

ISSN 1517-2627

Setembro, 2017

Empresa Brasileira de Pesquisa Agropecuária
Embrapa Solos
Ministério da Agricultura, Pecuária e Abastecimento

Documentos 192

Seminário PIBIC Embrapa Solos 2016/2017

Caio de Teves Inácio

Claudio Lucas Capeche

Alba Leonor da Silva Martins

Jacqueline Silva Rezende Mattos

Liliane de Carvalho

Rio de Janeiro, RJ

2017

Predição e mapeamento de atributos do solo utilizando sensores proximais⁽¹⁾

Hugo Machado Rodrigues⁽²⁾; Gustavo Mattos Vasques⁽³⁾

⁽¹⁾ Trabalho executado com recursos dos projetos Embrapa MP3 03.12.10.002.00.00 e CNPq Universal 479077/2013-4

⁽²⁾ Geógrafo, graduando em Engenharia Agrícola e Ambiental; Universidade Federal Fluminense; Niterói, RJ; E-mail: hugomr@id.uff.br;

⁽³⁾ Pesquisador da Embrapa Solos, Rio de Janeiro, RJ. Contato: <https://www.embrapa.br/fale-conosco/sac/>

RESUMO: O objetivo foi avaliar o uso *in situ* de sensores proximais para prever e mapear cinco atributos do solo em uma área de 3,4 ha em Seropédica, RJ. Foram definidos 105 pontos amostrais em malha uniforme de 20 m x 20 m, acrescidos de 25 pontos para validação externa. Nesses 130 pontos, foram medidos em laboratório os teores de argila, carbono orgânico, ferro e umidade e a capacidade de troca catiônica a partir de amostras de solo coletadas a 0-10 cm, e medidas por sensores proximais *in situ*, na superfície do solo, a susceptibilidade magnética (SM), condutividade elétrica aparente (CEa) e os teores de tório (eTh) e urânio (eU) equivalentes. Foram comparadas duas abordagens de mapeamento: 1) krigagem ordinária (KO) dos cinco atributos do solo a partir dos seus valores observados; e 2) regressão-krigagem (RK), compreendendo a predição dos atributos em função dos dados de sensores, seguida da krigagem dos valores preditos dos atributos. Os modelos de predição lineares dos atributos obtiveram R² ajustado de até 0,73 (argila), sendo que a SM e o eTh foram as variáveis preditoras mais importantes. Os mapas dos atributos obtidos por RK foram muito similares àqueles obtidos por KO, tanto nos padrões espaciais gerados quanto na incerteza quantificada a partir dos 25 pontos de validação externa. Isso significa que os dados de sensores obtidos rapidamente *in situ* permitem gerar mapas de atributos do solo, de mais difícil e demorada medição em laboratório, com ganho de eficiência e sem perda de qualidade nos mapas.

Termos para indexação: geoestatística, pedometria, sensoriamento proximal do solo.

INTRODUÇÃO

Por facilitarem a aquisição de grande quantidade de dados, com relativo baixo custo e tempo, os sensores proximais do solo são instrumentos eficientes e com grande potencial para auxiliar na caracterização detalhada e mapeamento dos solos e seus atributos. Por exemplo, Mahmood et al. (2013), utilizando um sensor gamarradiométrico portátil em uma fazenda experimental de 4 ha na

Holanda, encontraram modelos preditivos com coeficientes de determinação (R²) de até 0,60 para o teor de argila, 0,59 para pH e 0,65 para o teor de carbono orgânico (CO) do solo na profundidade de 0-15 cm. Sudduth et al. (2013) encontraram R² de 0,92 na predição da profundidade até a camada adensada (*claypan*), ou início do horizonte B textural (*argillic horizon*), do solo utilizando sensores de condutividade elétrica aparente (CEa) em uma área de 12 ha no Missouri, EUA.

Por outro lado, no Brasil, ainda são incipientes os estudos usando sensores proximais diretamente no campo (*in situ*), citando-se o trabalho de Rodrigues e Vasques (2017), que compararam krigagem ordinária e krigagem universal para mapear atributos do solo na mesma área de estudo do presente trabalho, e o trabalho de Oldoni e Bassoi (2015) de delineamento de zonas de manejo a partir de um sensor de CEa, em uma área de 1,6 ha cultivada com videira em Petrolina, PE.

