





Cartografía digital de suelos con regresión-Kriging y datos de sensores remotos

Digital soil mapping with regression-Kriging and data from remote sensing

Francisco Estrada-Godoy¹ , Gustavo Cruz-Cárdenas^{2†} ,
Salvador Ochoa-Estrada²  y José Teodoro Silva² 

¹ Instituto Politécnico Nacional, Escuela Superior de Ingeniería y Arquitectura (ESIA), Unidad Ticomán, COFAA. Av. Ticomán núm. 600, col. San José Ticomán. 07340 Delegación Gustavo A. Madero, Ciudad de México, México.

² Instituto Politécnico Nacional, CIIDIR-IPN-Michoacán, COFAA, Justo Sierra 28, col. Centro. 59510 Jiquilpan, Michoacán, México.

[†] Autor para correspondencia (guscruz@ipn.mx)

Editor de Sección: Dr. Fernando Ayala Niño

RESUMEN

El empleo de cartografía digital de suelos permite obtener información cuantitativa sobre la distribución y funcionamiento de los suelos, para proponer alternativas de manejo sobre dicho recurso. El objetivo de este trabajo fue realizar la predicción espacial de propiedades de suelo a través de regresión-kriging y que sirva de base para tomar las medidas necesarias de un uso sostenible del recurso. El área de estudio se encuentra en la ciénaga de Chapala porción Michoacán, México. El muestreo de suelo fue sistemático. En laboratorio se determinó, a cada muestra de suelo, la conductividad eléctrica, carbono orgánico, los cationes solubles (Ca, K, Mg, Na), nitrógeno total y pH. Las variables dependientes fueron nitrógeno total, conductividad eléctrica, carbono orgánico y pH. Las variables independientes las bandas del satélite Landsat 8. Se aplicó regresión-kriging para la predicción espacial. El ajuste de semivariograma experimental con modelos teóricos fue consistente para las cuatro propiedades de suelos, porque fue un diseño de muestreo sistemático y el tamaño de muestra de 297 puntos. El error cuadrático medio de la predicción espacial de conductividad eléctrica fue de 4, por presentar un coeficiente de variación de 355. Los suelos se consideraron con contenido de nitrógeno total de bajo a muy bajo (< 0.15%). Al menos 30% de los suelos presenta problemas de salinidad debido a que su conductividad eléctrica es mayor de 1.1 dS m⁻¹. Los contenidos de carbono orgánico se consideran de medios a altos (> 0.6%). El pH de los suelos es medianamente alcalino.

Palabras clave: algoritmo de aprendizaje automatizado, pedometría. scorpan.

SUMMARY

The use of digital soil mapping allows obtaining quantitative information on soil distribution and functioning to provide alternatives for their management. The objective of this research is to perform the spatial prediction of soil properties through regression-kriging and serve as a basis for taking the necessary measures for a sustainable use of the resource. The study area is located in the wetland Ciénaga de Chapala portion of Michoacán, Mexico. Soil sampling was systematic. In the laboratory, electrical conductivity, organic carbon, soluble cations calcium, potassium, magnesium, sodium (Ca, K, Mg, Na), total nitrogen and pH were determined for each soil sample. The dependent variables were total nitrogen, electrical conductivity, organic carbon and pH. The independent variables are the Landsat 8 satellite bands. Regression-kriging was applied for spatial prediction. The experimental



Cita recomendada:

Estrada-Godoy, F., Cruz-Cardenas, G., Ochoa-Estrada, S., & Teodoro-Silva, J. (2023). Cartografía digital de suelos con regresión-Kriging y datos de sensores remotos. *Terra Latinoamericana*, 41, 1-12. e1617. <https://doi.org/10.28940/terra.v41i0.1617>

Recibido: 7 de junio de 2022.
Aceptado: 22 de agosto de 2022.
Artículo. Volumen 41.
Enero de 2023.

semivariogram fit with theoretical models was consistent for the four soil properties, because it was a systematic sampling design and the sample size was 297 points. The root mean square error of the electrical conductivity spatial prediction was 4 because it showed a coefficient of variation of 355. Soils are considered having from low to very low total nitrogen content (<0.15%). At least 30% of the soils have salinity problems because their electrical conductivity is greater than 1.1 dS m⁻¹. Organic carbon contents are considered medium to high (>0.6%). The pH of the soils is moderately alkaline.

Index words: machine learning, pedometrics, scorpan.

INTRODUCCIÓN

Los suelos tienen varias funciones como amortiguamiento, regulador del clima, conservación de la biodiversidad, espacio habitable y actividades sobre él como la producción de alimentos, lo que lo hace un recurso valioso y existe la necesidad de ser estudiado de la manera más adecuada (Dominati, Patterson y Mackay, 2010).

Existen diferentes métodos cuantitativos y cualitativos propuestos para estudiar la distribución, funcionamiento y génesis de los suelos, los cuales se engloban en un área de conocimiento conocida como pedometría (Heuvelink, 2003). En la pedometría se encuentra el modelado y cartografía digital del suelo-paisaje (Grunwald, 2006).

