

MAPEAMENTO DIGITAL DE ATRIBUTOS FÍSICO-QUÍMICOS DE SOLOS DO PLANALTO CUNDIBOYACENSE NA COLÔMBIA

VIVIANA MARCELA VARÓN RAMÍREZ¹, GUSTAVO ALFONSO ARAUJO CARRILLO², CAMILO IGNACIO JARAMILLO BARRIOS³, DOUGLAS ANDRÉS GÓMEZ LATORRE⁴, JHON MAURICIO ESTUPIÑAN CASALLAS⁵, FABIO ERNESTO MARTÍNEZ MALDONADO⁶.

¹ MSc. Ingeniería Agrícola, Corporación Colombiana de Investigación Agropecuaria - AGROSAVIA, (+57 1) 4227300 Ramal 1456, vvaron@agrosavia.co.

² MSc. Ciencias de la Geoinformación y Observación de la Tierra, Corporación Colombiana de Investigación Agropecuaria - AGROSAVIA, (+57 1) 4227300 Ramal 1221, garaujo@agrosavia.co.

³ MSc. Estadística Aplicada, Corporación Colombiana de Investigación Agropecuaria - AGROSAVIA, (+57 1) 4227300 Ramal 2615, cijaramillo@agrosavia.co.

⁴ MSc. Ciencias – Meteorología, Corporación Colombiana de Investigación Agropecuaria - AGROSAVIA, (+57 1) 4227300 Ramal 1225, dagomez@agrosavia.co.

⁵ MSc. Recursos Hidráulicos, Corporación Colombiana de Investigación Agropecuaria - AGROSAVIA, (+57 1) 4227300 Ramal 1221, jmestupinan@agrosavia.co.

⁶ MSc. Ciencias agrarias, Corporación Colombiana de Investigación Agropecuaria - AGROSAVIA, (+57 1) 4227300 Ramal 1227, femartinez@agrosavia.co.

Apresentado no
XLVIII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2019
17 a 19 de setembro de 2019 - Campinas - SP, Brasil

RESUMO: A modelagem dos padrões do comportamento espacial dos atributos do solo permite o entendimento das relações complexas que existem entre elas. O objetivo deste trabalho foi realizar o mapeamento digital de atributos físico-químicos dos solos do planalto Cundiboyacense na Colômbia. Foram mapeados 16102 km² a partir das análises de 1728 amostras de solo e da construção de variáveis preditoras (geologia, geomorfologia, clima, cobertura e uso do solo) e modelos de aprendizagem de máquina. Foram obtidas superfícies de distribuição espacial de atributos físicos e químicos com resolução de 125 m, seus modelos apresentaram coeficientes de determinação (R^2) entre 0,2 e 0,6, e um erro quadrático médio (RMSE) entre 0,2 e 25,3, sendo que os atributos matéria orgânica, densidade do solo e cálcio intercambiável apresentaram os maiores índices de bondade de ajuste. Em relação as covariáveis preditoras, aquelas derivadas do modelo de elevação digital e as temperaturas ambientais foram as que apresentaram maior correlação com os atributos do estudo.

PALAVRAS-CHAVE: Mapeamento digital de solos, aprendizagem de máquina, variáveis preditoras

DIGITAL MAPPING OF SOIL PHYSICOCHEMICAL PROPERTIES IN THE COLOMBIAN CUNDIBOYACENSE HIGHLAND

ABSTRACT: Modeling spatial behavior patterns of soil properties allows us to understand the complex relationships that exist between them. The aim of the present work was to carry out the digital mapping of some physicochemical properties from the soils of the Cundiboyacense highlands (16102 km²) in Colombia, through the analysis of 1728 soil samples and the construction of predictor variables (geology, geomorphology, climate, coverage and use) and assembled machine learning models. As a result surfaces of spatial distribution of some physical and chemical properties were obtained with a resolution of 125 m whose models showed coefficients of determination (R^2) between 0,2 and 0,6 and a mean

square error (RMSE) between 0,2 and 25,3, being properties such as organic matter (OM), bulk density (BD) and exchangeable calcium (Ca) those with a higher goodness of fit ratios. As for the predictive covariates, those derived from the digital elevation model and the environmental temperatures were those that showed the highest correlation with the study properties.

KEYWORDS: Digital soil mapping, assembled models, predictor variables.

