

Nota técnica

MAPEO DIGITAL DE SUELOS AGRÍCOLAS EN LA REGIÓN OCCIDENTAL DEL VALLE CENTRAL DE COSTA RICA

Bryan Alemán-Montes^{1/}*, Andrés Búcaro-González^{**}, Carlos Henríquez-Henríquez^{***},
Kenneth Largaespada-Zelaya^{****}

Palabras clave: Mapeo digital de suelos; covariables ambientales; Valle Central Occidental de Costa Rica; fertilidad de suelos; sistemas de información geográfica.

Keywords: Digital soil mapping; pedometric; Western Central Valley of Costa Rica; soil fertility; geographic information systems.

Recibido: 12/09/18

Aceptado: 24/01/19

RESUMEN

El mapeo digital de suelos (MDS) se ha convertido en otra herramienta válida para la generación de información más precisa y actual sobre la variabilidad espacial de los suelos. Aunque se reconocen varias ventajas propias de esta disciplina, su aplicación y aprovechamiento han sido limitados en las regiones tropicales. Con el fin de evaluar el potencial de uso del MDS se desarrolló un ejercicio de mapeo de 3 atributos de la fertilidad del suelo, el pH, la acidez y la CICE en una zona agrícola con influencia de 3 cooperativas en la región occidental del Valle Central de Costa Rica, para lo cual se empleó el marco conceptual scorpan-SSPFe propuesto por McBratney *et al.* 2003. Para realizar el ejercicio se utilizaron 384 resultados de análisis químicos

ABSTRACT

Digital Soil Mapping in Agricultural Lands Located at the Western Central Valley of Costa Rica. Digital soil mapping (DSM) has become a valuable tool in order to generate accurate and current soil information. It is recognized that digital soil mapping presents some advantages compared to traditional soil surveys. Despite the growing demand for soil information, application of digital soil mapping in tropical context is still insufficient. In order to evaluate the potential use for DSM in agricultural zones managed by cooperatives in the Western Central Valley of Costa Rica, an exercise was performed to mapping three soil fertility properties (pH, acidity and ECEC) using the *scorpan-SSPFe* conceptual model proposed by McBratney *et al.*

1 Autor para correspondencia. Correo electrónico: bryan.aleman@ucr.ac.cr

* Universidad de Costa Rica, Centro de Investigaciones Agronómicas, Costa Rica.  0000-0003-4349-2255.

** Catholic Relief Services – USCCB, Guatemala.

 0000-0002-8991-4516.

*** Universidad de Costa Rica, Centro de Investigaciones Agronómicas, Costa Rica.  0000-0003-1487-4246.

**** Universidad de Costa Rica, Sede del Atlántico y Centro de Investigaciones Agronómicas, Costa Rica.  0000-0003-4651-443X.

de suelos, cada uno de ellos, con su respectiva ubicación geográfica, un modelo de elevación digital con resolución espacial de 30 m, imágenes satelitales disponibles para el periodo de estudio y registros climáticos del área de interés. A partir de dichas fuentes de información se generaron 24 capas de covariables espaciales que permitieron ajustar modelos lineales para inferir la variabilidad espacial de los atributos propuestos. Finalmente se evaluó la incertidumbre asociada a las predicciones, su alcance global y las limitaciones metodológicas en función de su posible implementación en otras regiones de producción agrícola en contexto similar.

INTRODUCCIÓN

Los atributos del suelo a partir del conocimiento de la variabilidad espacial es determinante para una adecuada gestión del recurso suelo (Heuvelink y Webster 2001, McBratney *et al.* 2003). El manejo de la fertilidad de los suelos, basado en un conocimiento preciso y actualizado, implica beneficios en la productividad y sostenibilidad de los cultivos (Henríquez *et al.* 2005, Villatoro *et al.* 2008). Es así como el mapeo digital de suelos (MDS) propone la determinación y cuantificación de la distribución espacial de los atributos y clases de suelos, a través del desarrollo de sistemas empíricos de inferencia entre las observaciones del suelo y un conjunto de variables representativas del paisaje referenciadas espacialmente (Lagacherie 2008, Grimm y Behrens 2010, Malone *et al.* 2017).

Entre las ventajas que se acreditan al MDS, se pueden citar la generación de productos en menor tiempo y costos, la construcción de inferencias estadísticas entre información de muestreos y características ambientales, la posibilidad de construir representaciones gráficas bajo un modelo de variación espacial continua, y la posibilidad de aplicar el MDS en lugares donde el acceso y la información de suelos son limitados

(2003) as basis. Data from 384 soil fertility tests, a digital elevation model (30 m spatial resolution), satellital imagery and climatic records were the inputs to build 24 covariates layers. There were adjusted linear model to make inferences about soil spatial variability and the uncertainty related to prediction was evaluated. The results are presented by each one of the 3 soil fertility attributes, also a global evaluation of scope and constraints of the proposed methodology as an opportunity to be implemented in other agricultural regions in similar contexts.

