para confirmar a presença de solo exposto nas imagens adquiridas. Este conceito se baseia na relação linear entre a reflectância do vermelho e do infravermelho próximo (NIR) que o solo apresenta, sendo que a dispersão de pontos no gráfico deve encontrar-se numa faixa ao longo de 45° do eixo x (coeficiente angular da reta igual a 1,0) e com valores de R^2 também próximos a 1,0 (NANNI e DEMATTÊ, 2006). O gráfico de dispersão com os valores das bandas do vermelho e do NIR das imagens utilizadas estão plotados na Figura 2A e B. A dispersão destes pontos obedeceu o comportamento espectral esperado de solo exposto, com coeficiente angular da reta oscilando entre 0,91 e 1,09 e R^2 entre 0,81 e 0,95.

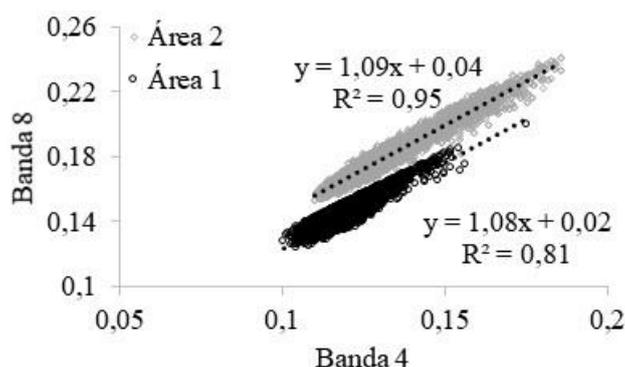


FIGURA 2. Linhas de solo obtidas com as imagens Sentinel para as Áreas 1 e 2. Eixo x referente ao comportamento espectral dos pixels da banda do vermelho e o eixo y da banda do infravermelho próximo.

Relação entre textura e técnicas de sensoriamento

A correlação dos atributos texturais com a CEa foi significativa em ambas as áreas, com uma correlação moderada na Área 1 (-0,52 para areia e 0,51 para argila) e forte na Área 2 (-0,94 para areia e 0,76 para argila) (Tabela 3). A diferença de desempenho da CEa nas duas áreas pode estar relacionada ao gradiente de umidade presente no solo no momento em que ambas foram sensoriadas, uma vez que a Área 1 foi avaliada no início do período de estiagem, com baixa umidade e a segunda área foi sensoriada em janeiro, período ainda chuvoso. A CEa aumenta sua sensibilidade à textura em solos que apresentam umidade, pois maiores valores de água estão presentes em texturas mais argilosas e, conseqüentemente, uma maior CEa. Esta inferência também é evidenciada pela amplitude de variação da CEa em ambas as áreas (Tabela 2), a qual foi maior para a Área 2, mesmo esta apresentando textura mais arenosa, o que presumiria uma menor CEa em relação a Área 1, caso o efeito da água fosse proporcional.

TABELA 3. Correlação entre atributos texturais, CEa e imagens orbitais para a Área 1 e 2.

	Areia	Argila	CEa	B2	B3	B4	B5	B6	B7	B8	B11	B12
----- Área 1 -----												
Areia	1,00	-0,98	-0,52	0,70	0,68	0,59	0,60	0,59	0,59	0,58	0,71	0,79
Argila		1,00	0,51	-0,69	-0,67	-0,58	-0,59	-0,58	-0,58	-0,57	-0,70	-0,78
CEa			1,00	-0,34	-0,30	-0,18	-0,18	-0,17	-0,18	-0,19	-0,33	-0,45
----- Área 2 -----												
Areia	1,00	-0,83	-0,94	0,46	0,40	0,29	0,11	0,11	0,14	0,25	0,69	0,67
Argila		1,00	0,87	-0,64	-0,60	-0,57	-0,41	-0,43	-0,63	-0,59	-0,72	-0,74
CEa			1,00	-0,43	-0,35	-0,23	-0,04	-0,04	-0,07	-0,20	-0,62	-0,57

Valores em negrito indicam coeficiente de correlação significativo ($P < 0,01$).