Para la cartografía digital de suelos (CDS) existe un modelo conceptualizado por McBratney, Santos y Minasny (2003), conocido como SCORPAN, donde emplea la ecuación de formación del suelo para una descripción empírica cuantitativa entre el suelo y sus factores formadores, que se relacionan con su predicción. El SCORPAN se basa en siete factores: 1 atributos medidos del suelo (S), 2 clima (C), 3 organismos (O), 4 topografía (R), 5 material parental (P), 6 edad (A); 7 espacio y posición geográfica (N). Mediante el SCORPAN se pueden inferir clases o propiedades de suelos relacionadas con su nutrición, fertilidad, entre otros (Grunwald, 2009). Para lo cual, se emplean modelos matemáticos que permiten realizar la correlación entre factores y la predicción del suelo. McBratney *et al.* (2003) y Thompson, Roecker, Grunwald y Owens (2012) realizaron revisiones exhaustivas sobre los modelos matemáticos y se agrupan en técnicas geoestadísticas, modelos lineales generalizados y de aprendizaje automatizado.

Las técnicas geoestadísticas son las más empleadas para realizar la predicción de atributos o propiedades de suelos, entre las que destacan kriging ordinario, co-kriging y regresión-kriging (Grunwald, 2009). Con la técnica de regresión-kriging se han obtenido mejores resultados, ha probado ser la mejor para la generación de mapas de propiedades de suelos (Hengl, Heuvelink y Rossiter, 2007b; Sun, Minasny y McBratney, 2012a; Hengl *et al.*, 2015), de tipos de vegetación (Miller, Franklin y Aspinall, 2007) y distribución de especies (Allouche, Steinitz, Rotem, Rosenfeld y Kadmon, 2008; Hengl, Sierdsema, Radović y Dilo, 2009). Además, permite tomar en cuenta la autocorrelación espacial que presentan los residuales de la regresión (Ge, Thomasson, Sui y Wooten, 2011).

Las fuentes de información para representar los factores del SCORPAN son diversas, y con el avance de la tecnología se ha hecho fácil disponer de ellas, entre las que destacan por representar información de tipo espacial y temporal, son los datos de sensores remotos. Además, se puede disponer desde escala de parcela a nivel global. Se han utilizado para predecir diferentes propiedades físicas y químicas como la textura, humedad, mineralogía, carbono orgánico, nitrógeno y salinidad (Mulder, De Bruin, Schaepman y Mayr, 2011; Rossiter, 2018).

El objetivo de la investigación fue contribuir al mejor entendimiento de la variabilidad espacial de algunas propiedades de los suelos existentes en la Ciénega de Chapala, Michoacán. Mediante la técnica geoestadística conocida como regresión-kriging y datos de sensores remotos.

MATERIALES Y MÉTODOS

Área de Estudio

En el periodo de 1904 a 1908 se construyó el bordo de Maltaraña para la desecación de la parte sureste del lago de Chapala, dando como origen a lo que hoy se conoce como la Ciénega de Chapala, porción Michoacán (Loeza, Ramírez y Reyes, 2015). La Ciénega de Chapala se localiza al noroeste del estado de Michoacán, entre las coordenadas 102° 45' O y 20° 12' N y 102° 30' O y 20° 05' N; su superficie es de 546.55 km² (Figura 1). Los tipos de suelos son Vertisoles y Fluvisoles principalmente. Los principales cultivos son maíz (*Zea mays*), sorgo (*Sorghum spp.*), cebolla (*Allium cepa*), alfalfa (*Medicago sativa*) y jitomate (*Solanum lycopersicum*) los cuales cuentan con riego. El clima es semicálido subhúmedo.

Muestreo y Análisis de Suelos

El esquema de muestreo fue sistemático y el tamaño de muestra de 297 puntos (Anexo 1), resultando una separación de 1357 m entre puntos. En cada sitio se colectó un kg de suelo a una profundidad de 0-30 cm. En laboratorio se determinó a cada muestra de suelo la conductividad eléctrica (extracto de saturación y conductímetro), carbono orgánico (Walkley-Black), los cationes solubles (Ca, K, Mg, Na; extracto de saturación, espectrometría de absorción atómica y espectrometría de adsorción), nitrógeno total (micro-Kjeldahl) y el pH (H₂O 1:2.5) (Van Reeuwijk, 2002). Para cada una las propiedades de suelos se obtuvieron las estadísticas descriptivas.

Regresión-Kriging

La regresión-kriging (RK) es la combinación de un modelo lineal múltiple (MLM) y kriging ordinario (Hengl, 2007a). La combinación de las dos técnicas se realizó adicionando los residuales de MLM (variable dependiente de la propiedad de suelo de interés y variables independientes, factores del SCORPAN) al kriging ordinario (Ecuación 1). Esta relación se establece por la siguiente formula:

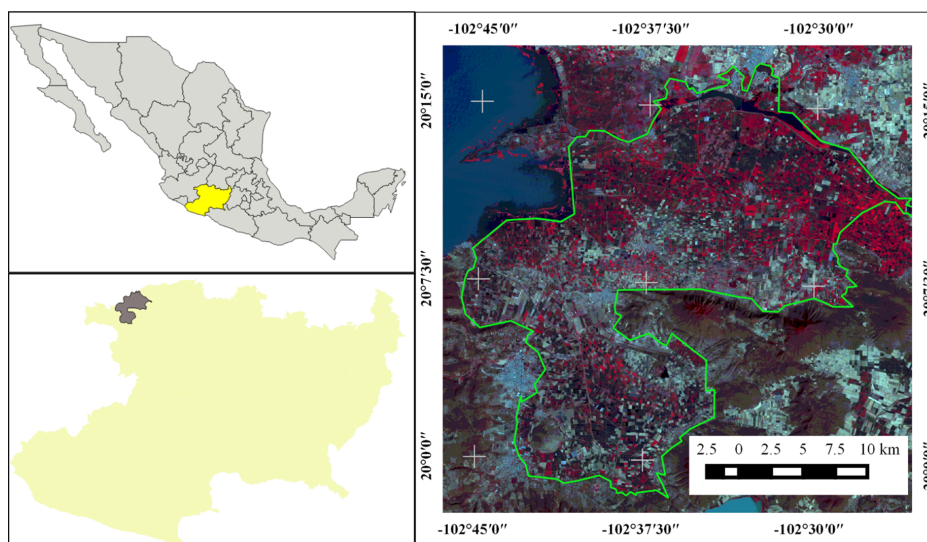


Figura 1. Localización del área de estudio.
Figure 1. Location of the study area.