INTRODUÇÃO: O conhecimento do solo permite orientar as práticas de manejo e o desenvolvimento da agricultura sustentável, o que permite realizar ações encaminhadas a garantir a segurança alimentar de um território (Ramos et al., 2018). Conhecer e modelar os padrões do comportamento espacial dos atributos do solo permite o entendimento das relações complexas que existem entre elas (Sánchez et al., 2009). Diante disso, diversos estudos têm sido desenvolvidos objetivando na realização do mapeamento digital dos atributos dos solos a escalas globais (Hengl et al., 2015), continental (Hengl et al., 2017) e a escalas nacionais (Ramos et al., 2018). Na Colômbia estudos locais têm sido realizados com a implementação de técnicas geoestatísticas (Varón-Ramírez et al., 2018) e de aprendizagem de máquina (Guevara et al., 2018). Por tanto, O objetivo deste trabalho foi realizar o mapeamento digital de atributos físico-químicos dos solos do planalto Cundiboyacense na Colômbia.

MATERIAL E MÉTODOS: O estudo foi desenvolvido em 16102 km² da região do planalto Cundiboyacense (Colômbia) (Figura 1A), com precipitação média anual varia entre 189 e 3107 mm, e temperatura média entre 6,3 e 25,7 °C. Os solos predominantes são da ordem da ordem de andisol e inceptisol (Soil Survey Staff, 2014). Os atributos do solo foram coletados a partir da compilação de informação secundária de projetos e parcerias entre a Corporação Colombiana de Pesquisa Agropecuária e instituições como o Instituto Geográfico Agustín Codazzi, permitindo obter 1728 observações. O mapeamento digital do solo foi realizado mediante técnicas de aprendizagem de máquina conforme descrito na Figura 1B. A construção de covariáveis preditoras foi feito a partir de fontes de informação secundária como estudos geológicos, agrológicos e a análises de estações meteorológicas. A definição do tamanho do pixel para as saídas finais foi feita conforme metodologia descrita por Hengl (2006).

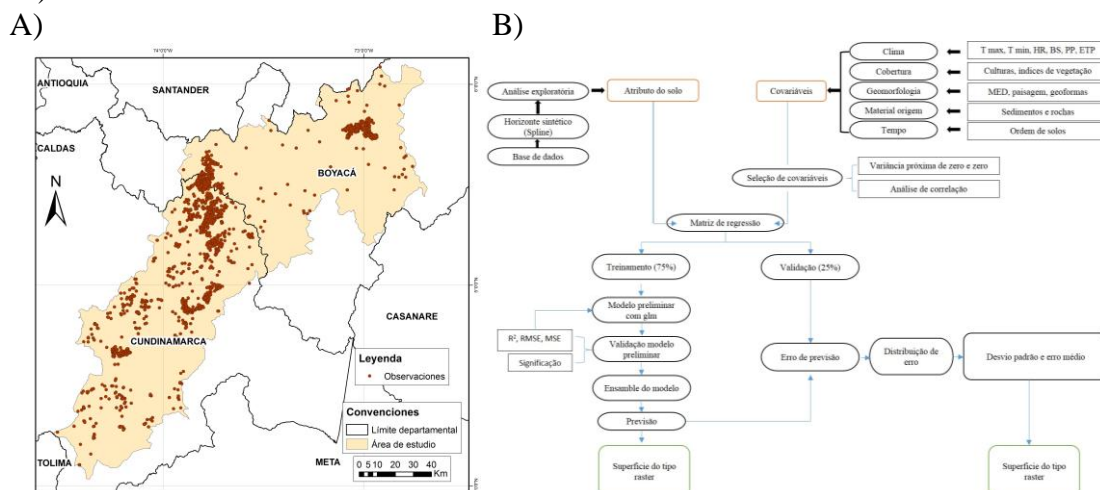


FIGURA 1. A). área de estudo e distribuição das observações. B). Metodologia do mapeamento digital dos solos.

RESULTADOS E DISCUSSÃO: os solos apresentaram condições de variabilidade moderada a alta (CV superiores a 12%) segundo classificação de Warrick (1980). Na maioria dos atributos do solo, deve-se ao fato dos solos da zona de estudo ter evoluído com

características e interação entre fatores formadores se apresentam os parâmetros de bondade de ajuste do modelo linear generalizado (glm) (modelo ensablado) construído para cada atributo.

