



XVIII
SBGFA

SIMPÓSIO BRASILEIRO DE
GEOGRAFIA FÍSICA APLICADA

GEOGRAFIA FÍSICA E AS MUDANÇAS GLOBAIS

UNIVERSIDADE FEDERAL DO CEARÁ • FORTALEZA - CE • 11 A 15 DE JUNHO DE 2019

Predição de argila no solo: modelos utilizando sensores proximais do solo VS atributos derivados de MDE

Hugo Machado Rodrigues^(a), Gustavo Mattos Vasques^(b), Yuri Gelsleichter^(a), Marcos Bacis Ceddia^(a)

^(a) Agronomia (Ciência do Solo)/UFRRJ, rodrigues.machado.hugo@gmail.com; marcosceddia@gmail.com

^(b) Embrapa Solos, gustavo.vasques@embrapa.br

^(c) PPGCTIA (Interdisciplinar)/UFRRJ, yuriplanta@gmail.com

Eixo: Geotecnologias e modelagem aplicada aos estudos ambientais

Resumo

O gerenciamento adequado de áreas agrícolas ou a modelagem de erosão de bacias são alguns dos desafios ambientais que requerem quantidades de dados, precisos e gerados tempo hábil para a pesquisa. Dos atributos do solo de interesse ambiental, o atributo argila é um dos primordiais, conquanto a mensuração desse é obtida convencionalmente por granulometria em laboratório, apresentando descompasso para o fornecimento dessa informação. Sendo assim, avaliaram-se os mapas preditos de argila realizado por sensores proximais portáteis (condutímetro/susceptímetro e gamarradiômetro) e outro utilizando 21 derivadas do MDE (gerado por GPS geodésico), com resolução de 1 metro, em 3,4 ha de área de estudo em Seropédica - RJ. Os modelos de predição da argila apresentaram valores de R^2 0.91 e 0.74, para derivadas de MDE e sensores proximais, respectivamente. Embora, o mapa que apresentou menores erros, mas não tão discrepantes, foi o baseado no modelo utilizando sensores proximais.

Palavras chave: Proximal Soil Sensing, DEM, Brasil, Comparação de métodos, Predição de argila

1. Introdução

O reconhecimento dos padrões de distribuição de atributos do solo não é um impasse recente para a agricultura global. Há muito tempo o homem busca obter o maior



XVIII
SBGFA

SIMPÓSIO BRASILEIRO DE
GEOGRAFIA FÍSICA APLICADA

GEOGRAFIA FÍSICA E AS MUDANÇAS GLOBAIS

UNIVERSIDADE FEDERAL DO CEARÁ • FORTALEZA - CE • 11 A 15 DE JUNHO DE 2019

número de informações dos atributos do solo com a finalidade de manejar o uso de água ou insumos para sua plantação. Por exemplo, a partir do reconhecimento de regiões em uma plantação que, mesmo apresentando uma morfologia homogênea, o solo pode apresentar distribuição distinta de suas características morfológicas. A busca pela maior quantidade de dados de campo e pelo menor desprendimento de trabalho, encontra na tecnologia sua maior aliada para fins de mapeamentos dos atributos de interesse agrícola e ambiental. O advento de sensores com maior precisão, como os atuais GPS com erros de poucos metros, bem como da possibilidade de utilização de sensores portáteis manuais com leitura direta em campo, permitindo recobrir áreas de interesse com um número elevado de pontos e dispensando as análises laboratoriais, são alguns dos exemplos de utilização de tecnologias que está avançando do campo da pesquisa somente, para a realidade de alguns agricultores e modelagens ambientais.

Sendo assim, esse trabalho tem como objetivo comparar os mapas de argila predita a partir de dados de campo em duas abordagens metodológicas. Para isso, ajustaram-se dois modelos de predição para argila: o primeiro utilizou as variáveis de dois sensores proximais (condutivímetro/susceptibilímetro e gamarradiômetro); o segundo utilizou 17 covariáveis derivadas do MDE com resolução de 1 metro. Após a krigagem ordinária dos valores de argila predita pelos dois modelos, avaliou-se a acurácia dos mapas utilizando amostras externas (ambos os modelos não “visualizaram” esses novos dados de argila para validação), e o erro médio e a raiz do erro quadrado médio.