$$\hat{z}(s_0) = \hat{m}(s_0) + \hat{e}(s_0) \quad (1)$$

Donde $\hat{z}(s_0)$ es predicción final de regresión-kriging, $\hat{m}(s_0)$ es el MLM ajustado, $\hat{e}(s_0)$ son los residuales.

En la RK se puede mejorar la predicción de la variable objetivo si se incorpora información de efectos aleatorios en el MLM, que consiste en agrupar los sitios o puntos de muestreo en grupos con características similares (Omuto y Vargas, 2015). Para este estudio así se generaron los grupos: 1) se realizó un análisis de componentes principales a las 10 variables de suelo; 2) se seleccionaron los primeros componentes principales que representaron más de 80% de la varianza acumulada para realizar un análisis clúster jerárquico (distancia euclidiana y método Ward). Los factores del SCORPAN para el MLM fueron datos de sensores remotos del satélite Landsat 8 del 5 de mayo de 2013 (bandas de la 2 a la 8). El nitrógeno total (N), conductividad eléctrica (CE), carbono orgánico (CO) y pH fueron las variables de interés a predecir. Los residuales del MLM se emplearon para construir el semivariograma experimental, se ajustaron siete modelos teóricos (bessel, esférico, exponencial, gaussiano, lineal, matern, pentaesférico) y se seleccionó el de menor error. Posteriormente se realizó la predicción espacial de las propiedades de suelo con kriging ordinario y el variograma ajustado. El poder predictivo de RK se evaluó con el error medio (ME, Ecuación 2) y error cuadrático medio (RMSE, Ecuación 3).

$$ME = \frac{1}{N} \sum_{i=1}^n [z(x_i) - \hat{z}(x_i)] \quad (2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n [z(x_i) - \hat{z}(x_i)]^2} \quad (3)$$

Donde $\hat{z}(x_i)$ es el valor estimado, $z(x_i)$ es el valor conocido y N es el tamaño de la muestra (Kravchenko y Bullock, 1999).

RESULTADOS Y DISCUSIÓN

Estadística Descriptiva

El Cuadro 1 muestra la estadística descriptiva de las propiedades de suelos. Las variables de conductividad eléctrica y cationes solubles muestran un coeficiente de variación mayor a 100%. Por lo contrario, el pH y nitrógeno total, presentaron coeficiente de variación menores a 50%. Las variables de suelo que presentaron coeficientes de variación mayores a 100%, se debe a la alta heterogeneidad de sus valores. Por ejemplo, existen suelos con conductividades eléctricas menores a 1 dS m⁻¹, y otros mayores a 30 dS m⁻¹. La alta conductividad de los suelos se debe a cuestiones naturales y antrópicas (Silva-García, Ochoa, Cristóbal y Estrada, 2006). La primera causa corresponde a suelos que se encuentran en una zona geotérmica conocida como Los Negritos, que está localizada en la parte media de la ciénega de Chapala. La segunda provocada porque algunos de los suelos son regados con aguas de pozos profundos, cuya salinidad varía de 1 dS m⁻¹ a 4.5 dS m⁻¹, lo cual ocasiona que estos suelos se degraden por los procesos de salinización (Silva, Rodríguez, Ochoa y López, 2002). El coeficiente de variación del pH fue menor a 5%, lo cual se debe a la génesis del suelo (Arnalds *et al.*, 2011). Los suelos son originados por sedimentos lacustres, y estos provinieron esencialmente de materiales ricos en bases como las rocas ígneas extrusivas básicas (basaltos), que proporcionan la característica de alcalinidad (Krasilnikov *et al.*, 2013).

Cuadro 1. Estadística descriptiva de las variables de suelo de la Ciénega de Chapala.
Table 1. Descriptive statistics of soil variables of the Ciénega de Chapala.

Variable	Mínimo	Máximo	Media	DS	CV	Sesgo	Curtosis
pH	6.60	9.00	7.89	0.34	4.33	-0.50	5.57
CE (dS m ⁻¹)	0.22	30.30	1.24	4.42	355.40	5.99	38.38
C _a CO ₃ (%)	0.15	21.00	8.30	5.83	70.26	0.02	-1.16
CO (%)	0.15	2.55	0.90	0.63	70.31	1.53	1.39
N (%)	0.01	0.19	0.08	0.03	41.45	0.17	1.96
P (cmol L ⁻¹)	3.73	69.84	9.89	9.62	97.28	4.94	30.29
Na (cmol L ⁻¹)	9.87	10831.55	328.89	1543.39	469.28	6.49	44.22
K (cmol L ⁻¹)	3.01	87.05	9.49	12.29	129.51	5.18	31.88
Ca (cmol L ⁻¹)	0.50	627.00	57.52	126.96	220.72	3.95	14.49
Mg (cmol L ⁻¹)	5.50	1060.00	33.26	147.59	443.79	6.88	48.49

DS = desviación estándar; CV = coeficiente de variación; CE = conductividad eléctrica; CO = carbono orgánico.
 SD = standard deviation; CV = coefficient of variation; EC = electrical conductivity; OC = organic carbon.

