

PREDICCIÓN DE CONTENIDO DE ARCILLA SUPERFICIAL UTILIZANDO CONDUCTIVIDAD ELÉCTRICA APARENTE Y ESQUEMAS DE MUESTREO BASADOS EN MODELOS

MAURICIO CASTRO-FRANCO*¹; HERNÁN JULIO DÍAZ²; MAURICIO QUIROZ LONDOÑO³; PABLO CICCORE⁴ & JOSÉ LUIS COSTA⁴

Recibido: 26-03-16

Recibido con revisiones: 17-11-16

Aceptado: 17-11-16

RESUMEN

La predicción espacial del contenido de arcillas (As) a escala de lote es requerida para la implementación de agricultura de precisión y modelos de simulación hidrológica. Sin embargo, la brecha de técnicas de cartografía que permitan establecer la heterogeneidad de As limita la capacidad para determinar su variabilidad. En este estudio, se utilizó cokriging ordinario, conductividad eléctrica aparente (CEa) como variable auxiliar y dos esquemas de muestreo basados en modelos (EBM) (Hipercubo latino condicionado (HCL) y fuzzy c-medias (FCM)) para predecir contenido de As superficial en un lote agrícola experimental de 25,18 ha. Los resultados soportan los supuestos que HCL y FCM capturan adecuadamente la distribución total de la CEa; y que As está cerradamente relacionado con CEa en condiciones del sudeste bonaerense. A partir de los resultados se determinó que (i) el tipo de EBM afecta la eficiencia de la interpolación para predecir As; (ii) una reducción considerable de muestras es posible cuando se aplica la metodología propuesta, logrando mapas precisos de As ($R^2 > 0,69$); (iii), un conjunto de muestras de suelo independiente es lo más adecuado para validar la metodología propuesta; y (iv) la Interpolación espacial a partir de CEa y HCL proporcionó una leve mejora en la predicción espacial de As ($R^2 = 0,78$, $RMSE = 1,50\%$) que interpolación espacial a partir de CEa y FCM ($R^2 = 0,69$, $RMSE = 1,69\%$). La metodología propuesta proporcionó una mejora significativa de información de As en comparación con los costos y el tiempo que demandan las técnicas de cartografía convencional. Además, la metodología propuesta es sencilla de replicar para otros lotes o condiciones edáficas, lo cual puede ser significativo para la implementación de manejo sitio específico de cultivos y para modelos de simulación hidrológica.

Palabras clave. Agricultura de precisión, cartografía digital de suelos, textura del suelo, VERIS 3100®.

PREDICTION OF TOPSOIL CLAY CONTENT USING APPARENT ELECTRICAL CONDUCTIVITY AND MODEL-BASED SAMPLING SCHEMES

ABSTRACT

Spatial prediction of clay content at field scale is needed to implement precision agriculture and hydrological models. However, the lack of techniques that can detect clay content heterogeneity limits the ability to determine its variability. In this study, we tested the use of geostatistical interpolation (ordinary cokriging), apparent electrical conductivity (CEa) as auxiliary information and two model-based soil sampling schemes (EBM) (conditioned Latin hypercube (HCL) and fuzzy K-means (FCM)) to predict clay content in a 25.18 ha agricultural field. Results support the underlying assumptions that both HCL and FCM capture adequately the full distribution of CEa; and that clay content was closely related to the CEa. Also, suggested that (i) the type of EBM affects the clay prediction model efficiency; (ii) a considerable soil sample reduction is possible when the proposed methodology is applied; (iii) an independent data set is most adequate to validate the proposed methodology; and (iv) the geostatistical interpolation based on CEa and HCL provided a slight improvement in the clay content prediction ($R^2 = 0.75$, $RMSE = 1.50\%$) compared to the geostatistical interpolation based on CEa and FCM ($R^2 = 0.73$, $RMSE = 1.69\%$). The proposed methodology provided a significant improvement of information on clay content with respect to soil survey techniques and is easy to replicate in other farm fields. Therefore, it can be significant to implement these findings in site-specific managements or hydrological simulations.

Key words. Digital soil mapping, precision agriculture, soil texture, VERIS 3100®.

1. Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)

2. Facultad de Ciencias Agrarias Universidad Nacional de Mar del Plata

3. Instituto de Geología de Costas y del Cuaternario, Universidad Nacional de Mar del Plata

4. Estación Experimental Agropecuaria INTA Balcarce

* Autor de contacto: agronomao@gmail.com

INTRODUCCIÓN

El contenido de arcilla superficial del suelo (As) es un factor clave para determinar la productividad del suelo debido a su efecto sobre propiedades geoeléctricas e hidrológicas (De Benedetto *et al.*, 2012; Piikki *et al.*, 2013). Sin embargo, determinar la distribución espacial de esta propiedad edáfica a escala de lote, mediante métodos convencionales de cartografía de suelos, suele ser costoso en tiempo y dinero. Por lo tanto, métodos innovadores, precisos, rápidos y económicos que permitan generar mapas de As a escala de lote, son requeridos para aumentar la eficiencia de implementación de prácticas de agricultura de precisión y de los modelos hidrológicos (Triantafilis & Lesch, 2005).

En las últimas décadas, el interés por determinar la distribución espacial de As a través de sensores de suelo basados en la medición de conductividad eléctrica aparente (CEa), ha crecido notoriamente (De Benedetto *et al.*, 2012; Rossel *et al.*, 2010b; Triantafilis & Lesch, 2005). A diferencia de los métodos convencionales de cartografía de suelos, el uso de sensores de CEa es más eficiente en trabajo, costo, usabilidad y precisión para la predicción de varias propiedades del suelo, a escala de lote (Corwin & Plant, 2005; Johnson *et al.*, 2001). Específicamente, CEa permite optimizar los esquemas de muestreo de suelo y el proceso de delimitación de zonas para manejo sitio específico (Castro Franco *et al.*, 2015; Kitchen *et al.*, 2005; Peralta *et al.*, 2013; Simón *et al.*, 2013). Generalmente, cuando se usan sensores de CEa, una menor cantidad de muestras de suelo es requerida para predecir propiedades del suelo a escala de lote. Cuando se dispone de mediciones de CEa, la estrategia para determinar un adecuado esquema de muestreo de suelos, en términos de localización y cantidad de muestras, es fundamental para generar modelos con buenas posibilidades de generalización, especialmente cuando tales modelos son calibrados para zonas con suelos tan complejos a escala de lote, *e.g.* sudeste de la provincia de Buenos Aires, Argentina (Amiotti *et al.*, 2001).

A pesar de que la CEa tiene un alto potencial para predecir As a escala de lote, la investigación tanto de esquemas eficientes de muestreo de suelos, como de la adecuada calibración de la cantidad y localización de muestras, ha sido escasa (Castro Franco *et al.*, 2015). En principio, la cantidad óptima de muestras y su localización, puede variar en función de la pedodiversidad y de la precisión de la escala a la cual se quiera generar información de suelos (Ramírez-López *et al.*, 2014). Por lo tanto, métodos numéricos que permitan identificar la cantidad óptima de muestreo y su respectiva

localización, podrían ser muy relevantes para la aplicación práctica de la CEa en la predicción espacial de As a escala de lote agrícola.