2. Materiais 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 x 20 m, constituída de 7 transetos longitudinais à topossequência com 15 pontos em cada um, perfazendo 105 pontos. Além desses pontos, 25 pontos foram alocados, para fins de validação externa dos mapas produzidos a partir dos modelos



XVIII
SBGFA

SIMPÓSIO BRASILEIRO DE
GEOGRAFIA FÍSICA APLICADA

GEOGRAFIA FÍSICA E AS MUDANÇAS GLOBAIS

UNIVERSIDADE FEDERAL DO CEARÁ • FORTALEZA - CE • 11 A 15 DE JUNHO DE 2019

gerados, 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 condutividade elétrica aparente (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, segundo Teixeira et al. (2017).

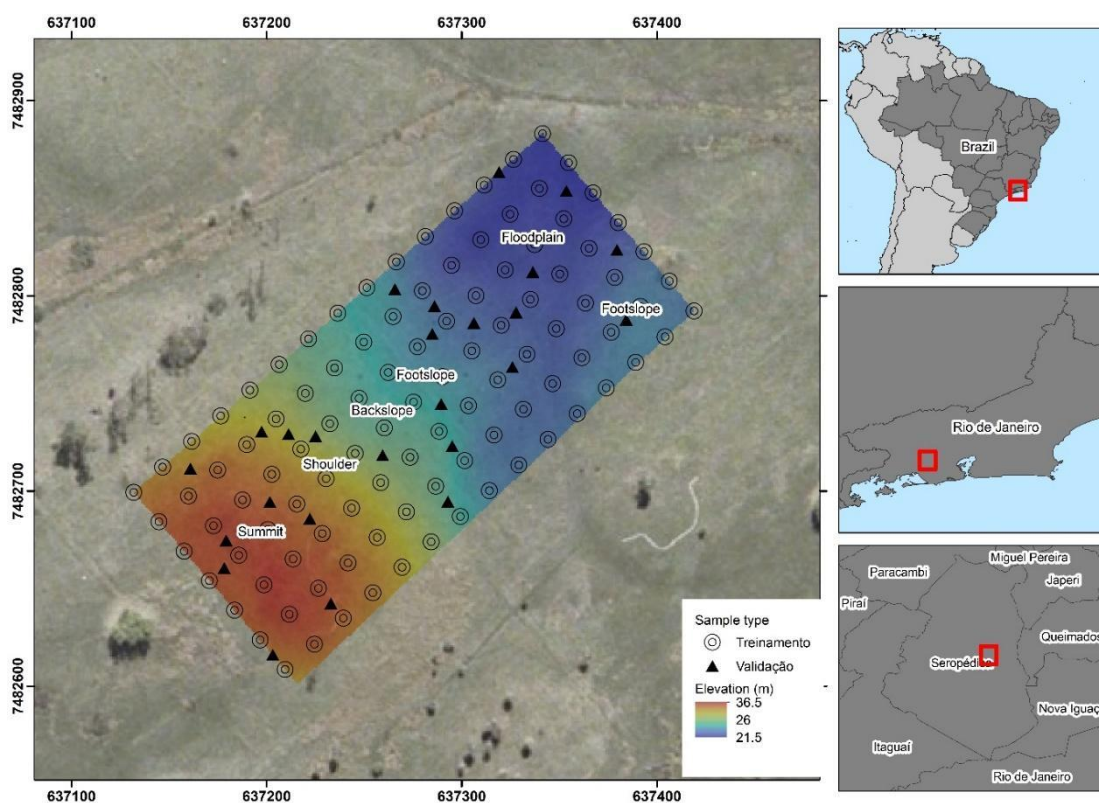


Figura 1. Mapa de localização da área de estudo e delineamento amostral.

