



**FCA**  
Facultad de Ciencias  
Agropecuarias

**INFORME**

---

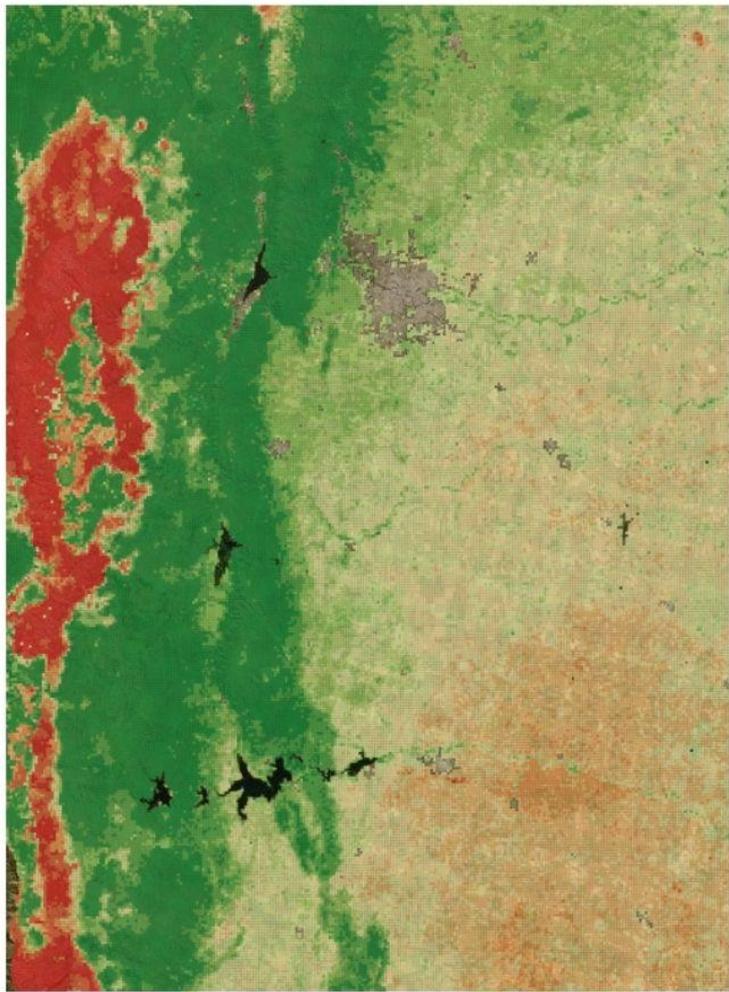
# **MAPEO DE PROPIEDADES DE SUELO**

---

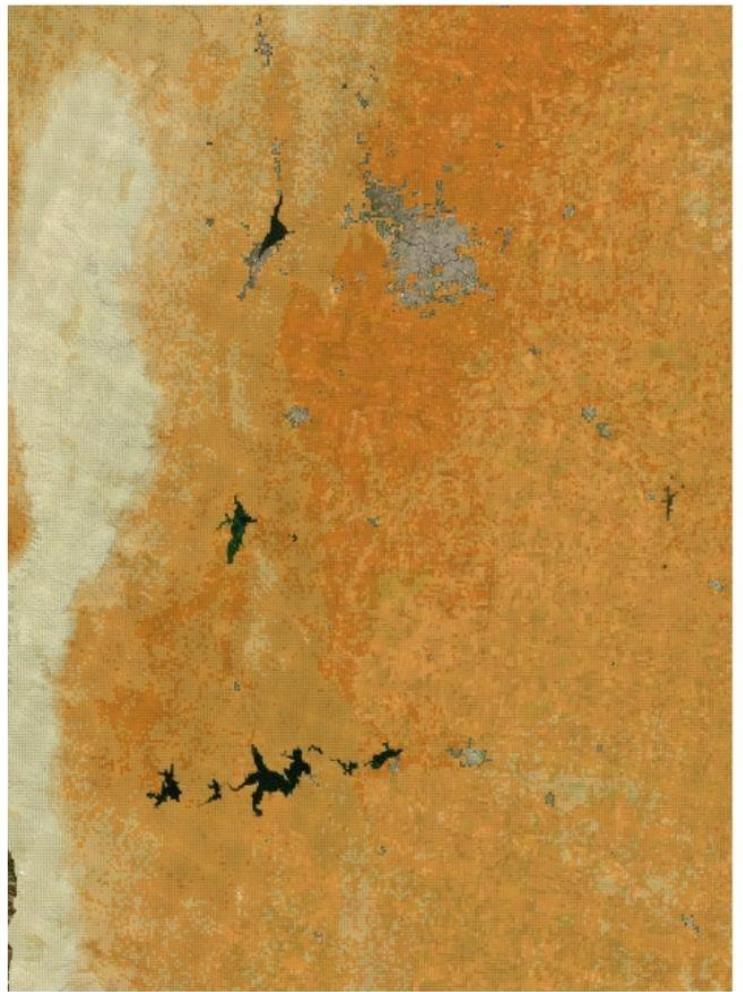
**MATERIA ORGÁNICA,  
FÓSFORO, pH y  
GRANULOMETRÍA  
EN LA PROVINCIA DE  
CÓRDOBA**