Existen numerosos algoritmos para determinar esquemas de muestreo basados en modelos (EBM) (Rossel *et al.*, 2010a). Sin embargo, varios estudios han determinado que Hipercubo Latino Condicionado (HCL) (Minasny y McBratney, 2006) y Fuzzy *c*-medias (De Gruijter *et al.*, 2010) (FCM) son EBM que han sido eficientes para capturar los patrones espaciales de propiedades del suelo a escala de lote, a partir de la disponibilidad de fuentes de información auxiliar del suelo tales como CEa (Castro Franco *et al.*, 2015; Schmidt *et al.*, 2014). Tanto HCL, como FCM se caracterizan por tener en cuenta la distribución multivariada de predictores y por determinar la localización de las muestras de acuerdo a su cantidad. No obstante, las aplicaciones de HCL y FCM para predecir As a escala de lote y a partir de la CEa, han sido escasas (Castro Franco *et al.*, 2015; Rad *et al.*, 2014).

En este contexto, los objetivos de este trabajo fueron: (i) analizar el rol de la cantidad y localización de muestras seleccionadas a partir de los esquemas de muestreos HCL y FCM, en la eficiencia de la representación de la distribución de CEa; y (ii), proponer una metodología para identificar el esquema de muestreo adecuado para la predicción espacial de As, a partir de la medición de CEa. Esta investigación documenta un caso de estudio de la aplicación de técnicas de cartografía digital de suelos y discute una metodología práctica para mejorar la predicción de As a través de sensores del suelo y EBM.

MATERIALES Y MÉTODOS

Lote experimental

El lote experimental se encuentra localizado en el partido de Balcarce (*Lat*: -37.6067; *Long*: -58.6355; *Datum*: WGS84). Este lote se caracteriza por tener la variabilidad típica de elevación y ambientes edafoclimáticos, característicos de la zona agrícola del sudeste de la provincia de Buenos Aires, Argentina. Toda el área del lote (25,18 ha) se encuentra sobre las unidades cartográficas de suelos MP11 y MP24. La primera está conformada en un 60% por la serie Mar del Plata (Argjudol Típico) y un 40% por la serie Balcarce (Argjudol Petrocálcico), mientras que la segunda está conformada en un 70% por la serie Mar del Plata y en 30% por la serie Tres esquinas (Argjudol Típico) (Soil Survey Staff, 2014).

Las rotaciones típicas en el lote experimental incluyen soja, maíz y girasol en verano y trigo en invierno. El clima es templado y el patrón de precipitación es isohigro. El promedio anual de

precipitación es 910 mm con una concentración durante octubre y marzo (>60%). La temperatura media anual es de 14 °C (Pascale & Damario, 2004). El régimen de humedad del suelo es údico.

Descripción del método de predicción

El método de predicción de As se desarrolló en cinco pasos (Fig. 1).

Paso 1. Medición de conductividad eléctrica aparente (CEa) y procesamiento de datos

La CEa fue medida de 0-30 cm (CEa_30cm) y 0-90cm (CEa_90cm) de profundidad, utilizando el equipo VERIS 3100® (Veris Technologies, Salina, KS, USA).

La Figura 2 muestra la distribución espacial de las mediciones de CEa y un esquema descriptivo de funcionamiento del VERIS 3100®. Este sensor mide la CEa_30cm y CEa_90cm de manera georreferenciada y puede ser fácilmente trasladado mediante una camioneta pick-up o tractor. Su funcionamiento tiene como base un conjunto de seis electrodos en forma de disco y ordenados de acuerdo a una matriz tipo Wenner (Rhoades, 1993). VERIS 3100® incluye todos los com-

ponentes necesario para medir CEa, excepto el vehículo que lo traslada y el navegador GPS. Generalmente, no requiere una calibración previa para su funcionamiento. Además, es robusto y de fácil uso. Información adicional sobre el funcionamiento del VERIS 3100®, está descrita por Corwin & Lesch (2003).

Variogramas experimentales fueron calculados y modelados para todos los datos de CEa_30cm y la CEa_90cm. Para esto se utilizó la siguiente ecuación (Diggle & Ribeiro, 2007):

$$\hat{\gamma}(h) = \frac{1}{2 N(h)} \sum_{\alpha=1}^{N(h)} [z(\mathbf{U}_{\alpha}) - z(\mathbf{U}_{\alpha} + \mathbf{h})]^2 \quad (1)$$

donde $\hat{\gamma}(h)$ es el valor de semivarianza a un intervalo de distancia h , $z(\mathbf{U}_{\alpha})$ es el valor de la muestra a partir de todos los puntos de \mathbf{U}_{α} y $N(h)$ es el número de pares de datos dentro de una clase dada de distancia y dirección.

El variograma experimental muestra la reducción en correlación espacial entre dos puntos cuando la distancia entre estos se incrementa (Oliver, 2010). Después de verificar los supuestos geoestadísticos, el modelo de variograma experimental seleccionado y ajustado fue utilizado para interpolar

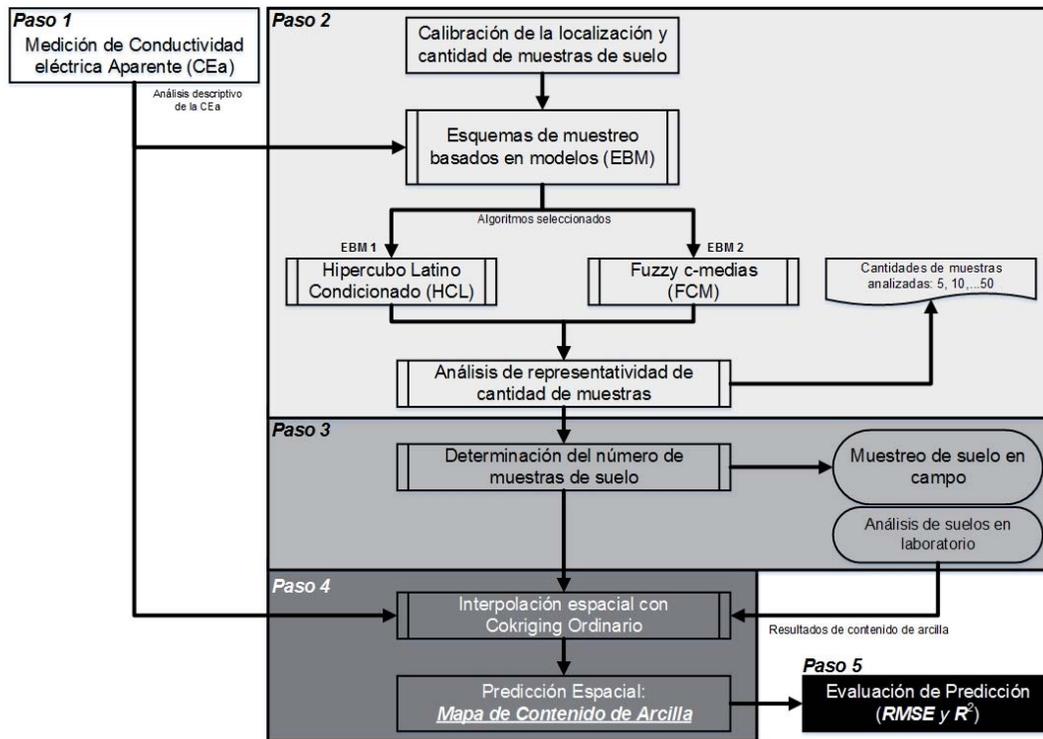


Figura 1. Descripción-esquema del proceso de predicción de contenido de arcilla (As).

Figure 1. Procedure description for clay content prediction (As).