O objetivo foi avaliar o uso *in situ* de dois sensores proximais para prever e mapear cinco atributos físicos e químicos do solo medidos em laboratório. Os objetivos específicos foram: 1) Prever os teores de argila, carbono orgânico, ferro e umidade e a capacidade de troca catiônica do solo, medidos em laboratório, em função da susceptibilidade magnética, condutividade elétrica aparente e teores de tório e urânio equivalentes, medidos *in situ* por sensores; 2) Mapear esses atributos, comparando a krigagem a partir dos seus valores observados com a krigagem a partir dos valores preditos por sensores; e 3) Comparar a qualidade dos mapas gerados, por meio de validação externa.

MATERIAL E MÉTODOS

A área de estudo possui aproximadamente 3,4 ha e está localizada em uma fazenda experimental no Município de Seropédica, RJ (Figura 1). Foi estabelecida uma malha amostral de 20 m x 20 m, constituída de 7 transetos longitudinais à topossequência com 15 pontos em cada um, perfazendo 105 pontos. Além desses, 25 pontos foram alocados, para fins de validação externa dos

mapas produzidos, utilizando o método do hipercubo latino condicionado (MINASNY; MCBRATNEY, 2006), totalizando 130 pontos.

Nos 130 pontos amostrais, foram medidas, na superfície do solo, a susceptibilidade magnética (SM) e a CEa do solo usando o sensor KT-10 S/C (Terraplus Inc., Richmond Hill, Canadá) e os teores de tório (eTh) e urânio (eU) equivalentes, usando o espectrômetro de raios gama RS-230 BGO (Radiation Solutions Inc., Mississauga, Canadá). Além disso, amostras de solo a 0-10 cm foram coletadas e analisadas em laboratório para medição dos teores de argila, ferro (Fe), CO e umidade e da capacidade de troca catiônica (CTC), segundo Donagema et al. (2011). Os valores de Fe são apresentados em unidades de Fe_2O_3 .

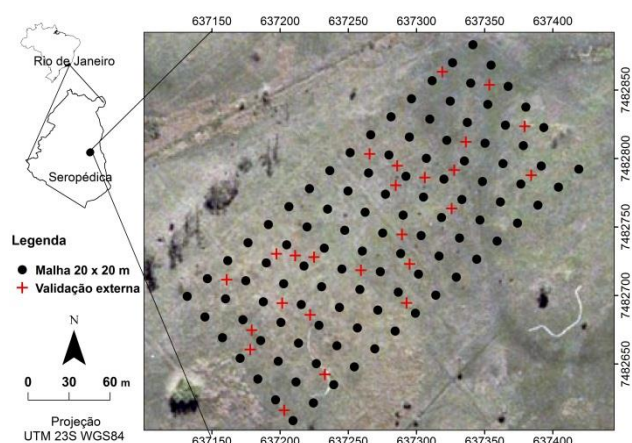


Figura 1. Mapa de localização da área de estudo e delineamento amostral.

Foram transformadas para logaritmo as variáveis SM e CEa, medidas por sensores, e o Fe medido em laboratório. Ajustaram-se modelos lineares para os cinco atributos medidos em laboratório em função das propriedades do solo medidas *in situ* pelos sensores proximais. Para isso, todas as combinações possíveis das variáveis CEa, SM, eTh e eU foram testadas, utilizando a função *regsubsets* presente no pacote *leaps* (LUMLEY, 2017) do programa R (R CORE TEAM, 2015). Como critério para escolha do melhor modelo preditivo, utilizou-se o R^2 ajustado.

Para mapeamento dos atributos medidos em laboratório, foram comparadas duas abordagens: 1) krigagem ordinária (KO) a partir dos seus valores observados; e 2) regressão-krigagem (RK), compreendendo a predição dos atributos em função dos dados de sensores, conforme descrito acima, seguida da krigagem dos seus valores preditos. Os semivariogramas foram ajustados manualmente usando o modelo esférico e os mapas foram gerados com tamanho de pixel de 1 m.

A avaliação da qualidade dos mapas foi feita por validação externa calculando-se o erro médio (EM) e a raiz do erro quadrado médio (REQM) a partir das 25 amostras de validação. As análises geoestatísticas foram feitas no programa R usando o pacote gstat (PEBESMA, 2004).