Definición de Efectos Aleatorios

Los primeros cinco componentes principales (PC) representan más de 81% de los datos originales. Las variables de conductividad eléctrica, nitrógeno total, carbono orgánico, fósforo y potasio se encuentran más correlacionadas para los primeros cinco PC respectivamente (Cuadro 2). Debido a las características que tienen los componentes principales, no correlacionados y se ponderan en orden de importancia. Se pueden emplear para análisis posteriores como datos de entrada, ya sea para modelos de nicho ecológico o análisis clúster. Sin perder en forma significativa información de todas las variables originales, pero generando modelos más parsimoniosos o disminuir la dimensión de los datos para análisis posteriores. Porque al menos con cuatro PC se puede representar más 78% de la varianza acumulada (Anaya-Flores, Cruz, Silva, Ochoa y Álvarez, 2018; Cadena, Vázquez, Cruz y Villaseñor, 2019).

Los primeros cinco PC se emplearon en el análisis clúster. Las 297 muestras de suelos se agruparon en cinco clústers (Figura 2). Los clústers con el mayor y menor número de observaciones (muestras de suelos) es el 2 y 5, con 96 y 15 respectivamente.

Ajuste de Semivariogramas

Los coeficientes de determinación de los MLM de N, CE, CO y pH son de 0.62, 0.63, 0.22 y 0.28 respectivamente. Los residuales de estos modelos se emplearon para ajustar el semivariograma experimental con los modelos teóricos. Los modelos teóricos con un mejor ajuste fueron esférico, lineal, exponencial y lineal para N, CE, CO y pH respectivamente (Figura 3). Un buen ajuste del semivariograma experimental con los modelos teóricos depende de varios factores como el tamaño de muestra, diseño de muestreo, la distancia entre pares de puntos (lag), entre otros. En el presente estudio, el tamaño de muestra fue de 297 puntos y el diseño sistemático, lo cual garantiza un semivariograma confiable, además, el lag no influyó por el tipo de muestreo (Oliver y Webster, 2014). Lo anterior asegura que se puedan formar un número similar de pares de puntos en toda el área y obtener menor error en el modelo ajustado (Mahdi, Abuzaid y Atta, 2020). En diversos estudios los semivariogramas de nitrógeno, conductividad eléctrica, carbono orgánico y pH del suelo, se han ajustado

Cuadro 2. Resumen del análisis de componentes principales (cinco componentes principales de 10) de las variables de suelo de la ciénega de Chapala.**Table 2. Summary of the principal components analysis (five principal components out of 10) of the soil variables of the cienega de Chapala.**

	PC1	PC2	PC3	PC4	PC5
Importancia de los componentes					
Desviación estándar	1.837	1.425	1.007	0.947	0.885
Proporción de la varianza	0.337	0.203	0.101	0.090	0.078
Proporción acumulativa	0.337	0.541	0.642	0.732	0.810
Valores de carga					
pH	0.104	0.443	0.322	0.248	-0.288
CE (dS m ⁻¹)	-0.488	0.18	-	-0.165	0.169
C _a CO ₃ (%)	0.102	0.503	-	-0.282	-0.411
CO (%)	-	-0.132	0.94	-	0.141
N (%)	0.101	0.546	-	-0.113	-
P (cmol L ⁻¹)	-0.134	-0.365	-	-0.571	-0.636
Na (cmol L ⁻¹)	-0.428	0.109	-	0.39	-0.27
K (cmol L ⁻¹)	-0.37	-0.137	-	0.481	-0.347
Ca (cmol L ⁻¹)	-0.417	0.164	-	-0.27	0.299
Mg (cmol L ⁻¹)	-0.467	0.11	-	-0.191	0.108

PC= Componente principal; CE= conductividad eléctrica; CO= carbono orgánico.
 PC = Principal component; EC = electrical conductivity; OC = organic carbon.

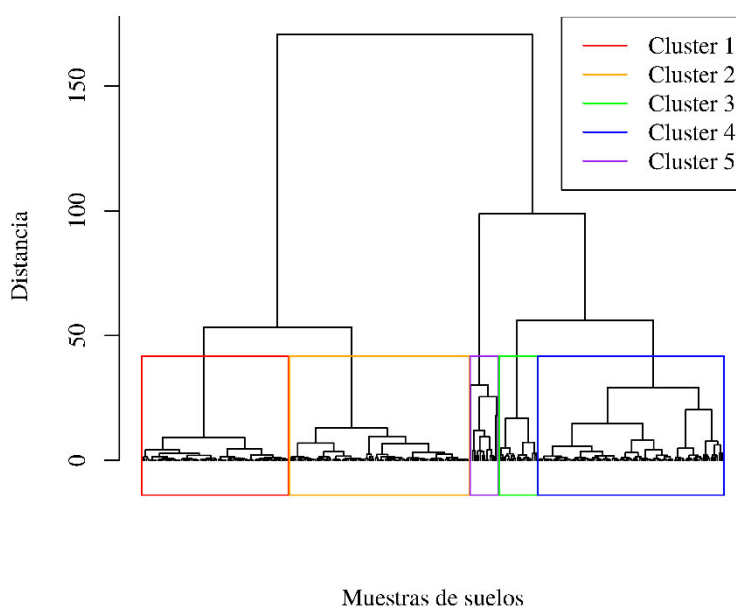


Figura 2. Dendrograma del análisis clúster jerárquico para los primeros cinco componentes principales y 297 muestras de suelos.