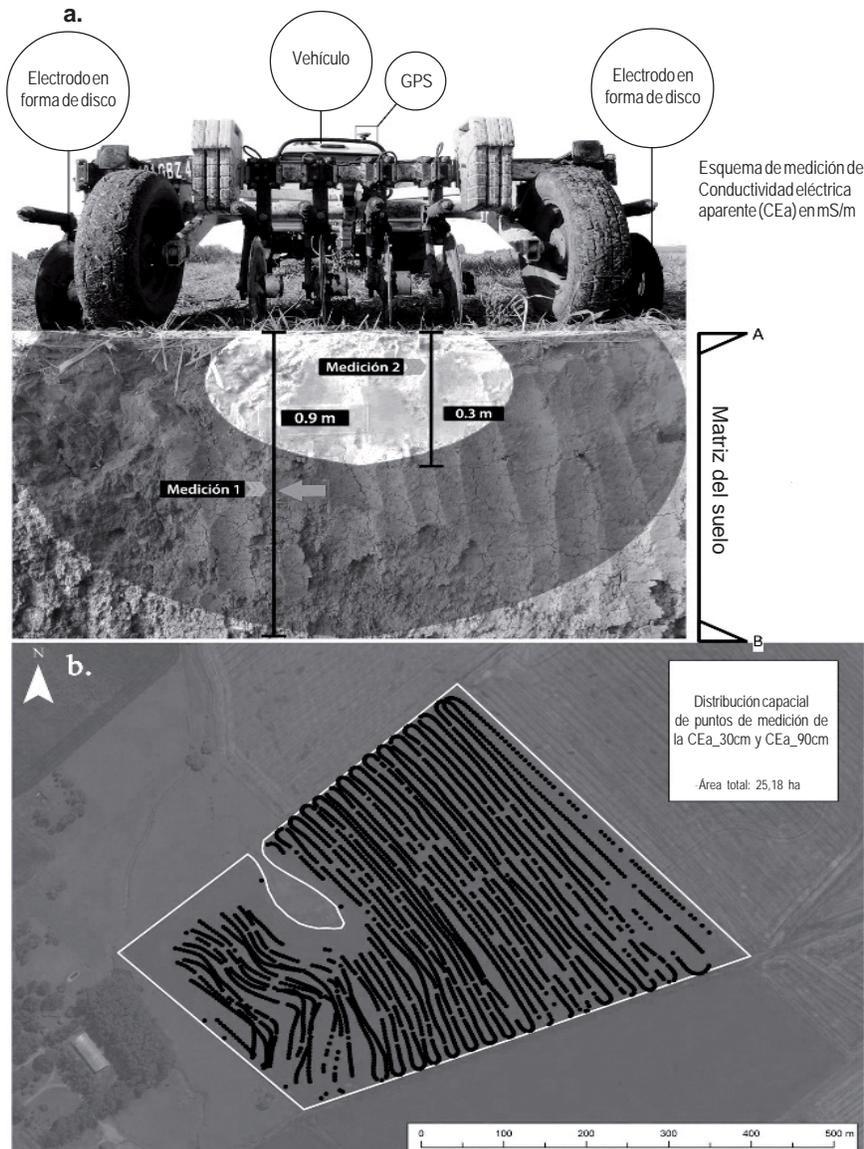


Figura 2. Esquema de funcionamiento del VERIS 3100® (a) y esquema de la distribución espacial de la medición de la conductividad eléctrica aparente (CEa) dentro del área del lote experimental (b).

Figure 2. Functioning description of VERIS 3100® (a) and spatial distribution for ECa measurements in the experimental field (b).

CEa_30cm y CEa_90cm a través de kriging ordinario. La interpolación geoestadística fue realizada utilizando el paquete "geoR" del software R v3.2.3 (R Development Core Team, 2016). Finalmente, todos los archivos de salida se configuraron como raster (grilla regular) de 10 x 10 m, debido a que este tamaño refleja la escala de variabilidad asociada con escala de lote (Corwin & Lesch, 2005).

Paso 2. Calibración de la localización y cantidad de muestras

HCL y FCM fueron los algoritmos utilizados para determinar la localización de muestras de calibración, dentro del lote experimental.

HCL es un algoritmo que de manera aleatoria y estratificada determina la localización de puntos de muestreo basado en la distribución espacial de la CEa_30cm y CEa_90cm (Castro Franco *et al.*, 2015). HCL intenta localizar un conjunto de muestras a partir de la CEa_30cm y la CEa_90cm, que cumplan con los requerimientos de un hipercubo latino, los cuales son que una misma muestra exista tanto en una colum-

na como en una fila en n dimensiones (Minasny & McBratney, 2010). El hipercubo latino es construido por muestreo aleatorio a partir de la distribución acumulada de CEa_30cm y CEa_90cm, utilizando un enfoque de optimización compacta. Es decir, busca aquellas muestras que representen de la mejor manera la distribución de todos los predictores. Adicionalmente, también se focaliza en preservar la correlación entre los predictores en el conjunto de muestras seleccionadas (Ramirez-Lopez *et al.*, 2014). El algoritmo de HCL se ejecutó utilizando el paquete "clhs" del software R v3.2.3 (R Development Core Team, 2016).

La ejecución del algoritmo FCM se basa en el procedimiento de agrupamiento o clúster c-medias (De Grujter *et al.*, 2010). FCM elabora particiones de muestreo a partir de todo el conjunto de muestras y calcula la probabilidad de que cada muestra seleccionada pertenezca a un grupo o clúster. Lo que se espera es que las muestras que sean seleccionadas para el mismo clúster tengan características similares y que las muestras de diferentes clúster tengan características diferentes. En la selección de muestras, las ubicaciones son el equivalente a los centróides de los clúster fuzzy c-medias logrados a partir de la discretización de la distribución espacial de CEa_30cm y CEa_90cm. El número de muestras que se requieren es igual al número de clúster que se generan. FCM fue ejecutado utilizando el paquete "e1071" del software R v3.2.3 (R Development Core Team, 2016)

El rol de la cantidad de muestras en la eficiencia de representación CEa, se evaluó utilizando un grupo de 5, 10, 15, 20, ..., 50 muestras obtenidas a partir de HCL y FCM. La media (\bar{x}) y varianza muestral (s^2) de los valores correspondientes de CEa_30 cm y CEa_90 cm de cada grupo de muestras, fueron comparados con la media (μ) y varianza poblacional (σ^2) de los valores correspondientes a todos los puntos de medición de la CEa_30cm y CEa_90cm. La cantidad de muestras que se seleccionó tanto para HCL, como para FCM, fue aquella con menor diferencia absoluta entre varianzas ($|s^2 - \sigma^2|$) y medias ($|\mu - \bar{x}|$) de CEa_30cm y CEa_90cm.

Por último, 26 muestras de suelo adicionales fueron tomadas de manera espacialmente aleatoria, con el objetivo de formar un conjunto de muestras para validación independiente de la metodología de predicción propuesta. Para este procedimiento, se utilizó el complemento *Soil sampling tool*, del programa QGIS v.2.14.1.

Paso 3. Muestreo y análisis de suelos

Una vez que se determinó la localización y cantidad de puntos de muestreo utilizando HCL y FCM, una muestra de suelo fue recolectada por cada punto. La muestra de suelo compuesta fue el producto de mezclar 3 submuestras recolectadas dentro de un radio de 5 m con referencia a cada punto georreferenciado. La profundidad de muestreo fue de 0-30 cm. Esta profundidad es la comúnmente utilizada en el sudeste bona-

rense por cartógrafos, científicos y productores en muestreos de suelos intensivos, para evaluar la variabilidad espacial de la fertilidad del suelo a escala de campo (Castro Franco *et al.*, 2015). Las muestras se llevaron al laboratorio de suelos del Instituto Nacional de Tecnología Agropecuaria, Estación Experimental Balcarce. Allí, la textura de cada muestra de suelo fue determinada mediante el método de la pipeta de Robinson (Robinson, 1922).