(Cambule *et al.* 2013, Malone *et al.* 2017). Asimismo, el MDS permite la estimación de la incertidumbre, asociada a las predicciones realizadas; esta incertidumbre puede ser causada por inconsistencias en el muestreo de suelos, diferencias en las metodologías analíticas empleadas, errores de laboratorio y de posicionamiento espacial, errores propios de las covariables ambientales y la falla propia de la técnica de modelización empleada (Heuvelink 2017), en términos generales evaluar la incertidumbre permite conocer la calidad del producto cartográfico generado.

La cartografía de propiedades de suelos se ha construido mediante distintas técnicas de análisis espacial, cada una con fortalezas y limitaciones metodológicas, se pueden citar algunos ejemplos donde se utilizaron los métodos: geoestadísticos (Henríquez *et al.* 2005, Henríquez *et al.* 2013, Pravat *et al.* 2016, Garbanzo *et al.* 2017), determinísticos (Villatoro *et al.* 2008, Fortis-Hernández *et al.* 2010), árboles de regresión (Scull *et al.* 2005, Taghizadeh-Mehrjardi *et al.* 2014) y machine learning (Brungard *et al.* 2015, Heung *et al.* 2016). No existe una técnica de modelización que pueda considerarse superior a otra, cada una puede o no funcionar mejor en contextos diferentes. De acuerdo a ejercicios realizados en

contextos similares, los modelos lineales han presentado un mejor desempeño en la modelización (modelos con menor incertidumbre) frente a técnicas de modelización del campo del aprendizaje automatizado, tales como Random Forest, que se plantean muy favorables por ser no paramétricas; otra ventaja de los modelos lineales es que su interpretación resulta práctica (Richardson *et al.* 2017, Búcaro 2017).

McBratney *et al.* (2003) proponen un modelo conceptual para el abordaje del MDS, este se denomina scorpan-SSPFe; el primer término del nombre hace referencia a una adaptación de la ecuación de los factores formadores del suelo propuesta por Jenny (1941), mientras que el sufijo hace referencia al término: funciones de predicción espacial de suelos con errores autocorrelacionados. Ambos términos explican conceptualmente las bases del modelo.

Con la finalidad de evaluar los alcances MDS, a partir de modelos lineales en condiciones de suelos tropicales, se desarrolló un ejercicio en la región Occidental del Valle Central de Costa Rica con el objetivo de generar mapas de la variabilidad espacial de los atributos: pH, acidez y CICE; en una región de aptitud agropecuaria de Costa Rica. Estas variables fueron consideradas al aprovechar los recursos fácilmente disponibles y aprovechando su relevancia en la gestión sostenible de la productividad del suelo. Como insumos se emplearon las bases de

información geográfica de 3 cooperativas agrícolas ubicadas en la región (CoopeAtenas R.L., CoopeVictoria R.L. y CoopAgrimar R.L.), el modelo de elevación digital e imágenes satelitales de la región de estudio.

MATERIALES Y MÉTODOS

El área de estudio abarcó parte de la Región Occidental del Valle Central, que incluye sectores de los cantones Alajuela, Atenas, San Ramón, Zarcero y Grecia, todos de la provincia Alajuela, Costa Rica. El área de estudio contó con una extensión aproximada de 1884 km², con una geodinámica externa que está dominada por relieves multiconvexos, principalmente en la parte Sur de la zona de estudio; las llanuras y las mesetas entalladas por profundos cañones de ríos se localizan en el sector central, mientras los edificios volcánicos y los piedemontes del Terciario y Cuaternario dominan en la parte Norte (Bergoing 1998). La variabilidad del relieve y de materiales parentales, aunado a los contrastes de temperatura y precipitación, generan la ocurrencia de asociaciones edáficas dominadas por Ustands, Humults, Ustepts y Orthents (Mata *et al.* 2013). Los suelos del área de estudio se destinan principalmente a actividades agropecuarias, donde predominan los cultivos de café, caña de azúcar, pasturas y hortalizas, entre otros (Figura 1).