O modelo digital de elevação (MDE) foi gerado por interpolação dos dados primários obtidos DGPS Trimble R4 (Trimble Navigation Limited, Westminster USA)



XVIII
SBGFA

SIMPÓSIO BRASILEIRO DE
GEOGRAFIA FÍSICA APLICADA

GEOGRAFIA FÍSICA E AS MUDANÇAS GLOBAIS

UNIVERSIDADE FEDERAL DO CEARÁ • FORTALEZA - CE • 11 A 15 DE JUNHO DE 2019

utilizando coleta estática, com 2 minutos em cada ponto, apresentando um MDE com resolução de 1 metro. O modelo digital de elevação (MDE) foi gerado por interpolação de dados primários de elevação e se restringiram aos limites da área de estudo. O modelo de elevação foi gerado pela ferramenta "*Topo To Raster*", com base no algoritmo ANUDEM desenvolvido por Hutchinson (1993) implementado no software ArcGis (ESRI, 2017). No software R (R CORE TEAM, 2015), as covariáveis foram geradas a partir do MDE utilizando a função *rsaga.geoprocessor* do mesmo pacote *RSAGA* (Brenning, et al. 2018) para compor o conjunto de variáveis predictoras usadas como entrada para os modelos preditivos.

Os atributos utilizados e derivados do MDE foram: Elevação (*DEM*), Northernness, Plano de Curvatura (*plan curv*), Perfil de Curvatura (*prof curv*), Índice de Convergência (*convergence*), Índice Topográfico de Umidade (*twi*), Posição de inclinação relativa (*rsp*), Distância da rede de canais (*chnd*), Nível de base da rede de canais (*chnb*) e *Fator LS*, todos esses derivados utilizando a função *rsaga.geoprocessor*, e os atributos Declividade (*slope*) e Aspecto (*aspect*) foram obtidos utilizando a função *rsaga.slope.asp.curv*, uma vez que desejava-se esses em porcentagem, ambas funções presentes no pacote *RSAGA* (Brenning, et al. 2018). Para completar as informações utilizadas como entrada para os modelos preditivos, foram utilizadas as bandas: *band1*, *band2*, *band3*, *band4*, *band5*, do sensor *Rapideye* e gerados dois índices espectrais a partir dos dados do sensor: o Índice de Vegetação por Diferença Normalizada (*NDVI*) e o Índice de Vegetação Ajustado ao Solo (*SAVI*), ambos utilizando a função *raster::overlay* presente no pacote *raster* (Robert, 2017). No total foram selecionadas 17 variáveis independentes utilizadas para o modelo de predição utilizando as variáveis derivadas do MDE.

Dos atributos utilizados pelos dois sensores proximais foram transformados para logaritmo neperiano as variáveis *SM* e *CEa*, e após, ajustou-se um modelo linear para predição da argila utilizando três (*SM*, *eTh* e *eU*) dos quatro atributos de sensores



XVIII
SBGFA

SIMPÓSIO BRASILEIRO DE
GEOGRAFIA FÍSICA APLICADA

GEOGRAFIA FÍSICA E AS MUDANÇAS GLOBAIS

UNIVERSIDADE FEDERAL DO CEARÁ • FORTALEZA - CE • 11 A 15 DE JUNHO DE 2019

proximais, uma vez que esses apresentaram a melhor combinação utilizando o R^2 ajustado como critério.

Os semivariogramas foram ajustados manualmente usando o modelo esférico (Figura 2). Após a seleção dos modelos de predição, os valores de argila predita foram mapeados por krigagem ordinária utilizando a função *krige* presente no pacote *gstat* (GRÄLER et al., 2016; PEBESMA, 2004), 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 usando o pacote *gstat* (GRÄLER et al., 2016; PEBESMA, 2004).