Na Área 1 todas imagens do satélite Sentinel 2A apresentaram correlação significativa com os atributos texturais, sendo que as bandas 2, 11 e 12 (azul, SWIR 1 e SWIR 2, respectivamente) apresentaram correlação alta ($\geq 0,70$) (Tabela 3). Já na Área 2, algumas bandas não apresentaram correlação significativa com a textura e apenas as bandas 11 e 12 apresentaram correlação alta com o teor de argila. Estes resultados sugerem que embora bandas do infravermelho de ondas curtas (SWIR) apresentem maior sensibilidade para a predição de atributos texturais - conforme observado por Franceschini et al. (2013) e também pelo presente trabalho - bandas na região do visível podem apresentar boas relações com atributos texturais uma vez que diferenças granulométricas do solo promovem alterações espectrais de albedo em toda curva espectral Vis-NIR-SWIR (LACERDA et al. 2016).

TABELA 4. Desempenho das regressões para predição de areia e argila utilizando o sensor de CEa, imagens orbitais, bem como da fusão de dados entre CEa e imagens orbitais.

	Área 1				Área 2				
	Areia		Argila		Areia		Argila		
	R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE	
CEa ¹	0,27	34,3	0,26	35,2	CEa ¹	0,89	14,5	0,77	14,0
B2 ¹	0,50	28,4	0,47	29,6	B2 ¹	0,22	39,1	0,42	22,0
B3 ¹	0,47	29,3	0,45	30,4	B3 ¹	-	-	0,36	50,3
B4 ¹	0,35	32,3	0,34	33,3	B4 ¹	-	-	0,34	50,1
B5 ¹	0,35	32,2	0,34	33,2	B7 ¹	-	-	0,41	50,6
B6 ¹	0,34	32,4	0,34	33,3	B8 ¹	-	-	0,35	50,2
B7 ¹	0,35	32,4	0,34	33,3	B11 ¹	0,48	32,0	0,51	51,5
B8 ¹	0,33	32,7	0,33	33,6	B12 ¹	0,45	32,9	0,56	51,9
B11 ¹	0,50	28,3	0,49	29,3	RM ²	0,52	30,5	0,75	14,3
B12 ¹	0,63	24,4	0,61	25,7	Fusão ³	0,92	12,9	0,86	10,9
RM ²	0,65	23,7	0,63	25,0					
Fusão ³	0,71	21,5	0,69	22,7					

¹ Regressão linear simples entre a resposta do sensor e o atributo do solo; ² Regressão linear múltipla entre as bandas com correlação significativa e o atributo do solo; ³ Fusão de dados utilizando metodologia de Granger e Ramanathan (1984) aplicada à regressão simples com a CEa e a regressão com as imagens orbitais que obteve melhores figuras de mérito.

Para Área 1 os três modelos mais promissores (com maior R² e menor RMSE) para a predição tanto de areia, quanto de argila, foram: utilizando fusão de dados, regressão múltipla e a regressão linear simples com a banda 12 (SWIR 2) (Tabela 4). Já para a Área 2 os mais promissores foram: fusão de dados, regressão linear simples com a CEa e regressão múltipla (Tabela 4). Assim, em ambas as áreas o melhor modelo de predição foi obtido utilizando o modelo de Granger e Ramanathan para fusão de dados de CEa e das imagens orbitais. Por sua vez, o modelo que apresentou segundo melhor desempenho não foi unânime para ambas as áreas, sendo obtido com os dados de CEa em uma das áreas e com com imagens orbitais na outra, mostrando que ambas as técnicas tem potencial para predição textural, porém cuidados devem ser tomados para a interpretação destas informações uma vez que sua relação entre causa e efeito da resposta do sensor com a textura do solo é dependente de outros fatores, tais como: (i) umidade do solo no caso da CEa e (ii) solo exposto no caso das imagens orbitais. Assim, mesmo com cuidados na aquisição destas informações com os sistemas sensores, validações de campo são primordiais para garantirmos modelos de predição confiáveis.

Validação dos modelos de predição de argila para Área 1

Para avaliar a replicação dos modelos de predição de argila com os dados de CEa, imagens orbitais e fusão de dados em área total, comparou-se o resultado de sua predição com os teores de argila e areia obtidos de laboratório em 10 pontos amostrados ao longo do talhão (Figura 1). O desempenho da replicação apontou novamente o modelo gerado com a fusão de dados como o mais promissor, apresentando o menor RMSE (Figura 3), reduzindo o erro de predição em pelo menos 10 g dm⁻³ ao ser comparado com o RMSE dos demais modelos. Estes resultados sugerem que a fusão de dados, explorando o sinergismo entre sensores, permite gerar modelos mais robustos para a predição de atributos de solo. Segundo O'Rourke et al. (2016), a combinação de predições realizada por equipamentos distintos permite a obtenção de resultados que sejam pelo menos tão bom quanto, ou melhor que qualquer um dos resultados individuais. Embora os resultados sejam promissores, novas investigações devem ser conduzidas para um melhor entendimento do ganho de desempenho ao explorarmos o sinergismo entre sensores. Comenta-se também que embora o modelo de fusão de dados aplicado neste trabalho seja relativamente simples de execução, sendo uma estratégia analítica a ser considerada quando os dados de mais de um sistema sensor estão disponíveis, a redução do erro observada foi relativamente pequena (~10 g dm⁻³) e deve ser levada em consideração.