Paso 4. Interpolación espacial de contenido de arcilla (As)

Interpolación geoestadística mediante cokriging ordinario fue utilizada para generar un mapa de As a 30 cm de profundidad. cokriging ordinario es un método de interpolación geoestadística que permite incorporar variables de información auxiliar (Wang *et al.*, 2013). La aplicación más común de cokriging ordinario es cuando la variable auxiliar ha sido intensamente medida y esta medición ha sido rápida, económica y precisa e.g. CEa. Normalmente, cokriging ordinario determina la correogionalización entre dos variables. Cuando esta correogionalización existe, entonces es factible utilizar las variables de información auxiliar para mejorar las predicciones de la variable objetivo (Pang *et al.*, 2009).

Específicamente, cokriging ordinario fue utilizado para predecir As en toda la superficie del lote, a partir de CEa_30cm y CEa_90cm como variables auxiliares y la cantidad de muestras de suelo determinada con HCL, FCM y todas las muestras recolectadas en ambos EBM. La predicción fue calculada como:

$$\bar{Z}_u(X_0) = \sum_{i=1}^N \lambda_{u,i}^u Z_u(X_i) + \sum_{i=1}^P \lambda_{v,i}^u Z_v(X_i), \tag{2}$$

donde $\bar{Z}_u(X_0)$ es el valor estimado de As en la ubicación X_0 ; Los valores de $\lambda_{u,i}^u$ y $\lambda_{v,i}^u$ son las ponderaciones de cokriging ordinario; $Z_u(X_i)$ y $Z_v(X_i)$ son los valores de As obtenidos en el laboratorio y los valores de la variable auxiliar, respectivamente; N y P es la cantidad de valores medidos de $Z_u(X_i)$ y $Z_v(X_i)$ utilizados en la estimación de la ubicación X_0 , respectivamente.

Paso 5. Evaluación de la precisión del mapa de As

La precisión del mapa de As fue evaluado utilizando una comparación de valores predichos de As mediante la interpolación geoestadística (cokriging ordinario) y los valores medidos de As en los puntos de muestreo del conjunto de muestras para validación. La raíz media del cuadrado del error (RMSE), error medio (ME) y el coeficiente de determinación (R^2) entre

valores predichos y medidos de As fueron utilizados para verificar la precisión global de la predicción. RMSE fue calculado como:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2} \quad (3)$$

donde X_i es el valor observado de As, Y_i es el correspondiente valor predicho de As, y n es el número de muestras. Con el propósito de evaluar si existe desvío en los residuales, ME fue calculado como:

$$ME = \frac{1}{n} \sum_{i=1}^n (X_i - Y_i) \quad (4)$$

Finalmente, R^2 fue calculado como:

$$R^2 = \frac{(\sum_{i=1}^n X_i Y_i - \bar{X} \bar{Y})^2}{(\sum_{i=1}^n X_i^2 - \bar{X}^2)(\sum_{i=1}^n Y_i^2 - \bar{Y}^2)} \quad (5)$$

RESULTADOS Y DISCUSIÓN

Análisis de la estructura espacial de la CEa

La Tabla 1 muestra el resumen de los parámetros de estadística descriptiva de las mediciones de CEa_30cm y CEa_90cm realizadas con el VERIS 3100®.

Los parámetros de estadística descriptiva plantean un patrón espacial complejo de propiedades del suelo. Las diferencias de medias entre CEa_30cm y CEa_90cm pueden deberse a la alta variabilidad de la profundidad del suelo hasta el horizonte petrocálcico y su efecto sobre el contenido de As (Pazos, 1984; Pazos & Mestelan, 2002). Los valores mínimos fueron similares para ambas CEa, mientras que los valores máximos fueron ampliamente mayores para CEa_90cm. Al respecto, varios autores han determinado que valores altos de CEa profunda e.g. CEa_90cm, podrían estar relacionados con presencia y variabilidad vertical de horizontes argílicos dentro del perfil del suelo (Boettinger *et al.*, 1997; Doolittle *et al.*, 1994; Drummond, 1999).

La Tabla 2 muestra una comparación de los parámetros de los modelos de semivariograma entre CEa_30cm y CEa_90cm.

Tabla 1. Parámetros de estadística descriptiva de las mediciones de conductividad eléctrica aparente medida de 0-30 cm (CEa_30 cm) y 0-90 cm (CEa_90 cm) de profundidad, utilizando el equipo VERIS 3100®.

Table 1. Statistical parameters for apparent electrical conductivity measured at 0-30 cm (CEa_30cm) and 0-90 cm (CEa_90 cm) depth, using VERIS 3100®.

Predictor	Unidades	Media	D.E.	Min*	Max†	Mediana	Coeficientes	
							Asimetría‡	Curtosis§
CEa_30 cm	ms m ⁻¹	16,99	3,05	12,40	26,80	16,30	0,91	0,31
CEa_90 cm	ms m ⁻¹	25,25	5,07	14,50	39,80	24,80	0,36	-0,30

* Valor Mínimo; † Valor Máximo; ‡ Coeficiente de Asimetría; § Coeficiente de Curtosis

CEa_30 cm y CEa_90 cm: Conductividad Eléctrica Aparente del suelo de 0 - 30 y 0 - 90 cm de profundidad, respectivamente.

Tabla 2. Parámetros geoestadísticos de los modelos ajustados de variogramas experimentales de las mediciones de conductividad eléctrica aparente medida de 0-30 cm (CEa_30 cm) y 0-90 cm (CEa_90 cm) de profundidad, utilizando el equipo VERIS 3100®.

Table 2. Geostatistical parameters of adjusted models of experimental variograms for apparent electrical conductivity measurements at 0-30 cm (CEa_30 cm) and 0-90 cm (CEa_90 cm) depth, using VERIS 3100®.

Variable	Modelo	C_0 †	$C_0 + C$ ‡	a (m)§
CEa_30 cm	Matérn	0,00	10,80	175,37
CEa_90 cm	Matérn	0,00	24,78	40,17

† Varianza Nugget. ‡ Silla. § Rango.

Los semivariograma teóricos Matérn proporcionaron el mejor ajuste para CEa_30cm y CEa_90cm. Generalmente, las funciones Matérn son útiles para describir la estructura espacial de varias propiedades del suelo, debido a que describen adecuadamente los variogramas experimentales a cortas distancias (Minasny & McBratney, 2005). Su factor de suavizado permite que las estructuras de correlación espacial puedan ser debidamente descritas.

En general, ambas CEa tuvieron una fuerte estructura espacial (relación Nugget Silla⁻¹ < 0,4) (Cambardella *et al.*, 1994). La varianza Nugget para ambas CEa indica una muy baja variación a cortas distancias. Sin embargo, este no era un resultado esperado debido a que por un lado el equipo VERIS suele tener múltiples fuentes de errores de medición y por el otro lado, el horizonte petrocálcico suele tener una alta variabilidad espacial a cortas distancias (Pazos & Meselán, 2002). Debido a eso, es pertinente aclarar que el ajuste adecuado del modelo de semivariograma pudo deberse

más a la fuente de parámetros que tuvo, que a la ausencia de errores por medición o por patrones complejos de variabilidad espacial. Las diferencias entre silla de CEa_30cm y CEa_90cm, indican que la complejidad de los suelos puede ser mayor a profundidades mayores a 30 cm, debido a que altos valores de silla indican gran variabilidad (Oliver, 2010). A partir de esto, se plantea que la presencia de horizontes argílicos a profundidades mayores a 30 cm, pueden tener un efecto de enmascaramiento que suaviza el efecto del horizonte petrocálcico sobre la CEa.