RESULTADOS E DISCUSSÃO

As estatísticas descritivas das variáveis do solo e os R^2 ajustados dos modelos de predição são apresentados nas Tabelas 1 e 2, respectivamente, enquanto os modelos de predição selecionados para cada atributo encontram-se na Tabela 3. O modelo de predição que obteve R^2 ajustado mais elevado foi o do teor de argila (0,73), seguido do da umidade e do Fe, todos eles utilizando as variáveis predictoras $\log(\text{SM})$, eTh e eU, enquanto os modelos do CO e CTC com maior R^2 ajustado (0,36 e 0,33, respectivamente) usaram $\log(\text{SM})$ e eTh. Isso mostra que a combinação de dados obtidos por diferentes sensores (eTh e SM) melhora a qualidade dos modelos de predição. Por outro lado, a inclusão do eU nos modelos de predição da argila, umidade e Fe melhorou muito pouco o R^2 ajustado em relação aos modelos somente com $\log(\text{SM})$ e eTh. Nesse sentido, somente se optou por usar os modelos com eU porque ele é medido junto com o eTh no campo, sem exigir esforço extra de medição.

Tabela 1. Estatística descritiva dos atributos do solo medidos em laboratório e propriedades medidas *in situ* por sensores proximais.*

Variável	Mín	Máx	Média	Mediana	DP
Argila (g kg^{-1})	20	380	176	160	93
Fe (g kg^{-1})	10	84	29	27	14
CO (g kg^{-1})	3,7	28	11,3	11,4	3,8
CTC ($\text{cmol}_c \text{ kg}^{-1}$)	2,6	12,9	6,9	6,9	2,0
Umid ($\% \text{ v v}^{-1}$)	4,2	31,7	15,4	15,6	5,6
SM (10^{-3} SI)	0,0	3,8	0,4	0,2	0,5
CEa (S m^{-1})	0,0	4,9	1,2	0,8	1,1
eTh (ppm)	0,0	13,9	6,3	5,8	2,8
eU (ppm)	0,5	3,4	1,3	1,2	0,4

* Mín, mínimo; Máx, máximo; DP, desvio padrão.

O eTh foi a variável preditora com maior correlação com os atributos do solo, seguido da SM (vide primeiras quatro linhas da Tabela 2). Por outro lado, nenhum modelo utilizando a CEa como variável preditora foi selecionado como melhor, ainda que a sua correlação com os atributos do solo seja maior do que a do eU.

Tabela 2. Coeficientes de determinação (R^2) ajustados dos modelos de predição, com os melhores modelos, para cada atributo, indicados em negrito e itálico.

Variáveis predictoras	Argila	CO	log(Fe)	CTC	Umid
log(SM)	0,25	0,13	0,24	0,14	0,28
log(CEa)	0,15	0,05	0,16	0,09	0,17
eTh	0,67	0,34	0,44	0,30	0,50
eU	0,01	0,00	0,02	0,00	0,01
log(SM), log(CEa)	0,26	0,12	0,25	0,14	0,28
log(SM), eTh	0,71	0,36	0,50	0,33	0,57
log(SM), eU	0,25	0,14	0,24	0,14	0,27
log(CEa), eTh	0,68	0,34	0,47	0,31	0,53
log(CEa), eU	0,15	0,05	0,16	0,08	0,17
eTh, eU	0,71	0,34	0,48	0,29	0,53
log(SM), log(CEa), eTh	0,71	0,36	0,50	0,32	0,57
log(SM), log(CEa), eU	0,25	0,13	0,25	0,14	0,28
log(SM), eTh, eU	0,73	0,36	0,52	0,32	0,58
log(CEa), eTh, eU	0,71	0,33	0,50	0,30	0,55
log(SM), log(CEa), eTh, eU	0,73	0,35	0,52	0,31	0,58

Tabela 3. Modelos de predição selecionados para cada atributo do solo.

Atributo	Modelo
Argila	$80,68 + 16,21 \times \log(\text{SM}) + 25,83 \times \text{eTh} - 36,68 \times \text{eU}$
log(Fe)	$2,97 + 0,11 \times \log(\text{SM}) + 0,10 \times \text{eTh} - 0,17 \times \text{eU}$
CO	$7,36 + 0,62 \times \log(\text{SM}) + 0,72 \times \text{eTh}$
CTC	$5,10 + 0,43 \times \log(\text{SM}) + 0,36 \times \text{eTh}$
Umid	$11,40 + 1,42 \times \log(\text{SM}) + 1,18 \times \text{eTh} - 1,58 \times \text{eU}$

Os semivariogramas ajustados aos valores originais para fins de KO tiveram maior alcance do que aqueles ajustados aos valores preditos para fins de RK, exceto os da umidade (**Tabela 4**), sendo os maiores alcances observados para o teor de argila (261 m e 371 m, respectivamente). Os outros parâmetros do semivariograma não tiveram diferenças consistentes (aumento ou diminuição) entre os semivariogramas dos valores originais e preditos dos diferentes atributos.