Figure 2. Hierarchical cluster analysis dendrogram for the first five principal components and 297 soil samples.

con el modelo exponencial (Hengl, Heuvelink y Stein, 2004; Sun, Whelan, Minasny y McBratney, 2012b; Bilgili, 2013; Hengl *et al.*, 2015); pero en el presente estudio solo fue el carbono orgánico. Esto se debe a que el modelo exponencial es más consistente para el ajuste, cuando la distancia máxima de separación entre pares de puntos es de $\frac{1}{2}$ aproximadamente 18 000 m (Figura 3c) y con un diseño de muestreo sistemático (Jin y Kelly, 2017).

Predicción Espacial

En términos generales se obtuvo buena predicción de las cuatro propiedades del suelo con RK (Cuadro 3; Anexo 2), porque se utilizó la versión modificada (con efectos aleatorios) y se obtuvo mejor desempeño (Keskin y Grundwald, 2018). Los valores de RMSE son menores a 1 para las variables de nitrógeno total, carbono orgánico y pH, coincidiendo lo reportado en otros estudios (Sun *et al.*, 2012a; Hengl *et al.*, 2015). Sin embargo, la conductividad eléctrica mostró RMSE mayor a 4, esto se relaciona con el coeficiente de variación, a medida que aumenta 355, (Cuadro 1) la precisión de RK disminuye (Keskin y Grundwald, 2018). Lo cual podría deberse a que no existe buena correlación entre los valores observados de la variable y los factores del SCORPAN, y que las variaciones de la conductividad eléctrica no son capturadas

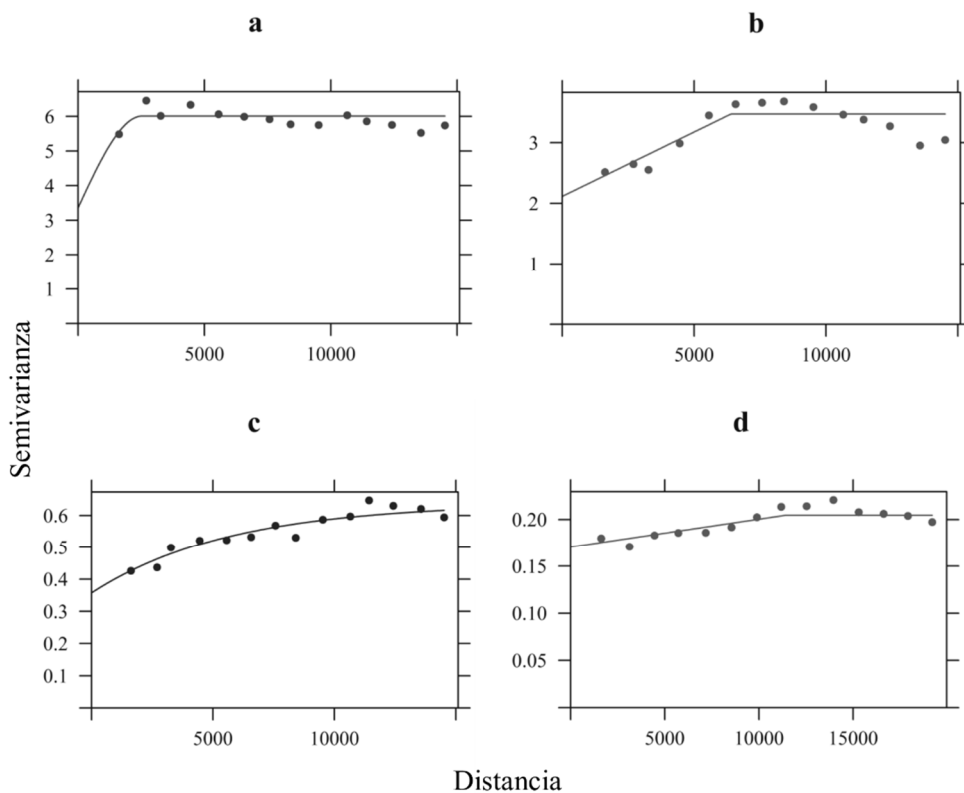


Figura 3. Semivariogramas ajustados de las cuatro propiedades de suelos. a) Nitrógeno (%); b) conductividad eléctrica (dS m^{-1}); c) carbono orgánico (%); d) pH. Distancia en m; nitrógeno ajustado con modelo esférico; conductividad eléctrica y pH ajustados con modelo lineal; carbono orgánico ajustado con modelo exponencial.

Figure 3. Fitted semivariograms of the four soil properties. a) Nitrogen (%); b) electrical conductivity (dS m^{-1}); c) organic carbon (%); d) pH. Distance in meters; nitrogen fitted with spherical model; electrical conductivity and pH adjusted with a linear model; organic carbon fitted with exponential model.

Cuadro 3. Evaluación de la predicción espacial con regresión-kriging.
Table 3. Evaluation of spatial prediction with regression-kriging.

Variable	EM	RMSE
N (%)	0.021	0.048
CE (dS m ⁻¹)	0.151	4.012
CO (%)	-0.422	0.842
pH	0.122	0.411

CE = conductividad eléctrica; CO = carbono orgánico; ME = error medio; RMSE = error cuadrático medio.
 EC = electrical conductivity; OC = organic carbon; ME = mean error; RMSE = root mean square error.

por los residuales del modelo (Eldeiry y Garcia, 2010; Sun *et al.*, 2012b). Además, la relación entre la conductividad eléctrica y los factores del SCORPAN podría ser no lineal como se establece con el MLM empleado, para mejorar el desempeño de RK se pueden utilizar otros modelos (Sun, Yang, Wang y Wu, 2019). Por ejemplo, con árboles de regresión, bosques aleatorios, máquinas de soporte vectorial y redes neuronales artificiales, la precisión de la predicción aumentó hasta en 20% (Dash, Panigrahi y Mishra, 2022).