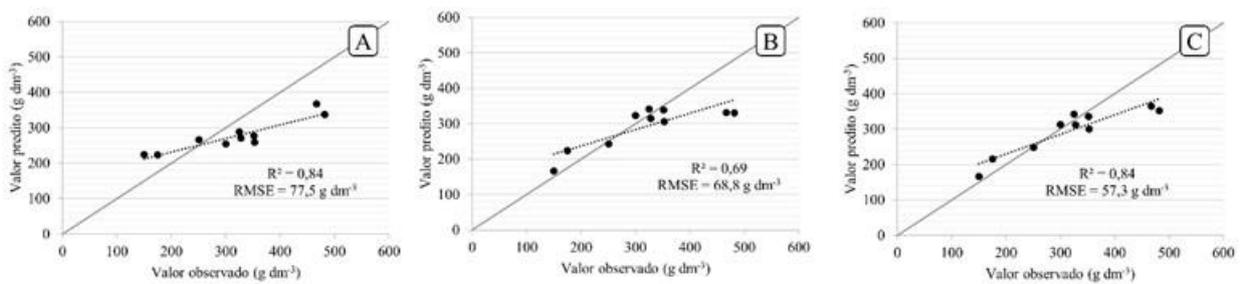


FIGURA 3. Validação da predição do teor de argila utilizando 10 pontos amostrados na Área 1. Modelo linear simples com a CEa (A); o modelo de regressão linear múltipla utilizando todas as bandas do satélite Sentinel (B) e o modelo com fusão de dados envolvendo ambas as predições já citadas e a metodologia de Granger e Ramanathan (1984) (C).

A CEa é uma ferramenta conhecida pela comunidade de AP para caracterização da variabilidade do solo. Ela permite mensurações on-the-go de maneira prática com a obtenção de informações em alta resolução espacial, as quais têm apresentado bons coeficientes de determinação com os atributos texturais; R^2 entre 0,78 e 0,95 (MACHADO et al., 2006; MOLIN e RABELLO, 2011; EITELWEIN, 2017). Por outro lado, a caracterização do solo via imagens orbitais do solo exposto ainda é pouco explorada pela comunidade de AP no Brasil. Pesquisas nacionais, explorando os satélites Landsat e ASTER, já apontaram o potencial desta ferramenta para determinação de atributos texturais em solos tropicais (DEMATTÊ et al., 2007; SOUSA JUNIOR et al., 2011). Neste sentido, a evolução dos sistemas sensores orbitais em resolução espacial, temporal e espectral, a qual temos visto nos últimos anos e que vem tornando ainda mais acessíveis seus dados (HOUBORG e Mc CABE, 2016; ONOJEGHUO et al., 2018), deve incentivar a comunidade de usuários e pesquisadores a buscarem e avaliarem estratégias analíticas de aplicação de imagens orbitais de alta resolução em abordagens de AP. Os dados apresentados neste trabalho mostram o potencial de ambas estas ferramentas de sensoriamento, bem como a possibilidade do uso de ambas como técnicas complementares.

Por último, vale ressaltar que embora trabalhos nacionais relatem que sensores ópticos e de CEa têm relações mais concisas com atributos texturais, em nível local podem ser observadas correlações consideráveis com outros atributos do solo, tal como relatado para pH (SANCHES et al., 2018), P (MOUAZEN et al., 2007), K, Ca e Mg (TAVARES et al., 2016). Assim, em alguns casos, determinações indiretas de nutrientes podem ser observadas utilizando técnicas de sensoriamento do solo, o que abre precedentes para a utilização destas ferramentas como técnicas auxiliares ao método tradicional de diagnóstico da fertilidade do solo - tal como explorado por Sanches et al., 2018 - que sempre será limitado em densidade espacial de dados devido aos custos das análises laboratoriais e por sua dificuldade operacional (Mc BRATNEY et al. 2003).