3. Resultados e discussões

As estatísticas descritivas das variáveis de argila medida em laboratório e das argilas preditas utilizando os modelos de sensores proximais e o de atributos derivados do MDE são apresentados na tabela 1. Os parâmetros de ajustes dos modelos bem como os valores de R^2 e R^2 ajustado dos modelos de predição são apresentados na tabela 2. O modelo de predição que obteve R^2 e R^2 ajustado mais elevado foi o modelo utilizando as variáveis derivadas do MDE (0,91 para ambos), seguido do modelo de predição utilizando as variáveis de sensores proximais (0,74 e 0,73, respectivamente).

Tabela 1. Estatística descritiva da argila medida em laboratório da argila predita pelos sensores proximais e pelos atributos derivados do MDE.

| | nobs | Mínimo | Máximo | Média | Mediana | DP |
|-----------------|------|--------|--------|-------|---------|------|
| Argila original | 105 | 20.0 | 380.0 | 172.2 | 160.0 | 89.4 |
| Argila Sensores | 102 | 31.2 | 371.3 | 172.0 | 168.7 | 76.9 |
| Argila MDE | 1217 | 39.9 | 290.0 | 159.3 | 144.2 | 74.2 |

nobs, número de observações; DP, desvio padrão.

Os parâmetros dos semivariogramas são mostrados na tabela 3. O alcance do semivariograma ajustado para a variável de argila de laboratório apresentou os maiores valores (261 m, Figura 2, A.1), enquanto os valores para argila predita por sensores proximais e por MDE se ajustaram a distâncias próximas (200 e 160 metros,



XVIII
SBGFA

SIMPÓSIO BRASILEIRO DE
GEOGRAFIA FÍSICA APLICADA

GEOGRAFIA FÍSICA E AS MUDANÇAS GLOBAIS

UNIVERSIDADE FEDERAL DO CEARÁ • FORTALEZA - CE • 11 A 15 DE JUNHO DE 2019

respectivamente, Tabela 3 e Figura 2, B.1 e C.1). O efeito pepita do semivariograma de sensores proximais apresentou valores maiores que os de MDE, provavelmente pela maior quantidade de pontos amostrais e variáveis utilizadas. Enquanto o patamar entre os dois semivariogramas se manteve similar.

Tabela 2. Parâmetros de ajustes dos modelos de predição

| <i>Predictores</i> | <i>Argila predita por MDE</i> | | <i>Argila predita por Sensores Proximais</i> | |
|--|-------------------------------|-------------------------------------|--|-------------------------------------|
| | <i>Estimado</i> | <i>Intervalo de confiança (95%)</i> | <i>Estimado</i> | <i>Intervalo de confiança (95%)</i> |
| (Intercept) | 460.01 *** | 380.09 – 539.92 | 80.68 *** | 39.89 – 121.47 |
| DEM | 18.23 *** | 17.37 – 19.10 | | |
| slope | -0.00 *** | -0.00 – -0.00 | | |
| aspect | 0.01 | -0.00 – 0.03 | | |
| northernness | -0.31 *** | -0.37 – -0.25 | | |
| plan curv | -0.00 *** | -0.00 – -0.00 | | |
| prof curv | 0.00 *** | 0.00 – 0.00 | | |
| convergence | -0.56 *** | -0.76 – -0.35 | | |
| twi | -10.07 *** | -11.34 – -8.81 | | |
| ls factor | 47.14 *** | 40.78 – 53.49 | | |
| chnd | -0.00 *** | -0.00 – -0.00 | | |
| band 1 | -0.05 *** | -0.06 – -0.04 | | |
| band 2 | -0.07 *** | -0.08 – -0.06 | | |
| band 3 | 0.01 | -0.07 – 0.09 | | |
| band 4 | 0.07 *** | 0.05 – 0.09 | | |
| band 5 | -0.04 | -0.10 – 0.03 | | |
| NDVI | -17273483.83 ** | -29087821.57 – -5459146.08 | | |
| SAVI | 11516050.76 ** | 3639077.73 – 19393023.79 | | |
| log SM | | | 16.22 ** | 5.22 – 27.22 |
| eTh | | | 25.83 *** | 22.04 – 29.61 |
| eU | | | -36.68 ** | -60.33 – -13.04 |
| Observações | 1217 | | 102 | |
| R ² / R ² ajustado | 0.91 / 0.91 | | 0.74 / 0.73 | |