Efecto del esquema de muestreo sobre la determinación de la cantidad de muestras

La Figura 3 muestra el efecto del EBM y cantidad de muestras de suelos sobre la diferencia absoluta entre varianza de la muestra (S^2) y la varianza poblacional (σ^2); y sobre la diferencia absoluta entre la media de la muestra (\bar{X}) y la media poblacional (μ).

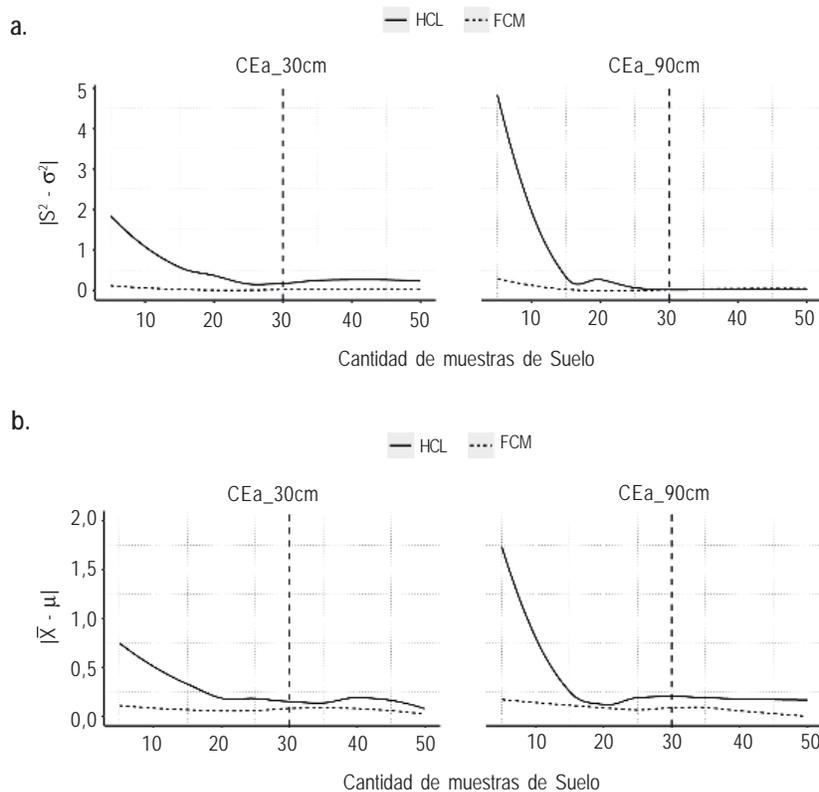


Figura 3. Efecto de la cantidad de muestras y del esquema de muestreo basado en modelos (EBM) sobre (a) la diferencia absoluta entre varianza muestral (S^2) y varianza poblacional (σ^2); (b) la diferencia absoluta entre la media muestral (\bar{X}) y la media poblacional (μ), para CEa_30cm y CEa_90cm y las funciones de densidad de probabilidad de los grupos de cantidad de muestras.

Figure 3. Effect of soil samples number and sampling scheme based on models (SBM) on (a) the absolute difference between sample variance (S^2) and population variance (σ^2); (b) the absolute difference between sample mean (\bar{X}) and population mean (μ), for ECa_30cm and ECa_90cm and probability density functions of number of samples.

La distribución original de CEa_30cm y CEa_90cm se replica mejor a una cantidad mayor a 30 y 10 muestras con HCL y FCM, respectivamente. Por otro lado, la densidad de distribución fue mejor replicada por los grupos de cantidad de muestras relacionados con CEa_30cm (Fig. 3a), ratificando la alta complejidad de los patrones espaciales de estos suelos a profundidades mayores a 30 cm. A partir de estos resultados, se considera que la selección de una cantidad mayor a 30 muestras de suelos es adecuada por dos motivos. Primero a que representa la distribución de la CEa adecuadamente en ambos EBM y segundo a que es una cantidad suficiente de puntos de muestreo para ejecutar cokriging, ya que este algoritmo requiere un mínimo de cantidad de muestras para arrojar valores confiables. Además, a partir de 30 muestras, las diferencias absolutas entre S^2 y σ^2 ($|S^2 - \sigma^2|$) y, \bar{X} y μ ($|\bar{X} - \mu|$) tienen una tendencia a no decrecer.

FCM representó mejor la distribución de la CEa que HCL. Estos resultados fueron contrarios a los reportados por Ramirez-Lopez *et al.* (2014), en condiciones de suelos Ferralsoles, Acrisoles y Cambisoles. Estos autores determinaron que HCL representó mejor que FCM y muestreo tipo Kennard-Stone, la distribución de la CEa y la elevación a escala de lote, con más de 150 muestras. Por lo general, Ferralsoles, Acrisoles y Cambisoles suelen tener perfiles menos heterogéneos hasta el metro de profundidad, en comparación con los Argiudoles petrocálicos (Soil Survey Staff, 2014). Al respecto, Amiotti *et al.* (2001) planteó que la heterogeneidad espacial de los materiales que están sobre el horizonte petrocálico en los suelos Argiudoles petrocálicos, así como las diferencias horizontales y verticales de la textura del suelo, sugieren que los sedimentos fueron depositados durante dos o más periodos eólicos. Ratificando este planteamiento, Dietrich *et al.* (2014) mediante tomografía de resistividad eléctrica, determinaron que los cambios de los patrones espaciales de los suelos del sudeste bonaerense se pueden presentar incluso a distancias menores a 10 m. Esta complejidad, hace que el comportamiento del flujo preferencial del agua dentro del perfil del suelo sea un factor a determinar en la eficiencia de los EBM.

La Figura 4 muestra la interpolación de CEa_30cm y CEa_90cm, junto con la distribución espacial de las 30 muestras de suelo de acuerdo a HCL (Fig. 4a y 4c) y FCM (Fig. 4b y 4d).

Valores altos de As tienden a estar en zonas con altos valores de CEa. La relación directa y positiva entre As y CEa

ha sido ampliamente discutida y justificada (Friedman, 2005). Por su parte, el rango entre valor mínimo y máximo de As fue de 11,05% y 12,95% para HCL y FCM, respectivamente. Ambos rangos ratifican plenamente la justificación de esta investigación. Las diferencias de As pueden tener un enorme efecto sobre propiedades relacionadas con capacidad de almacenamiento de agua y propiedades hidráulicas del suelo (Dietrich *et al.*, 2014); y por ende, sobre la productividad de los cultivos.