La mayor superficie de los suelos muestra contenido de nitrógeno total de 0.05% a 0.10%, principalmente hacia el norte del área de estudio. La conductividad eléctrica en general es menor a 1 dS m⁻¹; sin embargo, una superficie importante presenta conductividades de 2.1 a 4 dS m⁻¹. Por otra parte, más de 50% de la superficie tiene contenido de carbono orgánico de 0.5% a 1.5%. Aproximadamente 100% de los suelos del área de estudio tienen pH de 7.4 a 8.5 (Figura 4).

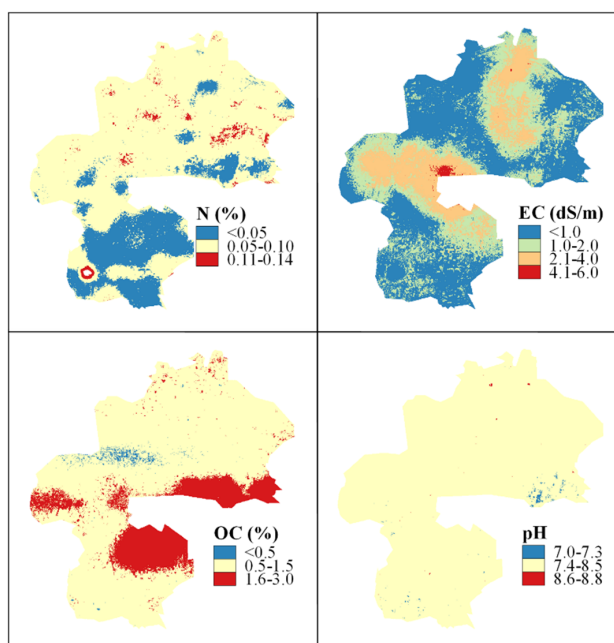


Figura 4. Predicción espacial con regresión-kriging de las cuatro propiedades de suelos. a) Nitrógeno; b) conductividad eléctrica; c) carbono orgánico; d) pH.
Figure 4. Spatial prediction with regression-kriging of the four soil properties. a) Nitrogen; b) electrical conductivity; c) organic carbon; d) pH.

En función de la NOM-021-SEMARNAT-2000 (SEMARNAT, 2002) el contenido de nitrógeno total de los suelos se considera como de bajo a muy bajo (< 0.15%). Al menos 30% de los suelos presentan problemas de salinidad debido a que su conductividad eléctrica es mayor de 1.1 dS m⁻¹. Los contenidos de carbono orgánico se consideran de medios a altos (> 0.6%). Los suelos tienen pH medianamente alcalino.

CONCLUSIONES

El uso de regresión-kriging y datos de sensores remotos para la cartografía digital de suelos generó mapas de precisión aceptable de manera general. Los factores que pueden afectar en el desempeño de regresión-kriging es el ajuste del semivariograma experimental con modelos teóricos, y la relación de los factores del SCORPAN con las propiedades de suelo estudiadas para la predicción espacial. El ajuste del semivariograma experimental fue el adecuado porque cuenta con el número suficiente de puntos de muestreo (297) y el diseño fue sistemático, lo que garantiza semivariogramas consistentes. Se pueden emplear otros modelos predictivos como los de aprendizaje automatizado cuando la propiedad de suelo de interés y los factores del SCORPAN no tengan relación lineal.

DECLARACIÓN DE ÉTICA

No aplicable.

CONSENTIMIENTO PARA PUBLICACIÓN

No aplicable.

DISPONIBILIDAD DE DATOS

Contactar autor para correspondencia.

CONFLICTO DE INTERESES

Los autores declaran que no tienen intereses en competencia.

FONDOS

No aplicable

CONTRIBUCIÓN DE LOS AUTORES

Conceptualización: G.C.C. y F.E.G. Metodología: G.C.C. Investigación: F.E.G. y S.O.E. Escritura: Preparación del borrador original: G.C.C. y J.T.S. Escritura: Revisión y edición: G.C.C., J.T.S. y S.O.E.