Os padrões de distribuição espacial obtidos por RK a partir dos valores preditos dos atributos são bastante similares àqueles obtidos por KO a partir dos valores originais (**Figura 2**). Os maiores valores de todos os atributos encontram-se na parte sudoeste do mapa, na parte mais elevada da área de estudo, e, secundariamente, no extremo norte da área de estudo. Os menores valores estão presentes na parte central do mapa, onde está

localizada uma encosta com solos mais arenosos.

Tabela 4. Parâmetros de ajuste dos semivariogramas dos atributos do solo a partir dos valores originais e preditos, respectivamente.

Atributo	Efeito pepita	Patamar	Efeito pepita/patamar	Alcance (m)
Valores originais				
Argila	430	13430	0,03	261
log(Fe)	0,03	0,28	0,11	181
CO	7,0	19,5	0,36	240
CTC	2,08	4,48	0,46	190
Umid	8,5	33,3	0,25	208
Valores preditos				
Argila	1400	11400	0,12	371
log(Fe)	0,02	0,16	0,13	240
CO	1,4	6,9	0,20	260
CTC	0,3	1,9	0,18	240
Umid	3,5	22,5	0,16	240

Os índices de incerteza dos mapas, calculados a partir das 25 amostras de validação externa, foram similares entre os mapas obtidos por RK, a partir dos valores preditos dos atributos em função dos dados de sensores, e aqueles obtidos por KO, a partir dos valores originais (**Tabela 5**). Ou seja, os dados de sensores, de mais rápida e fácil medição no campo, permitem, via RK, mapear os cinco atributos do solo, de mais difícil e demorada medição em laboratório, obtendo praticamente a mesma acurácia nos mapas gerados.

Tabela 5. Índices de incerteza, obtidos por validação externa, dos mapas de atributos do solo produzidos por krigagem ordinária e regressão-krigagem, respectivamente.*

Atributo	EM		REQM	
	KO	RK	KO	RK
Argila (g kg^{-1})	21	21	60	62
Fe (g kg^{-1})	7,5	8,6	14,4	16,0
CO (g kg^{-1})	1,2	1,5	2,9	3,1
CTC ($\text{cmol}_c \text{ kg}^{-1}$)	0,9	0,9	1,5	1,5
Umid ($\% \text{ v v}^{-1}$)	4,1	3,9	5,8	5,9

*EM, erro médio; REQM, raiz do erro quadrado médio.