Atributos como matéria orgânica (OM), densidade do solo (Ds) e Sódio (Na) apresentaram modelos com altos coeficientes de determinação explicando entre 52 e 60% da variação dos dados. Coeficientes de correlação similares foram obtidos por Hengl et al. (2015) na África y Hengl et al. (2017) a nível global com una resolução de 250 m. Na figura 2, apresenta-se a distribuição espacial do teor de OM do solo e a incerteza na predição para cada pixel da superfície.

TABELA 1. Parâmetros de bondade de ajuste dos modelos lineares generalizados (glm).

Atributos do solo	Ensemble model (glm)	R ²	RMSE	MAE
Cálcio (Ca)	-0,39079+1,01188rf +0,21624cubist -0,18923gbm	0.398	5.566	3.290
Magnésio (Mg)	-0,19100 -0,21524gbm+1,28985	0.455	1.592	0.973
Sódio (Na)	-0,02737+1,10435rf -0,10688pls	0.566	0.521	1.283
Alumínio (Al)	-0,105+0,309ranger+ 0,382xgbTree +0,175knn+0,231knn	0.443	1.691	1.009
Fósforo (P)	1,0915+0,4531rf+0,3553cubist+0,1427knn	0.204	25.354	50.760
Capacidade de intercâmbio (ECEC)	-0,17162+0,43591rf +0,31849 ranger+0,31564 cubist-0,06891pls	0.456	7.735	4.583
pH	-0,1700+0,3862rf+0,6458ranger	0.303	0.709	0.521
Matéria orgânica (OM)	-0,5667+0,1324 rf+0,3054ranger +0,4031cubist+0,1956knn	0.603	6.147	4.294
Condutividade elétrica (EC)	-0,033+0,668rf +0,411ranger +0,0007svmLinear-0,018cubist +0,003xgbTree - 0,189knn+ 0,085knn+ 0,075pls	0.323	1.026	0.450
Argila (Ar)	-4,76609+0,31358xgbTree+0,95352 ranger-0,13320svmPoly	0.192	15.181	12.398
Densidade do solo (Ds)	-0,074+0,135pls+0,124 xgbTree-0,109svmPoly+0,756ranger-0,154rf+0,337 cubist	0.520	0.237	0.187
Textura do solo	Random Forest (classification)	Accuracy: 0.427		Kappa: 0.189

Métodos: Random Forest (rf), Cubist (cubists), Stochastic Gradient Boosting (gbm), Partial Least Squares (pls), Random Forest (ranger), eXtreme Gradient Boosting (xgbTree), k-Nearest Neighbors (knn), Support Vector Machines with Linear Kernel (svmLinear), Support Vector Machines with Polynomial Kernel (svmPoly).

Os modelos construídos para os atributos conseguiram explicar entre 30 e 45% da variação dos dados, valores superiores aos encontrados por Mosleh et al. (2016) avaliando árvores de regressão para mapear EC y Ca obtindo R² de 0,16 y 0,02, portanto é de esperar que um modelo elaborado com algoritmos más complexos como um bosque aleatório de arvores de regressão (Ex. rf, ranger e cubist) consiga encontrar um modelo no qual as covariáveis ambientais expliquem uma porcentagem maior na variação dos dados (Zeraatpisheh et al., 2019). Não entanto, outros autores como Hengl et al. (2015) lograram construir modelos que explicaram até 69 % e 78% da variabilidade do Ca e Mg na África, construindo modelos ensablados via glm.

As variáveis predictoras através da análise de correlação de Pearson demostraram que as covariáveis derivadas do modelo de elevação digital (DEM) como a pendente, a rugosidade e a textura da superfície. As superfícies de temperaturas máximas e mínimas do dia apresentaram uma alta correlação com atributos físicos do solo como o teor de argila e a densidade do solo, e com químicos como pH, MO, Ca e Al. Uma correlação média foi obtida nos índices de vegetação, índice de área foliar e temperatura superficial da terra no dia. Finalmente, covariáveis como os índices de curvatura e convergência do terreno, temperatura superficial da terra na noite, brilho solar e umidade relativa apresentaram baixas com os atributos do solo.