AGRADECIMIENTOS

No aplicable

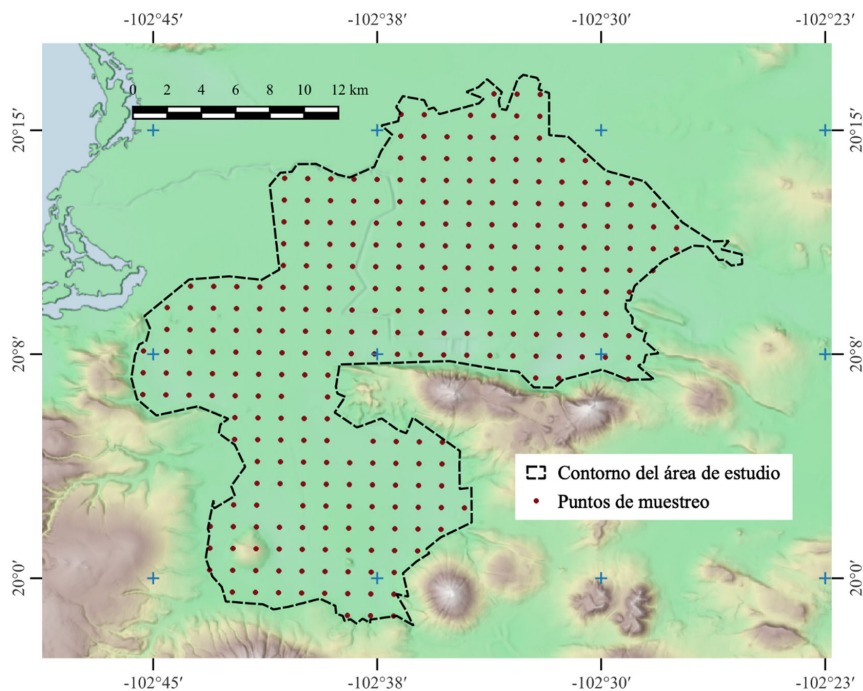
LITERATURA CITADA

Allouche, O., Steinitz, O., Rotem, D., Rosenfeld, A., & Kadmon, R. (2008). Incorporating distance constraints into species distribution models. *Journal of Applied Ecology*, 45(2), 599-609. <https://doi.org/10.1111/j.1365-2664.2007.01445.x>

- Anaya-Flores, R., Cruz-Cárdenas, G., Silva, J. T., Ochoa-Estrada, S., & Álvarez-Bernal, D. (2018). Space-time modeling of the electrical conductivity of soil in a geothermal zone. *Communications in Soil Science and Plant Analysis*, 49(9), 1107-1118. <https://doi.org/10.1080/00103624.2018.1448862>
- Arnalds, O., Beinroth, F. H., Bell, J. C., Bockheim, J. G., Boettinger, J. L., Collins, M. E., ... Wilding, L. P. (2011). Classification of soils. In: P. M. Huang, Y. Li, M. E. Sumner (Eds.). *Handbook of Soil Sciences Properties and Processes* (33-1 pp.). Boca Ratón, FL, USA: CRC Press.
- Bilgili, A. V. (2013). Spatial assessment of soil salinity in the Harran Plain using multiple kriging techniques. *Environmental Monitoring and Assessment*, 185(1), 777-795.
- Cadena-Rodríguez, Y. J., Vázquez-Sánchez, M., Cruz-Cárdenas, G., & Villaseñor, J. L. (2019). Use of ecological niche models of plant species to optimize placement of apiaries. *Journal of Apicultural Science*, 63(2), 243-265. <http://doi.org/10.2478/jas-2019-0017>
- Dash, P. K., Panigrahi, N., & Mishra, A. (2022). Identifying opportunities to improve digital soil mapping in India: A systematic review. *Geoderma Regional*, 28, e00478. <https://doi.org/10.1016/j.geodrs.2021.e00478>
- Dominati, E., Patterson, M., & Mackay, A. (2010). A framework for classifying and quantifying the natural capital and ecosystem services of soils. *Ecological Economics*, 69(9), 1858-1868. <https://doi.org/10.1016/j.ecolecon.2010.05.002>
- Eldeiry, A. A., & Garcia, L. A. (2010). Comparison of ordinary kriging, regression kriging, and cokriging techniques to estimate soil salinity using LANDSAT images. *Journal of Irrigation and Drainage Engineering*, 136(6), 355-364. [https://doi.org/10.1061/\(ASCE\)IR.1943-4774.0000208](https://doi.org/10.1061/(ASCE)IR.1943-4774.0000208)
- Ge, Y., Thomasson, J. A., Sui, r., & Wooten, j. (2011). Regression-kriging for characterizing soils with remote sensing data. *Frontiers of Earth Science*, 5(3), 239-244. <https://link.springer.com/article/10.1007/s11707-011-0174-1>
- Grunwald, S. (2006). *Environmental soil-landscape modeling: Geographic information technologies and pedometrics* (504 pp.). New York: CRC Press.
- Grunwald, S. (2009). Multi-criteria characterization of recent digital soil mapping and modeling approaches. *Geoderma*, 152(3-4), 195-207. <https://doi.org/10.1016/j.geoderma.2009.06.003>
- Hengl, T. (2007a). *A practical guide to geostatistical mapping of environmental variables*. Ispra, Varese, Italy: European Commission-Joint Research Centre- Institute for Environment and Sustainability. ISBN: 978-92-79-06904-8
- Hengl, T., Heuvelink, G. B. M., Kempen, B., Leenaars, J. G. B., Walsh, M. G., Shepherd, K. D., ... Tondoh, J. E. (2015). Mapping soil properties of Africa at 250 m resolution: Random forests significantly improve current predictions. *PLoS One*, 10(6), e0125814. <https://doi.org/10.1371/journal.pone.0125814>
- Hengl, T., Heuvelink, G. B. M., & Rossiter, D. G. (2007b). About regression-kriging: From equations to case studies. *Computers & Geosciences*, 33(10), 1301-1315. <https://doi.org/10.1016/j.cageo.2007.05.001>
- Hengl, T., Heuvelink, G. B. M., & Stein, A. (2004). A generic framework for spatial prediction of soil variables based on regression-kriging. *Geoderma*, 120(1-2), 75-93. <https://doi.org/10.1016/j.geoderma.2003.08.018>
- Hengl, T., Sierdsema, H., Radović, A., & Dilo, A. (2009). Spatial prediction of species' distributions from occurrence-only records: combining point pattern analysis, ENFA and regression-kriging. *Ecological Modelling*, 220(24), 3499-3511. <https://doi.org/10.1016/j.ecolmodel.2009.06.038>
- Heuvelink, G. (2003). The definition of pedometrics. *Pedometron*, 15, 1-15.
- Jin, R., & Kelly, G. E. (2017). A comparison of sampling grids, cut-off distance and type of residuals in parametric variogram estimation. *Communications in Statistics-Simulation and Computation*, 46(3), 1781-1795. <https://doi.org/10.1080/03610918.2015.1011785>
- Keskin, H., & Grunwald, S. (2018). Regression kriging as a workhorse in the digital soil mapper's toolbox. *Geoderma*, 326, 22-41. <https://doi.org/10.1016/j.geoderma.2018.04.004>
- Krasilnikov, P., Gutiérrez-Castorena, M. C., Ahrens, R. J., Cruz-Gaistardo, C. O., Sedov, S., & Solleiro-Rebolledo, E. (2013). *The soils of Mexico*. Netherlands: Springer. <https://doi.org/10.1007/978-94-007-5660-1>
- Kravchenko, A., & Bullock, D. G. (1999). A comparative study of interpolation methods for mapping soil properties. *Agronomy Journal*, 91(3), 393-400. <https://doi.org/10.2134/agronj1999.0002196200910030007x>
- Loeza-Lara, P. D., Ramírez-Sánchez, R. D., & Reyes-Téllez, M. A. (2015). La Ciénaga de Chapala, Michoacán: cambios y permanencias en la construcción regional. *Relaciones. Estudios de Historia y Sociedad*, 36(142), 237-259.
- Mahdi, E., Abuzaid, A. H., & Atta, A. (2020). Empirical variogram for achieving the best valid variogram. *Communications for Statistical Applications and Methods*, 27(5), 547-568. <https://doi.org/10.29220/CSAM.2020.27.5.547>
- McBratney, A. B., Santos, M. M., & Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117(1-2), 3-52. [https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4)
- Miller, J., Franklin, J., & Aspinall, R. (2007). Incorporating spatial dependence in predictive vegetation models. *Ecological Modelling*, 202(3-4), 225-242. <https://doi.org/10.1016/j.ecolmodel.2006.12.012>
- Mulder, V. L., De Bruin, S., Schaepman, M. E., & Mayr, T. R. (2011). The use of remote sensing in soil and terrain mapping-A review. *Geoderma*, 162(1-2), 1-19. <https://doi.org/10.1016/j.geoderma.2010.12.018>