CONCLUSÃO

Informações obtidas pelo satélite Sentinel 2A, bem como a CEa, se mostraram promissoras para o mapeamento da textura do solo, sendo coerentes tanto em resolução espacial, quanto na relação entre resposta do sensor e atributo a ser mapeado. A utilização da técnica de fusão de dados de CEa e imagens orbitais permite a obtenção de modelos mais robustos, com menores erros de predição da textura, mostrando a complementariedade de ambas as técnicas.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) por fornecer a bolsa de estudos do primeiro e segundo autor (Processos nº 2017/21969-0 e 2014/10737-3, respectivamente), à empresa Terra Santa Agro S.A. e ao Grupo Bom Futuro por cederem as áreas de teste.

REFERÊNCIAS

- ADAMCHUK, V. I. et al. On-the-go soil sensors for precision agriculture. **Computers and electronics in agriculture**, v. 44, n. 1, p. 71-91, 2004.
- BARET, F.; JACQUEMOUD, S.; HANOCQ, J. F. The soil line concept in remote sensing. **Remote Sensing Reviews**, v. 7, n. 1, p. 65-82, 1993.
- CAMBARDELLA, C. A. et al. Field-scale variability of soil properties in central Iowa soils. **Soil science society of America journal**, v. 58, n. 5, p. 1501-1511, 1994.

CONGEDO, L. Semi-automatic classification plugin documentation. 2016. DOI: <http://dx.doi.org/10.13140/RG.2.2.29474.02242/1>

CHERUBIN, M. R.; SANTI, A. L.; EITELWEIN, M. T.; AMADO, T. J. C.; SIMON, D. H.; DAMIAN, J. M. Dimensão da malha amostral para caracterização da variabilidade espacial de fósforo e potássio em Latossolo Vermelho, **Pesquisa Agropecuária Brasileira**, v.50, n. 2, p.168-177, 2015.

DEMATTE, J. A. M. et al. Quantification of tropical soil attributes from ETM+/landsat-7 data. **International Journal of Remote Sensing**, v. 28, n. 17, p. 3813-3829, 2007.

DEMATTE, J. A. M.; ALVES, M. R.; GALLO, B. C.; FONGARO, C. T.; SOUZA, A. B.; ROMERO, D. J.; SATO, M. V. Hyperspectral remote sensing as an alternative to estimate soil attributes. **Revista Ciência Agrônômica**, v. 46, n. 2, p. 223–232, 2015.

DIKS, C.G.H., VRUGT, J.A. Comparison of point forecast accuracy of model averaging methods in hydrologic applications. **Stochastic Environmental Research and Risk Assessment**, v. 24, p. 809–820, 2010.

EITELWEIN, M. T. Sensoriamento proximal de solo para a quantificação de atributos químicos e físicos (Tese de doutorado, Universidade de São Paulo), 2017.

FRANCESCHINI, M. H. D.; DEMATTE, J. A. M.; SATO, M. V.; VICENTE, L. E.; GREGO, C. R. Abordagens semiquantitativa e quantitativa na avaliação da textura do solo por espectroscopia de reflectância bidirecional no VIS-NIR-SWIR. **Pesquisa Agropecuária Brasileira**, v.48, p.1569-1582, 2013.

FORTES, R. et al. A methodology based on apparent electrical conductivity and guided soil samples to improve irrigation zoning. **Precision agriculture**, v. 16, n. 4, p. 441-454, 2015.

GRANGER, C.W.J.; RAMANATHAN, R. Improved methods of combining forecasts. **Journal of Forecasting**, v. 3, p. 197–204, 1984.

HORTA, A.; MALONE, B.; STOCKMANN, U.; MINASNY, B.; BISHOP, T. F. A.; MCBRATNEY, A. B.; PALLASSER, R.; POZZA, L. Potential of integrated field spectroscopy and spatial analysis for enhanced assessment of soil contamination: A prospective review. **Geoderma**, v. 241-242, p. 180–209, 2015.

HOUBORG, R.; Mc CABE, M. F. High-resolution NDVI from Planet’s constellation of earth observing nano-satellites: a new data source for precision agriculture. **Remote Sensing**, v. 8, n. 9, p. 768, 2016.

LACERDA, M. P. C et al. Tropical texture determination by proximal sensing using a regional spectral library and its relationship with soil classification. **Remote Sensing**, v. 8, n. 9, p. 701, 2016.

Mc BRATNEY, A. B.; SANTOS, M. L. M.; MINASNY, B. On digital soil mapping. **Geoderma**, v. 117, n. 1-2, p. 3-52, 2003.