* $p < 0.05$ ** $p < 0.01$ *** $p < 0.001$

Tabela 3. Parâmetros de ajuste dos semivariogramas dos atributos do solo a partir dos valores originais e preditos.

| <i>Argila</i> | <i>Efeito pepita</i> | <i>Patamar</i> | <i>Efeito pepita/ patamar</i> | <i>Alcance (m)</i> |
|--------------------------|----------------------|----------------|-------------------------------|--------------------|
| Valores originais | | | | |
| Original | 430 | 13430 | 0.03 | 261 |
| Valores preditos | | | | |
| Sensores | 1400 | 7900 | 0.18 | 200 |
| MDE | 500 | 7500 | 0.07 | 160 |




XVIII
SBGFA

SIMPÓSIO BRASILEIRO DE
GEOGRAFIA FÍSICA APLICADA

GEOGRAFIA FÍSICA E AS MUDANÇAS GLOBAIS

UNIVERSIDADE FEDERAL DO CEARÁ • FORTALEZA - CE • 11 A 15 DE JUNHO DE 2019

Os padrões de distribuição espacial obtidos pela krigagem ordinária da argila predita pelos modelos utilizando sensores proximais e derivadas do MDE apresentaram padrões espaciais similares entre si (Figura 2, B e C, respectivamente) e corresponderam aos padrões reais de distribuição da argila visualizável no mapa krigado dos valores originais (Figura 2 A). No geral, os padrões exibidos por todos os mapas preditos apresentam os maiores valores para o atributo argila na parte sudoeste do mapa (*summit*), sendo essa a parte mais elevada da área de estudo como pode ser visto no modelo digital de elevação apresentado na figura 1. Secundariamente, no extremo norte e na área central dos mapas são localizadas as manchas com os menores valores para o atributo argila.





XVIII
SBGFA

SIMPÓSIO BRASILEIRO DE
GEOGRAFIA FÍSICA APLICADA

GEOGRAFIA FÍSICA E AS MUDANÇAS GLOBAIS

UNIVERSIDADE FEDERAL DO CEARÁ • FORTALEZA - CE • 11 A 15 DE JUNHO DE 2019




Figura 2. A: Mapa krigado de argila dos valores originais, A.1: Semivariograma preliminar e ajustado da argila original; B: Mapa krigado de argila predita utilizando o modelo de sensores proximais, B.1: Semivariograma preliminar e ajustado da argila predita por sensores proximais; C: Mapa krigado de argila predita utilizando os o modelo de derivadas do MDE, C.1: Semivariograma preliminar e ajustado da argila predita por derivadas do MDE.

Os índices de incerteza dos mapas, calculados a partir das 25 amostras de validação externa, apresentaram resultados melhores para o modelo ajustado utilizando as variáveis de sensores proximais (Tabela 5). É possível notar que, tanto o EM quanto o REQM para os valores de argila predita por sensores proximais apresentaram resultados praticamente iguais de validação externa dos mapas originais de argila medidos em laboratório. Mesmo que os erros utilizando os modelos de predição via sensores proximais tenha apresentado um resultado melhor se baseando na validação externa, a estimativa dos erros dos mapas de argila predita via atributos de MDE são próximos e suficientemente aceitáveis. O resultado dos erros dos mapas de atributos de MDE não distaram tanto dos erros dos mapas de argila originais uma vez que a resolução espacial do MDE é de 1 metro, e vale lembrar que o mesmo é um sensor de campo e portátil.