- Oliver, M. A., & Webster, R. (2014). A tutorial guide to geostatistics: Computing and modelling variograms and kriging. *Catena*, 113, 56-69. <https://doi.org/10.1016/j.catena.2013.09.006>
- Omuto, C. T., & Vargas, R. R. (2015). Re-tooling of regression kriging in R for improved digital mapping of soil properties. *Geosciences Journal*, 19(1), 157-165. <https://link.springer.com/article/10.1007/s12303-014-0023-9>
- Rossiter, D. G. (2018). Past, present & future of information technology in pedometrics. *Geoderma*, 324, 131-137. <https://doi.org/10.1016/j.geoderma.2018.03.009>
- SEMARNAT (Secretaría de Medio Ambiente y Recursos Naturales). (2002). Norma Oficial Mexicana NOM 021-SEMARNAT-2000 antes NOM-021-RECNAT-2000. Que establece las especificaciones de fertilidad, salinidad y clasificación de suelos. Estudios, muestreo y análisis. *Diario Oficial de la Federación*. D.F.: SEGOB.
- Silva-García, J. T., Ochoa-Estrada, S., Cristóbal-Acevedo, D., & Estrada-Godoy, F. (2006). Calidad química del agua subterránea de la Ciénega de Chapala como factor de degradación del suelo. *Terra Latinoamericana*, 24(4), 503-513.
- Silva-García, J., Castillo-Rodríguez, R., Ochoa-Estrada, S., & López-Díaz, S. (2002). Lake Chapala and the Ciénega aquifer: Chemical evidence of hydraulic communication. *Geofísica Internacional*, 41(1), 63-73.
- Sun, W., Minasny, B., & McBratney, A. B. (2012a). Analysis and prediction of soil properties using local regression-kriging. *Geoderma*, 171, 16-23. <https://doi.org/10.1016/j.geoderma.2011.02.010>
- Sun, W., Whelan, B. M., Minasny, B., & McBratney, A. B. (2012b). Evaluation of a local regression kriging approach for mapping apparent electrical conductivity of soil (ECa) at high resolution. *Journal of Plant Nutrition and Soil Science*, 175(2), 212-220. <https://doi.org/10.1002/jpln.201100005>
- Sun, X. L., Yang, Q., Wang, H. L., & Wu, Y. J. (2019). Can regression determination, nugget-to-sill ratio and sampling spacing determine relative performance of regression kriging over ordinary kriging? *Catena*, 181, 104092. <https://doi.org/10.1016/j.catena.2019.104092>
- Thompson, J. A., Roecker, S., Grunwald, S., & Owens, P. R. (2012). Digital Soil Mapping: Interactions with and Applications for Hydropedology. In: H. Lin (Ed.). *Hydropedology Synergistic Integration of Soil Science and Hydrology* (pp. 665-709). London: Academic Press.
- Van Reeuwijk, L. P. (2002). *Procedures for soil analysis*. Wageningen, The Netherlands: International Soil Reference and Information Centre-FAO.

ANEXO 1. Puntos de muestreo de suelos.
ANNEX 1. Soil sampling points.



ANEXO 2. Valores observados contra estimados de las cuatro propiedades de suelos.
ANNEX 2. Observed values against estimates of the four soil properties.