La localización de las 30 muestras a partir de FCM, presentan una distribución espacial más uniforme que HCL. Sin embargo, estos resultados sugieren que la homogeneidad de la distribución espacial del muestreo de suelo, no determinan la eficiencia de representación óptima de la distribución simultánea de CEa_30cm y CEa_90cm. Al respecto, Schmidt *et al.* (2014), plantearon que los esquemas de muestreo convencionales e.g. aleatorio, estratificado o sistemático, tienen una eficiencia heterogénea para representar la distribución de las variables auxiliares relacionada con los factores formadores del suelo tales como la CEa, elevación, respuesta espectral, entre otras (McBratney *et al.*, 2003; Minasny & McBratney, 2010). Debido a esto, los EBM tienen como ventaja con respecto a los esquemas convencionales, que permiten para todos los casos, ser más homogéneas en la eficiencia de representación de variables auxiliares, ya que tienen en cuenta cada condición particular en las zonas de muestreo.

Precisión de predicción de As

La Figura 5 muestra la comparación de los resultados de interpolación espacial de As utilizando cokriging ordinario con las 30 muestras obtenidas con HCL (CKO-HCL), cokriging ordinario con las 30 muestras obtenidas con FCM (CKO-FCM) y cokriging con 60 muestras, obtenidas a partir de la integración de los dos grupos de muestras anteriores (CKO-Todas).

Los patrones espaciales de todas las predicciones de As fueron similares entre sí y con CEa, sugiriendo que el patrón espacial de As podría estar relacionado con el patrón espacial de profundidad del suelo hasta el horizonte petrocálico. Como se observa, mayores contenidos de As se encuentran en la zona este y sureste, donde la profundidad efectiva del suelo no es mayor a 90 cm (datos no mostrados). Varios trabajos han descrito la relación entre profundidad del horizonte petrocálico y contenido de As, en condiciones del sudeste bonaerense (Cabria & Culot, 1994;

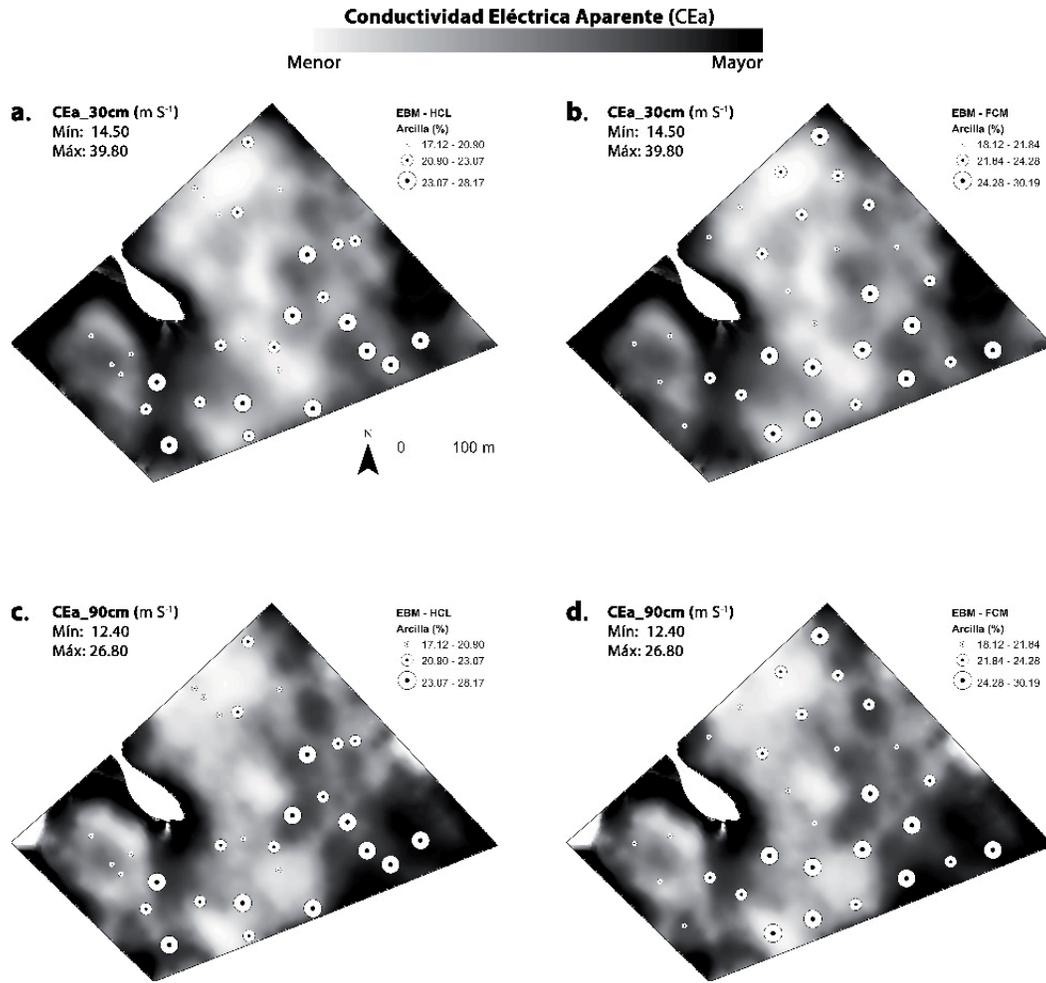


Figura 4. Distribución espacial de los puntos de muestreo a partir de la aplicación del esquema hipercubo latino condicionado (EBM-HCL) (a. y c.) y del esquema fuzzy c-medias (EBM-FCM) (b y d). En el fondo se observa la distribución de la conductividad eléctrica aparente (CEa) de 0-30 cm (CEa_30cm) y/o 0-90 cm (CEa_90cm)

Figure 4. Spatial distribution of soil sampling points based on conditioned Latin Hipercube scheme (SBM-cLH) (a. and c.) and fuzzy k-means scheme (SBM-FCM) (b and d). Distribution of apparent electrical conductivity (ECa) of 0-30 cm (ECa_30 cm) and/or 0-90cm (ECa_90cm) (at the back)

Pazos, 1984). Por lo tanto, es posible ratificar que el patrón vertical de contenido de As es complejo, está determinado por la profundidad efectiva y que determinar los patrones espaciales de CEa.

Complementariamente, la Figura 5 muestra la distribución espacial del conjunto de las 26 muestras de validación y las gráficas de puntos entre contenido de arcilla predicho con cokriging-HCL (Fig. 5d), cokriging-FCM (Fig. 5e), y cokriging-Todas (Fig. 5f), y contenido de arcilla medido en laboratorio para cada una de las 26 muestras para validación.

Cokriging con HCL fue ligeramente mejor para predecir As superficial que cokriging con FCM. Por su parte, EM indica que cokriging fue levemente negativo en todas las predicciones, posiblemente debido a la poca cantidad de valores bajos extremos de As en el conjunto de muestras para validación. Estos resultados ratifican lo reportado por Heil & Schmidhalter (2012), quienes determinaron que la eficiencia de cokriging para predecir los patrones espacial de As, utilizando CEa como variable auxiliar, se debe a que se aprovecha eficientemente la correlación sólida y consistente que tiene As con CEa. El aumento de la cantidad