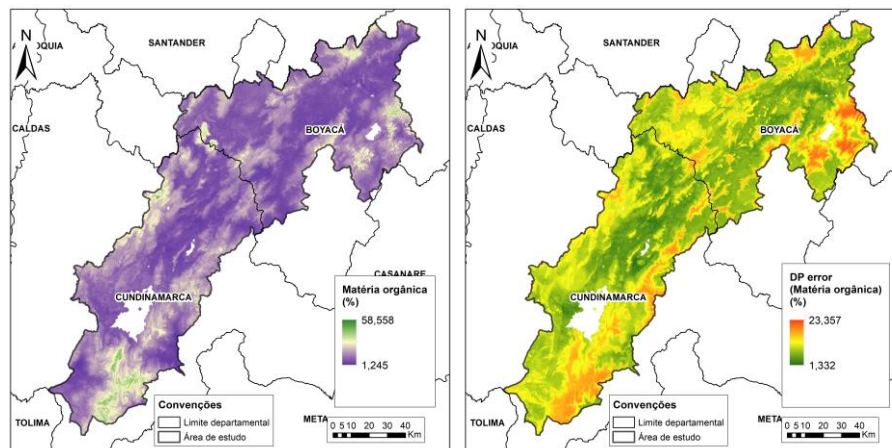


FIGURA 2. A) Predição espacial da matéria orgânica. B) Incerteza da predição

CONCLUSÕES: O mapeamento digital constitui uma ferramenta no entendimento das relações complexas dos atributos do solo e seu entorno. Não existe um único modelo que seja capaz de explicar o comportamento espacial de todos os atributos do solo, assim, a bondade de ajuste de cada um deles dependerá da variabilidade de fatores formadores presentes na zona de estudo, a diversidade no uso, a quantidade de informação disponível e a precisão das covariáveis predictoras. A disposição para consulta online e descarga para usuários básicos e avançados deste tipo de informação deve constituir-se o seguinte passo. As superfícies geradas poderiam melhorar na sua predição se o modelo se alimenta com maior informação dos solos e com covariáveis a escalas mais detalhadas.

REFERÊNCIAS:

- Warrick, A. W. (1980). Spatial variability of soil physical properties in the field. Application of soil physics: 319-344.
- Guevara, m.; olmedo, g. F.; stell, e.; yigini, y.; aguilar duarte, y.; arellano hernández, c.; arévalo, g. E.; arroyo-cruz, c. E.; bolivar, a.; bunning, s.; bustamante cañas, n.; cruz-gaistardo, c. O.; davilla, f.; dell acqua, m.; encina, a.; figuero tacona, h.; fontes, f.; hernández herrera, j. A.; ibelles navarro, a. R.; loayza, v.; manueles, a. M.; mendoza jara, f.; olivera, c.; osorio hermosilla, r.; pereira, g.; pietro, p.; ramos, i. A.; rey brina, j. C.; rivera, r.; rodríguez-rodríguez, j.; roopnarine, r.; rosales ibarra, a.; rosales riveiro, k. A.; schulz, g. A.; spence, a.; vasques, g. De m.; vargas, r. R.; vargas, r. 2018. No silver bullet for digital soil mapping: country-specific soil organic carbon estimates across Latin America. SOIL (4): 173–193.
- Hengl T. 2006. Finding the right pixel size. Computers & Geosciences (32): 1283–1298.
- Hengl T, Heuvelink GBM, Kempen B, Leenaars JGB, Walsh MG, Shepherd KD, et al. 2015. Mapping Soil Properties of Africa at 250 m Resolution: Random Forests Significantly Improve Current Predictions. PLoS ONE 10(6).
- Hengl T, Mendes de Jesus J, Heuvelink GBM, Ruiperez Gonzalez M, Kilibarda M, Blagotić A, et al. 2017. SoilGrids250m: Global gridded soil information based on machine learning. PLoS ONE 12(2): e0169748.
- Mosleh, Z., Salehi, M. H., Jarafi, A., Borujeni, I. E., Mehnatkesh, A. 2016. The effectiveness of digital soil mapping to predict soil properties over low-relief areas. Environ Monit Assess:188-195.
- Varón-Ramírez V. M., Camacho-Tamayo J.H., González-Nivia J. 2018. Management zones determination based on physical properties of the soil. Ciência e Agrotecnologia, 42(3):248-260.
- Soil Survey Staff. 2014. Keys to Soil Taxonomy, 12th ed. USDA-Natural Resources Conservation Service, Washington, DC.
- Zeraatpisheh, M., Ayoubi, S., Jafari, A., Tajik, S., & Finke, P. 2019. Digital mapping of soil properties using multiple machine learning in a semi-arid region, central Iran. Geoderma (338): 445-452.