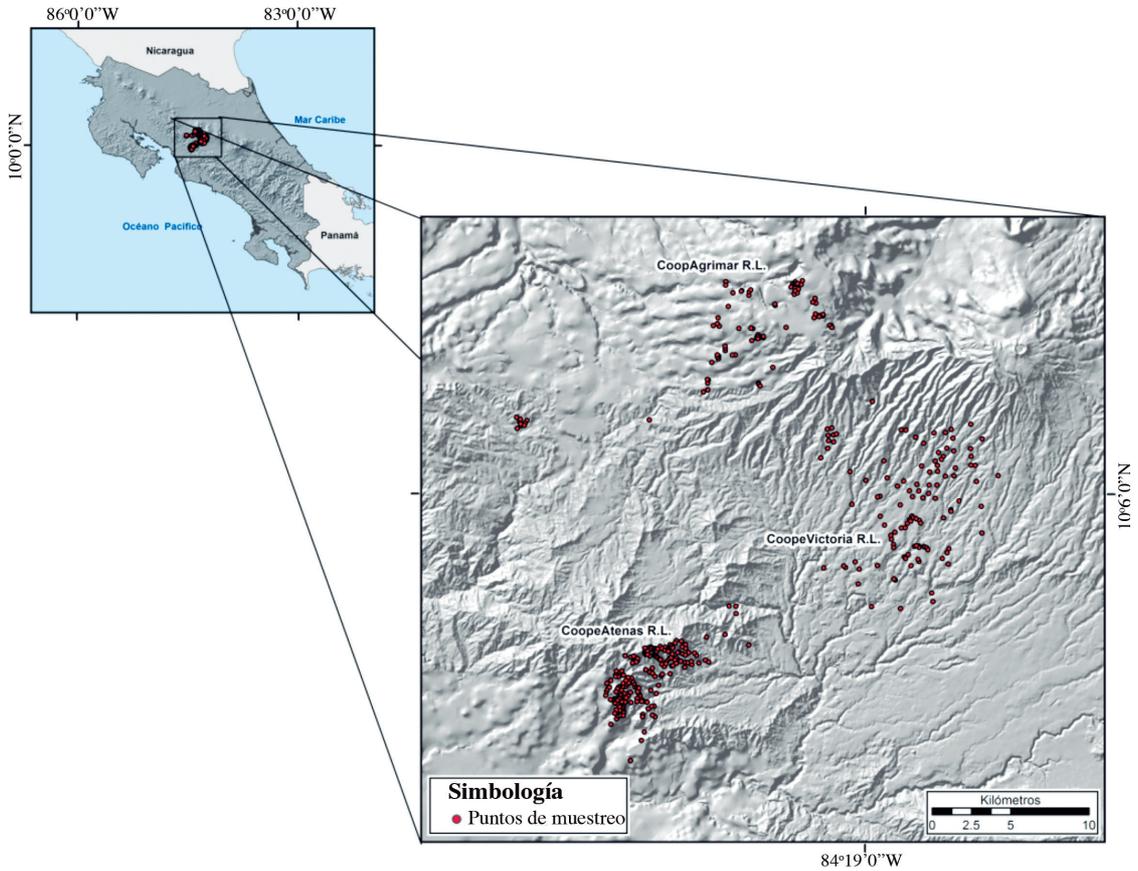


Fig. 1. Ubicación general del área de estudio ubicada en la región Occidental del Valle Central de Costa Rica.

Se utilizaron los registros georreferenciados de 384 análisis químicos de suelos con fines de fertilidad realizados entre 2012 y 2015 en las cooperativas CoopAgrimar R.L., CoopeAtenas R.L. y CoopeVictoria R.L., todas ellas dentro del área de estudio propuesta. El muestreo se llevó a cabo en el marco de un proyecto colaborativo y cofinanciado entre la Universidad de Costa Rica (UCR) y el Instituto de Fomento Cooperativo (INFOCOOP). Se recolectaron muestras compuestas por cada lote previamente georreferenciado. Cada una estuvo constituida de 15 submuestras distribuidas aleatoriamente dentro del lote y colectadas de los primeros 20 cm

superficiales. La georreferenciación de los análisis de fertilidad se realizó a través de la asignación de dicha información al centroide del polígono que delimitaba cada lote muestreado.

Además, de la recopilación de estas muestras de suelos, se construyeron 24 capas de variables asociadas a los factores de formación del suelo que serían utilizadas como covariables (Cuadro 1). Para la construcción de estas capas se consideró el modelo conceptual scorpan-SSPF. Con una adaptación de la ecuación propuesta para explicar cuantitativamente la relación entre los factores formadores del suelo y su génesis (Jenny 1941).

Cuadro 1. Fuentes y variables predictoras generadas para desarrollar los modelos de predicción.