MACHADO, P, D, A et al. Mapeamento da condutividade elétrica e relação com a argila de Latossolo sob plantio direto, **Pesquisa Agropecuária Brasileira**, v. 41, n. 6, p. 1023-1031, 2006.

MINASNY, B., MCBRATNEY, A.B., WHELAN, B.M. Vesper 1.62 Spatial prediction software for precision agriculture. Australian Centre for Precision Agriculture, University of Sydney, McMillan Building A05, NSW 2006, 2005.

MOUAZEN, A. M. et al. On-line measurement of some selected soil properties using a VIS–NIR sensor. **Soil and Tillage Research**, v. 93, n. 1, p. 13-27, 2007.

MOLIN, J. P.; RABELLO, L. M. Estudos sobre a mensuração da condutividade elétrica do solo, **Engenharia Agrícola**, v. 31, n. 1, p. 90-101, 2011.

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. **Agricultura de precisão**. São Paulo: Oficina de Textos, 2015.

MORAL, F. J.; TERRÓN, J. M.; MARQUES DA SILVA, J. R. Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques. **Soil and Tillage Research**, v. 106, n. 2, p. 335-343, 2010.

NANNI, M. R.; DEMATTE, J. A. M. Comportamento da linha do solo obtida por espectrorradiometria laboratorial para diferentes classes de solo. **Revista Brasileira de Ciência do solo**, v. 30, n. 6, 2006.

NANNI, M. R.; POVH, F. P.; DAMATTE, J. A. M.; OLIVEIRA, R. B.; CHICATI, M. L.; CEZAR, E. Optimum size in grid soil sampling for variable rate application in site-specific management. **Scientia Agrícola**, v. 68, p. 386-392, 2011.

ONOJEGHUO, A. O. et al. Applications of satellite ‘hyper-sensing’ in Chinese agriculture: Challenges and opportunities. **International Journal of Applied Earth Observation and Geoinformation**, v. 64, p. 62-86, 2018.

O’ROURKE, S. M.; STOCKMANN, U.; HOLDEN, N. M.; MCBRATNEY, A. B.; MINASNY, B. An assessment of model averaging to improve predictive power of portable vis-NIR and XRF for the determination of agronomic soil properties. **Geoderma**, v. 279, p. 31–44, 2016.

PORTZ, G.; MOLIN, J. P.; JASPER, J. Active crop sensor to detect variability of nitrogen supply and biomass on sugarcane fields. **Precision Agriculture**, v. 13, n. 1, p. 33-44, 2012.

SOUSA, D. D.; LOBATO, E. Cerrado: correção do solo e adubação. Planaltina: Embrapa Cerrados. 2004.

SOUSA JUNIOR, J. G.; DEMATTÊ, J. A. M.; ARAÚJO, S. R. Modelos espectrais terrestres e orbitais na determinação de teores de atributos dos solos: potencial e custos. **Bragantia**, v. 70, n. 3, 2011.

SEELAN, Santhosh K. et al. Remote sensing applications for precision agriculture: A learning community approach. **Remote Sensing of Environment**, v. 88, n. 1-2, p. 157-169, 2003.

SHABOU, Marouen et al. Soil clay content mapping using a time series of Landsat TM data in semi-arid lands. **Remote Sensing**, v. 7, n. 5, p. 6059-6078, 2015.

SPEKKEN, M.; ANSELMINI, A. A.; MOLIN, J. P. A simple method for filtering spatial data. In: European Conference of Precision Agriculture, 2013, Lleida, Espanha. Precision agriculture '13. Wageningen: Wageningen Academic Publishers, 2013. p. 259-266.

TAVARES, T. R.; SOUZA, A. B.; MARTELLO, M.; EITELWEIN, M. T.; DEMATTÊ, J. A. M. Espectroscopia de reflectância Vis-NIR: uma alternativa às análises químicas tradicionais de solo, In Proceedings of the Brazilian Conference on Precision Agriculture, Goiânia, Brazil, 2016.

ROSSEL, R. A. V.; BOUMA, J. Soil sensing: A new paradigm for agriculture. **Agricultural Systems**, v. 148, p. 71-74, 2016.

WARREN, G.; METTERNICHT, G. Agricultural applications of high-resolution digital multispectral imagery: Evaluating within-field spatial variability of canola (*Brassica napus*) in Western Australia. **Photogrammetric Engineering and Remote Sensing**, v. 71, p. 595-602, 2005.

WEBSTER, R.; OLIVER, M. A. **Geostatistics for environmental scientists**. John Wiley & Sons, 2007. <http://dx.doi.org/10.1002/9780470517277>.