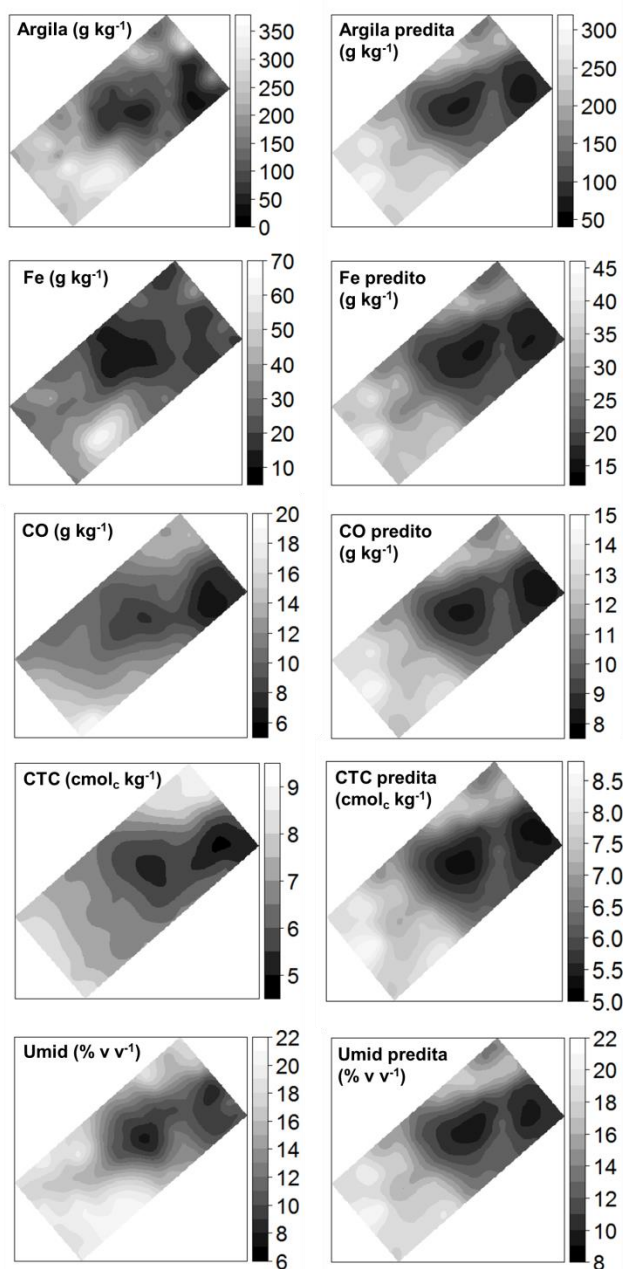


Figura 2. Mapas dos atributos do solo obtidos por krigagem ordinária a partir dos valores originais (coluna da esquerda) e por regressão-krigagem a partir dos valores preditos em função dos dados de sensores proximais (coluna da direita).

CONCLUSÕES

Os sensores proximais do solo permitem prever e mapear, via regressão-krigagem, os teores de argila, carbono orgânico, ferro e umidade e a capacidade de troca catiônica do solo, com maior eficiência e sem perda de qualidade em relação à krigagem ordinária diretamente dos valores dos atributos medidos em laboratório.

Os mapas de atributos do solo produzidos a partir dos seus valores preditos em função dos dados de sensores proximais medidos *in situ* honram os

principais padrões de variação espacial dos atributos, conforme os mapas obtidos via krigagem dos seus valores observados.

Os resultados mostram o potencial dos sensores proximais do solo para o mapeamento indireto de atributos do solo que requerem a coleta de amostras no campo e sua análise em laboratório, as quais constituem etapas laboriosas e demoradas do mapeamento de atributos do solo.

AGRADECIMENTOS

À Embrapa e ao CNPq pelo suporte financeiro e às equipes dos respectivos projetos pelo apoio e incentivo. O primeiro autor agradece à Embrapa Solos e ao CNPq pelo apoio financeiro via bolsa de iniciação científica (PIBIC) número 144933/2016-0.

REFERÊNCIAS

- DONAGEMA, G. K.; CAMPOS, D. V. B. de; CALDERANO, S. B.; TEIXEIRA, W. G.; VIANA, J. H. M. (Org.). **Manual de métodos de análise de solo**. 2. ed. rev. Rio de Janeiro: Embrapa Solos, 2011. 230 p. (Embrapa Solos. Documentos, 132).
- LUMLEY, T. **Leaps: Regression Subset Selection**. R package version 3.0. 2017. (Based on Fortran code by Alan Miller)
- MAHMOOD, H. S.; HOOGLMOED, W. B.; VAN HENTEN, E. J. Proximal gamma-ray spectroscopy to predict soil properties using windows and full-spectrum analysis methods. **Sensors**, v. 13, n. 12, p. 16263-16280, 2013.
- MINASNY, B.; MCBRATNEY, A. B. A conditioned Latin hypercube method for sampling in the presence of ancillary information. **Computers & Geosciences**, v. 32, n. 9, p. 1378-1388, Nov. 2006.
- OLDONI, H.; BASSOI, L. H. Delineamento de zonas de manejo com base na condutividade elétrica aparente de solo arenoso. In: SIMPÓSIO DE GEOESTATÍSTICA APLICADA EM CIÊNCIAS AGRÁRIAS, 4., 2015, Botucatu. **Anais...** Botucatu: Universidade Estadual Paulista, 2015.
- PEBESMA, E. J. Multivariable geostatistics in S: the gstat package. **Computers & Geosciences**, v. 30, n. 7, p. 683-691, Aug. 2004.
- R CORE TEAM. **R: A language and environment for statistical computing**. Viena: R Foundation for Statistical Computing, 2015.
- RODRIGUES, H. M.; VASQUES, G. M. Integração de sensores geofísicos e geoestatística para mapear atributos do solo. In: SIMPÓSIO BRASILEIRO DE GEOGRAFIA FÍSICA APLICADA, 17., 2017, Campinas. **Anais...** Campinas: Universidade Estadual de Campinas, 2017.
- SUDDUTH, K. A.; MYERS, D. B.; KITCHEN, N. R.; DRUMMOND, S. T. Modeling soil electrical conductivity-depth relationships with data from proximal and penetrating EC_a sensors. **Geoderma**, v. 199, p. 12-21, May 2013.