Covariables de imagen LANDSAT 8		12	Sombreado Analítico (ANAHILL)
1	Banda 1	13	Pendiente (SLOPE)
2	Banda 2	14	Aspecto (ASPECT)
3	Banda 3	15	Curvatura del Plano (PLANC)
4	Banda 4	16	Curvatura del Perfil (PROFILEC)
5	Banda 5	17	Índice de Convergencia (CONINDEX)
6	Banda 6	18	Área de Acumulación (CATAREA)
7	Banda 7	19	Índice de Humedad (WI)
8	NDVI	20	Factor de Largo de Pendiente (LSFACTOR)
Covariables de Registros Climáticos		21	Nivel Base de la Red de Drenaje (CHNBL)
9	Temperatura (TEMP)	22	Altura sobre la Red de Drenaje (AACHN)
10	Precipitación (PP)	23	Índice Multirresolución Depresional de Valles (MRVBF)
Covariables del DEM		24	Índice Multirresolución de Llanura de Crestas (MRRTF)
11	Altitud (DEM)	---	---

El modelo queda representado por la siguiente ecuación:

$$Sc = f(s, c, o, r, p, a, n) + e,$$

Sc = representa el atributo o clase del suelo a modelizar o predecir, como una función de

S = suelo (observaciones previas de clases o atributos del suelo);

c = clima (precipitación, temperatura, evapotranspiración, etc.);

o = organismos (actividad biótica o antrópica);

r = relieve (atributos del paisaje geomorfológico);

p = material parental (litología asociada a un punto determinado);

a = edad (tiempo transcurrido para la génesis del suelo) y

n = espacio o posición espacial.

Finalmente, se hace referencia a la incertidumbre asociada al modelo, es decir, a las predicciones de los atributos o clases de suelos.

Aunque en este caso no se pretende su uso para explicar la pedogénesis, sino para describir de forma empírica y cuantitativa las relaciones entre el suelo y otras variables espacialmente referenciadas que describen su ambiente o paisaje.

Fueron empleados 4 insumos básicos para la construcción de las capas predictoras: el modelo de elevación digital (DEM) con una resolución espacial de 30 m, una imagen LANDSAT 8 OLI del área de estudio correspondiente a la época seca y 2 capas climáticas (precipitación y temperatura media anual) de la región de estudio (Cuadro 1). A partir del DEM se construyeron 14 capas de atributos morfométricos primarios y secundarios para utilizarlos como predictores representativos del relieve; de la imagen LANDSAT 8 OLI se emplearon las bandas 1 a 7 y un NDVI como predictores representativos de los organismos. Las capas de precipitación y temperatura también fueron empleadas como predictores representativos del clima.

Para cada punto asociado a un análisis de fertilidad se extrajeron los valores correspondientes de las 24 capas predictoras o covariables, los cuales conformaron la base de datos que se empleó en la modelización de los atributos propuestos. Se seleccionaron aleatoriamente y separaron del conjunto de datos 84 observaciones que se emplearon posteriormente en la validación de los resultados (Henríquez *et al.* 2013). Se realizó una modelización de los atributos (pH, Acidez y CICE) como función de las variables predictoras generadas al emplear modelos lineales, se utilizaron los algoritmos de selección de variables paso a paso desde su introducción y eliminación progresiva con la finalidad de obtener modelos más parsimoniosos. Se seleccionó el mejor modelo obtenido para cada atributo con base en el Criterio de Información de Akaike (CIA), el cual indica la calidad relativa del modelo a partir de las variables utilizadas; por tanto, el CIA sólo tiene sentido cuando se comparan modelos creados a partir del mismo conjunto de datos.

También se realizó el proceso de validación para corroborar la consistencia de la incertidumbre asociada a cada modelo (Villatoro *et al.* 2008, Garbanzo-León *et al.* 2017). Se evaluó la autocorrelación espacial de los residuos de cada modelo para la realización del krigaje de los mismos. La capa de los residuos interpolados se sumó a la capa generada para cada modelo lineal, respectivamente, lo cual generó un nuevo modelo. Se extrajeron los valores predichos del nuevo modelo para los puntos de validación y se realizó nuevamente el proceso de validación según la propuesta de McBratney *et al.* (2003). Se seleccionó el mejor modelo obtenido y se construyó un mapa para cada atributo propuesto, utilizando álgebra de mapas.