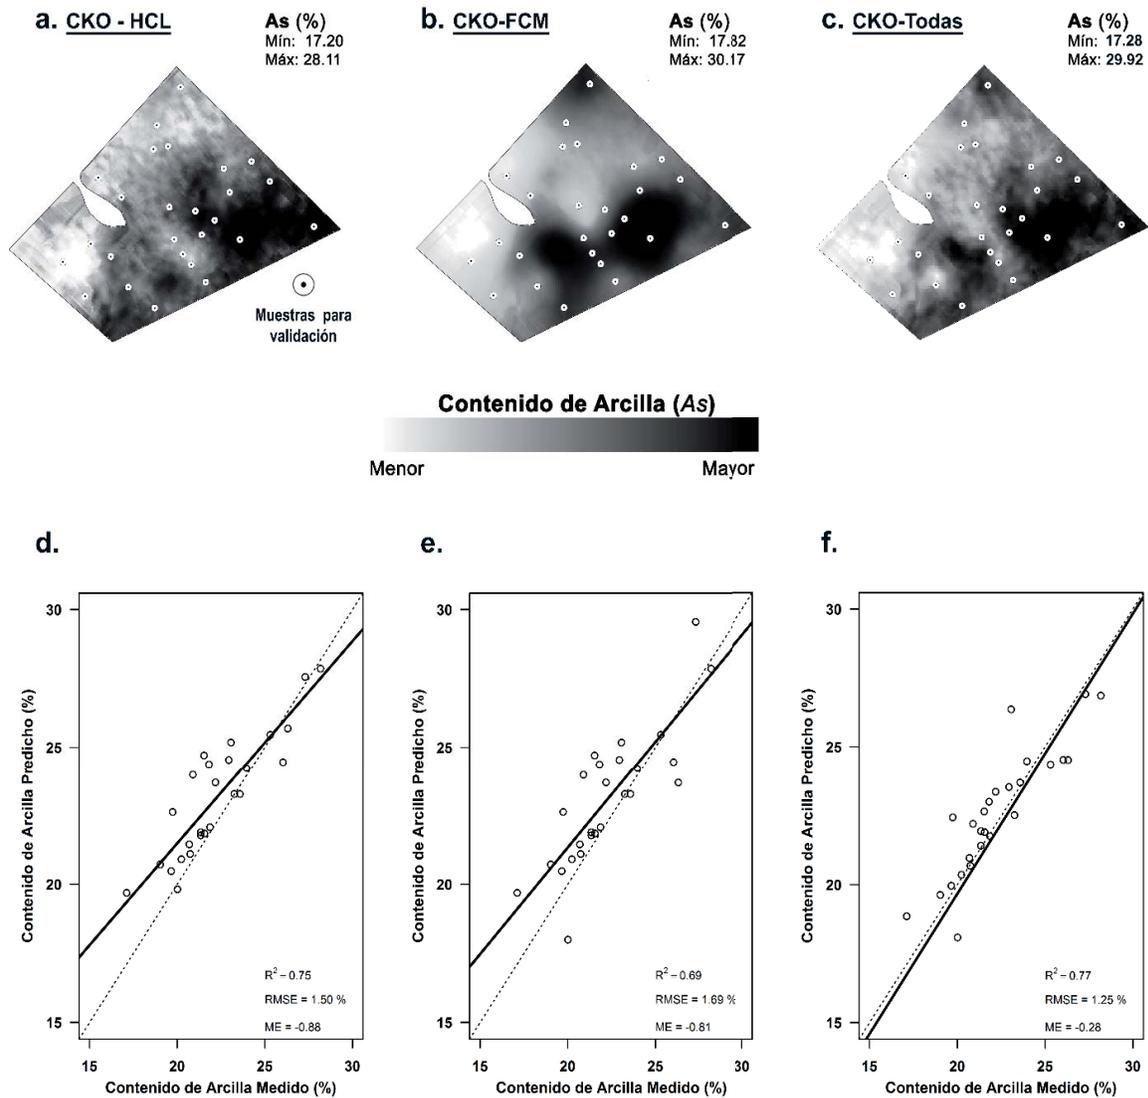


Figura 5. Distribución espacial de las muestras de suelos para validación y de la predicción espacial de contenido de As a través de la interpolación con cokriging ordinario y el esquema hipercubo latino condicionado (CKO-HCL) (a), cokriging ordinario y fuzzy c-medias (CKO-FCM) (b) y cokriging ordinario con todas las muestras de ambos esquemas (CKO-Todas) (c). Abajo se observa la figura de dispersión de valores entre contenido de arcilla (As) medido versus As predicho para cada interpolación, respectivamente (d,e y f)

Figure 5. Spatial distribution of soil sampling for validation and spatial prediction for clay content based on ordinary cokriging interpolation and conditioned Latin Hipercube scheme (OCK-cLH) (a), ordinary cokriging and fuzzy k-means (OCK-FKM) (b) and ordinary cokriging with all samples for both schemes (OCK-all) (c). Dispersion values of clay content observed (As) versus As predicted for each interpolation, respectively (d,e and f) (down)

de muestra permitió mejorar la predicción de contenido de As. Sin embargo, este mejoramiento implicó doblar la cantidad de muestras de muestreo, lo cual no se justifica en términos de conveniencia económica y de análisis de muestras.

CONCLUSIONES

Una metodología precisa, rápida y económica para determinar la variabilidad espacial de As a escala de lote, fue propuesta en este trabajo. Esta metodología se basa en el uso de cokriging ordinario, CEa como variable auxiliar y

EBM para seleccionar la cantidad y localización de puntos de muestreo para predecir As superficial. Para ajustar la metodología, primero se analizó el rol de la cantidad y localización de muestras seleccionadas a partir de dos EBM (HCL y FCM), en la eficiencia de la representación de la distribución espacial de CEa. Después, se propuso y aplicó una metodología para identificar el esquema de muestreo adecuado para predecir As. Finalmente, se realizó una evaluación de la eficiencia de predicción espacial de As, a partir de cokriging.

En el contexto de los resultados, se validó la utilidad de los EBM como técnica adecuada para determinar la cantidad y localización de muestras en condiciones del sudeste bonaerense. Además, los resultados soportan el supuesto de que HCL y FCM, replican eficientemente la distribución y el patrón espacial de la CEa, la cual confirmó ser una variable auxiliar idónea para predecir As, en condiciones del sudeste bonaerense.

A partir de los resultados se concluye que la eficiencia de predicción de As utilizando cokriging y CEa como variable auxiliar, depende considerablemente del esquema de muestreo que se utilice. Específicamente, la combinación cokriging con HCL proporcionó una mejora leve con respecto a la combinación cokriging con FCM, para predecir As a escala de lote. Ambos EBM, permitieron reducir considerablemente la cantidad de muestras necesarias para realizar una eficiente predicción de contenido de As superficial. Teniendo en cuenta que tanto la combinación de cokriging con HCL como con FCM, son sencillos y fáciles de replicar para otros lotes agrícolas, esto puede ser un avance considerable para la implementación de manejo sitio específico o para la calibración y validación de modelos de simulación hidrológicos. Sin embargo, se sugiere en futuros trabajos evaluar otros algoritmos de regresión y fuentes de información auxiliar.

AGRADECIMIENTOS

Este trabajo fue financiado por el proyecto específico de INTA Nro. 1124023. Los autores también agradecen a la Ing. Agr. Mag. Marisa Domenech de la CEI Barrow, por su asesoría y colaboración.