XVIII
SBGFA

SIMPÓSIO BRASILEIRO DE
GEOGRAFIA FÍSICA APLICADA

GEOGRAFIA FÍSICA E AS MUDANÇAS GLOBAIS

UNIVERSIDADE FEDERAL DO CEARÁ • FORTALEZA - CE • 11 A 15 DE JUNHO DE 2019

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

| Argila | REQM | EM |
|---------------------------|-------------|-----------|
| Original | 59.8 | 20.8 |
| Sensores Proximais | 61.8 | 20.7 |
| MDE | 72.6 | 32 |

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

Os sensores proximais do solo permitiram prever e mapear, via modelo linear e posterior krigagem dos valores, os teores de argila com eficiência e sem perda de qualidade em relação à krigagem ordinária diretamente dos valores dos atributos medidos em laboratório. Ambos os mapas apresentados pelos dois modelos de predição, tanto os utilizando as variáveis de sensores bem como os utilizando as variáveis derivadas do MDE honram os principais padrões de variação espacial dos atributos, conforme os mapas obtidos via krigagem dos seus valores preditos. Mesmo com esses padrões similares nos mapas, os mapas de sensores proximais apresentaram erros menores quando submetidos à validação externa, demonstrando serem mais eficientes do que os mapas gerados pelo modelo utilizando as derivadas do MDE, mesmo que esse tenha apresentado um R^2 superior. É interessante notar que os atributos do relevo apresentados pelas derivadas do MDE mostraram os padrões espaciais similares aos mapas de sensores proximais, podendo sugerir que o relevo é principal controlador da distribuição espacial dos atributos mensurados pelos sensores proximais.

Sendo assim, os resultados mostram o potencial do uso de sensores proximais, quanto de posicionamento global (GPS), com resolução adequada, para atuarem em um nível de gerenciamento e fornecimento de dados para o manejo agrícola. Apresentando-se como alternativas de geração de dados frente aos métodos convencionais de análise laboratorial.



XVIII
SBGFA

SIMPÓSIO BRASILEIRO DE
GEOGRAFIA FÍSICA APLICADA

GEOGRAFIA FÍSICA E AS MUDANÇAS GLOBAIS

UNIVERSIDADE FEDERAL DO CEARÁ • FORTALEZA - CE • 11 A 15 DE JUNHO DE 2019

4. Agradecimentos

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

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001

5. Referências Bibliográficas

GRÄLER, Benedikt et al. 2016. **Spatio-Temporal Interpolation using gstat**. The R Journal 8(1), 204-218.

BRENNING A; BANGS D; BECKER M. (2018). **RSAGA: SAGA Geoprocessing and Terrain Analysis**. R package version 1.2.0. <https://CRAN.R-project.org/package=RSAGA>

ESRI 2017. **ArcGIS Desktop**: Release 10.5. Redlands, CA: Environmental Systems Research Institute.

HUTCHINSON, M. F. 1993. **Development of a continent-wide DEM with applications to terrain and climate analysis**. In Environmental Modeling with GIS, ed. M. F. Goodchild et al., 392–399. New York: Oxford University Press.

LUMLEY, T. **leaps**: Regression Subset Selection. R package version 3.0. 2017. (Based on Fortran code by Alan Miller)



XVIII
SBGFA

SIMPÓSIO BRASILEIRO DE
GEOGRAFIA FÍSICA APLICADA

GEOGRAFIA FÍSICA E AS MUDANÇAS GLOBAIS

UNIVERSIDADE FEDERAL DO CEARÁ • FORTALEZA - CE • 11 A 15 DE JUNHO DE 2019

MINASNY, Budiman; MCBRATNEY, Alex B. A conditioned Latin hypercube method for sampling in the presence of ancillary information. **Computers and Geosciences**, v. 32, n. 9, p. 1378–1388, 2006.

PEBESMA, E.J., 2004. **Multivariable geostatistics in S: the gstat package**. *Computers & Geosciences*, 30: 683-691.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Viena, Áustria: R Foundation for Statistical Computing, 2015.

ROBERT J. H. (2017). **raster: Geographic Data Analysis and Modeling**. R package version 2.6-7. <https://CRAN.R-project.org/package=raster>

TEIXEIRA, Paulo César et al. **Manual de métodos de análise de solo**. 3. ed. rev ed. Brasília, DF: Embrapa, 2017.