RESULTADOS Y DISCUSIÓN

Al evaluar el CIA para los modelos de pH, el modelo lineal que presentó mejor desempeño predictivo para el pH de suelo fue:

$$\begin{aligned} \text{pH} = & 6,00 \times 10^0 - 7,03 \times 10^{-2}(\text{TEMP}) + 6,93 \times 10^{-4}(\text{CHNBL}) - 6,25 \times 10^{-2}(\text{WI}) \\ & - 8,75 \times 10^{-1}(\text{SLOPE}) - 9,87 \times 10^{-4}(\text{AACHN}) + 1,42 \times 10^{-4}(\text{PP}) \end{aligned}$$

En donde pH es el valor predicho de pH del suelo en agua (relación suelo agua 1:2.5), TEMP es la temperatura media anual (°C), CHNBL es la altura basal del nivel de drenaje (m), WI es el índice de humedad (adimensional), SLOPE es el valor de pendiente (%), AACHN es la altura sobre el nivel basal de drenaje (m) y PP es la

precipitación media anual (mm). La combinación de dichas covariables presentó como resultado la variación espacial del pH que se presenta en la Figura 2A. El modelo seleccionado evidenció un aumento del pH cuando aumentaba CHNBL y PP, caso contrario sucedió con las restantes 4 covariables seleccionadas.