BIBLIOGRAFÍA

- Amiotti, N; M del C. Blanco & LF Sanchez. 2001. Complex pedogenesis related to differential aeolian sedimentation in microenvironments of the southern part of the semiarid region of Argentina. *Catena* 43: 137-156.
- Boettinger, JL; JA Doolittle; NE West; EW Bork & EW Schupp. 1997. Nondestructive assessment of rangeland soil depth to petrocalcic horizon using electromagnetic induction. *Arid. Soil. Res. Rehab* 11: 375-390.
- Cabria, F & JP Culot. 1994. Selección y utilización de características edáficas para discriminar series de Argiudoles en el sudeste bonaerense. *Ciencia del suelo* 12: 41-45.
- Cambardella, CA; TB Moorman; TB Parkin; DL Karlen; JM Novak; RF Turco & AE Konopka. 1994. Field-Scale Variability of Soil Properties in Central Iowa Soils. *Soil Sci. Soc. Am. J.* 58: 1501-1511.
- Castro Franco, M; JL Costa; N Peralta & V Aparicio. 2015. Prediction of Soil Properties at Farm Scale Using a Model-Based Soil Sampling Scheme and Random Forest. *Soil Sci.* 180: 1-12.
- Corwin, DL & SM Lesch. 2003. Application of Soil Electrical Conductivity to Precision Agriculture: Theory, Principles, and Guidelines. *Agron. J.* 95: 455-471.
- Corwin, DL & SM Lesch. 2005. Characterizing soil spatial variability with apparent soil electrical conductivity: I. Survey protocols. *Comput. Electron. Agric.* 46: 103-133.
- Corwin, DL & RE Plant. 2005. Applications of apparent soil electrical conductivity in precision agriculture. *Comput. Electron. Agric.* 46: 1-10.
- De Benedetto, D; A Castrignano; D Sollitto; F Modugno; G Buttafuoco & G lo Papa. 2012. Integrating geophysical and geostatistical techniques to map the spatial variation of clay. *Geoderma* 171: 53-63.
- De Gruijter, J; A McBratney & J Taylor. 2010. Sampling for high-resolution soil mapping. *In: Proximal Soil Sensing*, Springer. 3-14 p.
- Dietrich, S; PA Weinzettel & M Varni. 2014. Infiltration and drainage analysis in a heterogeneous soil by electrical resistivity tomography. *Soil Sci. Soc. Am. J.* 78: 1153-1167.
- Diggle, PJ & PJ Ribeiro. 2007. Model based Geostatistics. Springer Series in Statistics, New York. 232 pp.
- Doolittle, JA; KA Sudduth; NR Kitchen & SJ Indorante. 1994. Estimating depths to claypans using electromagnetic induction methods. *J. Soil Water Conserv.* 49: 572-575.
- Drummond, ST. 1999. Soil Conductivity Sensing on Claypan Soils: Comparison of Electromagnetic Induction and Direct Methods. *In: Precision Agriculture*, American Society of Agronomy, Crop Science Society of America, Soil Science Society of America, Madison, WI.p.
- Friedman, SP. 2005. Soil properties influencing apparent electrical conductivity: a review. *Comput. Electron. Agric.* 46: 45-70.
- Heil, K & U Schmidhalter. 2012. Characterisation of soil texture variability using the apparent soil electrical conductivity at a highly variable site. *Comput. Geosci.* 39: 98-110.
- Johnson, CK; JW Doran; HR Duke; BJ Wienhold; KM Eskridge & JF Shanahan. 2001. Field-Scale Electrical Conductivity Mapping for Delineating Soil Condition. *Soil Sci. Soc. Am. J.* 65: 1829-1837.
- Kitchen, NR; KA Sudduth; DB Myers; ST Drummond & SY Hong. 2005. Delineating productivity zones on claypan soil fields using apparent soil electrical conductivity. *Comput. Electron. Agric.* 46: 285-308.
- McBratney, AB; ML Mendonça Santos & B Minasny. 2003. On digital soil mapping. *Geoderma* 117: 3-52.

- Minasny, B & AB McBratney. 2005. The Matérn function as a general model for soil variograms. *Geoderma* 128: 192-207.
- Minasny, B & AB McBratney. 2006. A conditioned Latin hypercube method for sampling in the presence of ancillary information. *Comput. Geosci.* 32: 1378-1388.
- Minasny, B & AB McBratney. 2010. Conditioned Latin Hypercube Sampling for Calibrating Soil Sensor Data to Soil Properties. *In: Proximal Soil Sensing*, Springer Netherlands. 111-119 p.
- Oliver, MA. 2010. *Geostatistical Applications for Precision Agriculture*. Springer, United Kingdom. 337 pp.
- Pang, S; T-x Li; Y-d Wang; H-y Yu & X Li. 2009. Spatial Interpolation and Sample Size Optimization for Soil Copper (Cu) Investigation in Cropland Soil at County Scale Using Cokriging. *Agr Sci China* 8: 1369-1377.
- Pascale, AJ & EA Damario. 2004. *Bioclimatología agrícola y agroclimatología* Editorial Facultad de Agronomía. Universidad de Buenos Aires, Buenos Aires, Argentina. 550 pp.
- Pazos, M. 1984. Relación arcilla lluvia/arcilla total en Molisoles del sudeste de la provincia de Buenos Aires. *Ciencia del suelo* 2: 131-136.
- Pazos, MS & SA Mestelan. 2002. Variability of Depth to Tosca in Udolls and Soil Classification, Buenos Aires Province, Argentina. *Soil Sci. Soc. Am. J.* 66: 1256-1264.
- Peralta, NR; JL Costa; M Balzarini & H Angelini. 2013. Delineation of management zones with measurements of soil apparent electrical conductivity in the southeastern pampas. *Can. J. Soil Sci.* 93: 205-218.
- Piikki, K; M Söderström & B Stenberg. 2013. Sensor data fusion for topsoil clay mapping. *Geoderma* 199: 106-116.
- R Development Core Team: A language and Environment for Statistical Computing. Vienna, Austria. Programa computacional.
- Rad MRP; N Toomanian; F Khormali; CW Brungard; CB Komaki & P Bogaert. 2014. Updating soil survey maps using random forest and conditioned Latin hypercube sampling in the loess derived soils of northern Iran. *Geoderma* 232: 97-106.
- Ramirez-Lopez, L; K Schmidt; T Behrens, B van Wesemael, JA Demattè & T Scholten. 2014. Sampling optimal calibration sets in soil infrared spectroscopy. *Geoderma* 226: 140-150.
- Rhoades, JD. 1993. Electrical Conductivity Methods for Measuring and Mapping Soil Salinity. *In: Advances in Agronomy*, Academic Press. 201-251 p.
- Robinson, GW. 1922. A new method for the mechanical analysis of soils and other dispersions. *J. Agric. Sci.* 12: 306-321.
- Rossel, RAV; AB McBratney & B Minasny. 2010a. *Proximal Soil Sensing* Springer, London-New York. 448 pp.
- Rossel, RAV; NJ McKenzie & MJ Grundy. 2010b. Using Proximal Soil Sensors for Digital Soil Mapping. *In: Digital Soil Mapping*, Springer Netherlands. 79-92 p.
- Schmidt, K; T Behrens; J Daumann; L Ramirez-Lopez; U Werban; P Dietrich & T Scholten. 2014. A comparison of calibration sampling schemes at the field scale. *Geoderma* 232: 243-256.
- Simón, M; N Peralta & JL Costa. 2013. Relación entre la conductividad eléctrica aparente con propiedades del suelo y nutrientes. *Ciencia del suelo* 31: 45-55.
- Soil Survey Staff. 2014. *Keys to Soil Taxonomy*, 12th ed. United States Department of Agriculture - Natural Resources Conservation Service, Washington, DC. 343 pp.
- Triantafyllis, J & SM Lesch. 2005. Mapping clay content variation using electromagnetic induction techniques. *Comput. Electron. Agric.* 46: 203-237.
- Wang, K; C Zhang & W Li. 2013. Predictive mapping of soil total nitrogen at a regional scale: A comparison between geographically weighted regression and cokriging. *Appl. Geogr.* 42: 73-85.