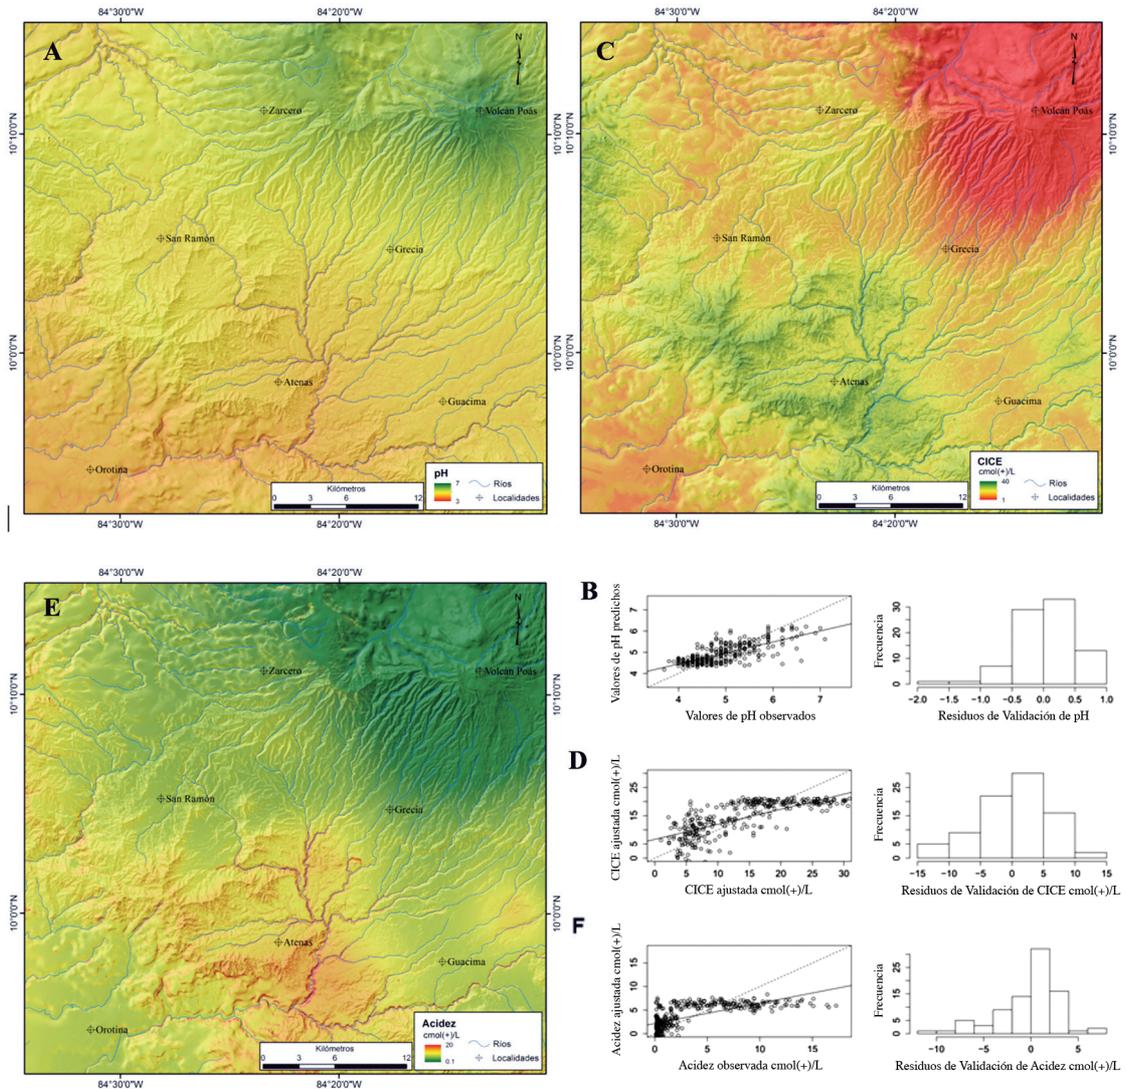


Fig. 2. Variables predictoras generadas para la realización de los ejercicios de MDS. (A) Mapa de pH generado a partir del modelo descrito. (B) Gráfico de dispersión de valores observados contra predichos para el modelo de pH e histograma de residuos de validación. (C) Mapa de CICE generado a partir del modelo descrito. (D) Gráfico de dispersión de valores observados contra predichos para el modelo de CICE e histograma de residuos de validación. (E) Mapa de Acidez generado a partir de modelo descrito. (F) Gráfico de dispersión de valores observados contra predichos para el modelo de acidez e histograma de residuos de validación.

Este modelo alcanzó a explicar el 51% de la variación en el pH (según R^2), al emplear 6 variables predictoras, y presentó un error estándar residual de 0,45. Los resultados de validación

evidenciaron una desviación estándar de los residuos de 0,49, promedio absoluto del error de 0,37, promedio de los errores de 0,24. Estos datos demuestran la consistencia de la incertidumbre

asociada al modelo. La consistencia entre la incertidumbre propia del modelo y la incertidumbre evaluada, a través de la validación, radica en la similitud entre el error estándar residual del modelo y la desviación estándar de los residuos de validación. La diferencia de 0,04 unidades de pH entre ambos datos puede explicarse por la diferencia en el tamaño de la muestra de los datos empleados para entrenar el modelo ($n=300$) y los empleados en la validación ($n=84$).

El desempeño de predicción del modelo para el pH se consideró aceptable, ya que se encontró consistencia del modelo en relación con el cumplimiento de los supuestos de la

regresión lineal múltiple. Asimismo, el error estándar residual se interpreta al estimar que, aproximadamente con un 70% de confiabilidad, el valor real de pH se encontrará entre el intervalo que va del valor predicho $\pm 0,45$ (Figura 2B). De acuerdo con el análisis de varianza y a los análisis de sensibilidad realizados, el factor con mayor poder predictor es la temperatura, seguida por la pendiente, el nivel base de red de drenaje, la altura sobre el nivel de drenaje, el índice de humedad y la precipitación, respectivamente.

Para el caso de la CICE, el modelo lineal que presentó mejor desempeño predictivo fue:

$$\begin{aligned} CICE = & -1,08x10^2 + 5,01x10^0(TEMP) - 2,51x10^2(\sqrt{MRVBF}) + 1,19x10^{-2}(DEM) \\ & + 2,50x10^{-1}(LSFACTOR) - 1,54x10^{-2}(AACHN) \end{aligned}$$

En donde CICE es el valor predicho de CICE ($\text{cmol}(+)\cdot\text{l}^{-1}$), TEMP es la temperatura media anual ($^{\circ}\text{C}$), MRVBF es el índice multiresolución depresional de valles (adimensional), DEM es el valor de altitud en metros sobre el nivel del mar (m), LSFACTOR es el valor del índice de largo de pendiente (adimensional) y AACHN es la altura sobre el nivel basal de drenaje (m); para este caso la variación espacial de la CICE del suelo en la región de interés se presenta en la Figura 2C.

Este modelo alcanzó a explicar el 52% de la variación en la CICE (según R^2) al emplear 5 variables predictoras y presentó un error estándar residual de $5,94 \text{ cmol}(+)\cdot\text{l}^{-1}$. Los resultados de validación evidenciaron una desviación estándar de los residuos de $5,87 \text{ cmol}(+)\cdot\text{l}^{-1}$, un promedio absoluto del error de $4,53 \text{ cmol}(+)\cdot\text{l}^{-1}$ y un promedio de los errores cuadrados de $34,37 (\text{cmol}(+)\cdot\text{l}^{-1})^2$. Estos datos demuestran la consistencia de la incertidumbre asociada al modelo.

Con base en los resultados, se consideró que el desempeño de predicción del modelo para la CICE es medianamente aceptable. Al considerar la consistencia del modelo en relación con el

cumplimiento de los supuestos de la regresión lineal múltiple, el error estándar residual se interpreta al estimar que, aproximadamente, con un 70% de confiabilidad el valor de real de CICE, se encontrará entre el intervalo que va del valor predicho $\pm 5,94 \text{ cmol}(+)\cdot\text{l}^{-1}$ (Figura 2D). De acuerdo con el análisis de varianza y los análisis de sensibilidad realizados, el factor con mayor poder predictor es la temperatura, seguida por la altitud, la raíz cuadrada del índice multiresolución depresional de valles, la altura sobre el nivel de drenaje y el factor de largo de pendiente, respectivamente. Una de las limitaciones notorias en el modelo es que no se alcanza a explicar aceptablemente la variación de los valores arriba de $20 \text{ cmol}(+)\cdot\text{l}^{-1}$, ya que tiene limitaciones para capturar la variación espacial local de la CICE, por lo cual es recomendable evaluar otras fuentes de información para generar nuevas variables predictoras; otro factor puede estar relacionado con la cantidad de observaciones utilizadas para la validación del modelo.

Por otra parte, el modelo que presentó mejor desempeño para la acidez fue:

$$ACIDEZ = -3,68x10^1 + 2,08x10^{-3}(DEM) + 1,70x10^0(TEMP) + 2,30x10^{-1}(LSFACTOR)$$

En donde ACIDEZ es el valor predicho de la acidez intercambiable ($\text{cmol}(+)\cdot\text{l}^{-1}$), DEM es el valor de altitud en metros sobre el nivel del mar (m), TEMP es la temperatura media anual ($^{\circ}\text{C}$) y LSFACTOR es el valor del índice de largo de pendiente (adimensional); lo cual dio como resultado la Figura 2E.

Este modelo alcanzó a explicar un 42% de la variación en la acidez (según R^2), al emplear 3 variables predictoras, y presentó un error estándar residual de $3,18 \text{ cmol}(+)\cdot\text{l}^{-1}$. Los resultados de la validación evidenciaron una desviación estándar de los residuos de $3,30 \text{ cmol}(+)\cdot\text{l}^{-1}$, un promedio absoluto del error de $2,44 \text{ cmol}(+)\cdot\text{l}^{-1}$ y un promedio de los errores cuadrados de $10,80 (\text{cmol}(+)\cdot\text{l}^{-1})^2$. Estos datos demuestran la consistencia de la incertidumbre asociada al modelo.

Al igual que los prototipos anteriores, el desempeño de predicción del modelo para la acidez se consideró medianamente aceptable. Al considerar la consistencia del modelo en relación con el cumplimiento de los supuestos de la regresión lineal múltiple, el error estándar residual se interpreta al estimar que con un 70% de confiabilidad el valor de real de acidez se encontrará entre el intervalo que va del valor predicho $\pm 3,18 \text{ cmol}(+)\cdot\text{l}^{-1}$ (Figura 2F). De acuerdo con el análisis de varianza y a los análisis de sensibilidad realizados, el factor con mayor poder predictor es la temperatura, seguida por la altitud y el factor de largo de pendiente, respectivamente. Este modelo logra explicar la variabilidad espacial de la acidez de forma global, al sacrificar las tendencias locales; por tanto, una de las limitaciones notorias en el modelo es que no se alcanza a explicar aceptablemente la variación de los valores arriba de $9 \text{ cmol}(+)\cdot\text{l}^{-1}$, como en el caso anterior es recomendable evaluar otras fuentes de información para generar nuevas variables predictoras.

CONCLUSIÓN

Los Modelos Digitales de Suelos (MDS) demostraron ser una herramienta potencialmente aplicable para la obtención de información útil en la estimación de la fertilidad de suelos a nivel regional en un escenario multifactorial lo cual aporta conocimientos más precisos y actuales respecto a la variabilidad espacial de los atributos y clases del suelo; asimismo, representa beneficios en términos de productividad y sostenibilidad en los cultivos. Aunque los modelos generados presentaron una fracción de incertidumbre asociada, se evidencia que representan una herramienta aplicable con menores costos y menos tiempo de ejecución, que genera representaciones de la variabilidad espacial continua, utilizables para la toma de decisiones agrícolas y permite aprovechar información generada previamente en zonas donde se cuenta con información de suelos. Dentro del contexto actual del sector agropecuario, se recomienda la utilización de los MDS, como una alternativa confiable para generación de datos y su análisis, para el recurso suelo.

AGRADECIMIENTOS

Este proyecto se desarrolló bajo el convenio entre el Instituto de Fomento Nacional Cooperativo y la Universidad de Costa Rica y en cumplimiento de los objetivos de los proyectos VI-733-B5-A11 y VI-733-B5-508.

LITERATURA CITADA

- Bergoeing, J. 1998. Geomorfología de Costa Rica. Instituto Geográfico Nacional. San José Costa Rica. 409 p.
- Brungard, C; Boettinger, J; Duniway, M; Wills, S; Edwards, T. 2015. Machine learning for predicting soil classes in three semi-arid landscape. *Geoderma* 239-240:68-83.
- Búcaro, JA. 2017. Modelización y mapeo digital de suelos en la cuenca del lago de Atitlán, Guatemala. Tesis de maestría, San José, Costa Rica, UCR. 101 p.

- Cambule, A; Rossiter, G; Stoorvogel, J. 2013. A methodology for digital soil mapping in poorly-accessible areas. *Geoderma* 192:341-353.
- Fortis-Hernández, M; Huerta-García, A; Segura-Castruita, M; Leos-Rodríguez, J; García-Salazar, A; Valdez-Cepeda, R. 2010. Validación de cuatro modelos de interpolación para cartografiar nitrato y anomio en suelo. *Terra Latinoamericana* 28(4):371-379.
- Garbanzo-León, JG; Alemán-Montes, B; Alvarado-Hernández, A; Henríquez-Henríquez, C. 2017. Validación de modelos geoestadísticos y convencionales en la determinación de la variación espacial de la fertilidad de suelos del Pacífico Sur de Costa Rica. *Investigaciones Geográficas* 93:1-22.
- Grimm, R; Behrens, T. 2010. Uncertainty analysis of sample locations within digital soil mapping approaches. *Geoderma* 155:154-163.
- Henríquez, C; Killorn, R; Bertsch, F; Sancho, F. 2005. La geoestadística en el estudio de la variación espacial de la fertilidad del suelo mediante el uso del interpolador Kriging. *Agronomía Costarricense* 29(2):73-81.
- Henríquez, C; Méndez, J; Masís, R. 2013. Interpolación de variables de fertilidad del suelo mediante el análisis Kriging y su validación. *Agronomía Costarricense* 37(2):71-82.
- Heung, B; Chak Ho, H; Zhang, J; Knudby, A; Bulmer, C; Schmidt, M. 2016. An overview and comparison of machine-learning techniques for classification purposes in digital soil mapping. *Geoderma* 265:62-77.
- Heuvelink, G; Webster, R. 2001. Modelling soil variation: past, present, and future. *Geoderma* 100:269-301.
- Heuvelink, G. 2017. Uncertainty. *In* Yigini, Y; Reiter, S; Baritz, R; Viatkin, K; Vargas, R (eds.). *Soil Organic Carbon Mapping CookBook*. 2 ed. Roma, Italia, FAO. p. 143-152.
- Jenny, H. 1941. *Factors of Soil Formation: A System of Quantitative Pedology*. New York, USA, McGraw Hill. 281 p.
- Lagacherie, P. 2008. Digital Soil Mapping, A State of the Art. *In* Hartemink, A; McBratney, A; Mendonça-Santos (eds.). *Digital Soil Mapping with Limited Data*. Berlín, Alemania, Springer. p. 3-14.
- McBratney, A; Mendonça-Santos, M; Minasny, B. 2003. On Digital Soil Mapping. *Geoderma* 117:3-52.
- Malone, B; Minasny, B; McBratney, A. 2017. *Using R for Digital Soil Mapping*. Switzerland, Springer. 262 p.
- Mata, R; Rosales, A; Vásquez, A; Sandoval, D. 2013. *Mapa de Subórdenes de Suelos de Costa Rica*. 2 ed. San José, Costa Rica. Asociación Costarricense de la Ciencia del Suelo. Escala 1:200,000. Color.
- Pravat, S; Gouri, B; Ramkrishna, M. 2016. Spatial analysis of soil properties using GIS based geostatistics models. *Modeling Earth Systems and Environment* 2:1-6.
- Richardson, H; Hill, D; Denesiuk, D; Fraser, L. 2017. A comparison of geographic datasets and field measurements to model soil carbon using random forests and stepwise regressions (British Columbia, Canada). *GIScience & Remote Sensing* 24:1:19.
- Scull, P; Frankling, J; Chadwick, O.A. 2005. The application of classification tree analysis to soil type prediction in a desert landscape. *Ecological Modelling* 181:1-15.
- Taghizadeh-Mehrjardi, R; Sarmadain, F; Minasny, B; Triantafyllis, J; Omid, M. 2014. Digital mapping of soil classes using decision tree and auxiliary data in the Ardakan Region, Iran. *Arid Land Research and Management* 28:147-168.
- Villatoro, M; Henríquez, C; Sancho, F. 2008. Comparación de los interpoladores IDW y Kriging en la variación espacial de pH, Ca, CICE y P del suelo. *Agronomía Costarricense* 32(1):95-105.



Todos los derechos reservados. Universidad de Costa Rica. Este artículo se encuentra licenciado con Creative Commons Reconocimiento-NoComercial-SinObraDerivada 3.0 Costa Rica. Para mayor información escribir a rac.cia@ucr.ac.cr