**NOVIEMBRE 2021**

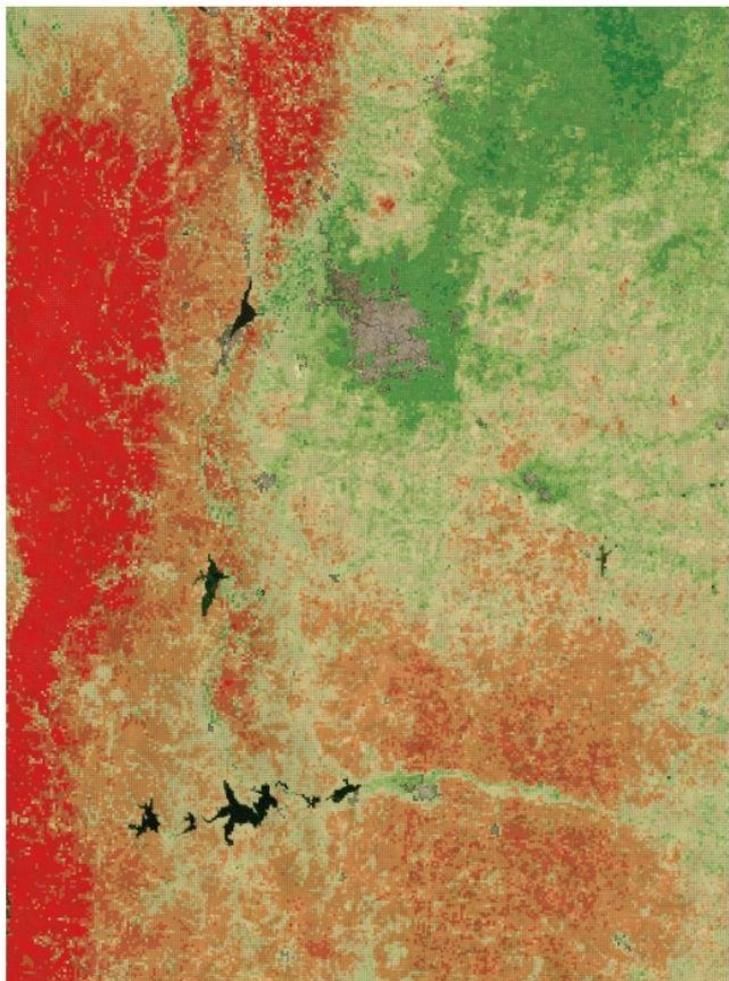
**IDECOR - INFRAESTRUCTURA DE DATOS ESPACIALES  
GOBIERNO DE LA PROVINCIA DE CÓRDOBA**



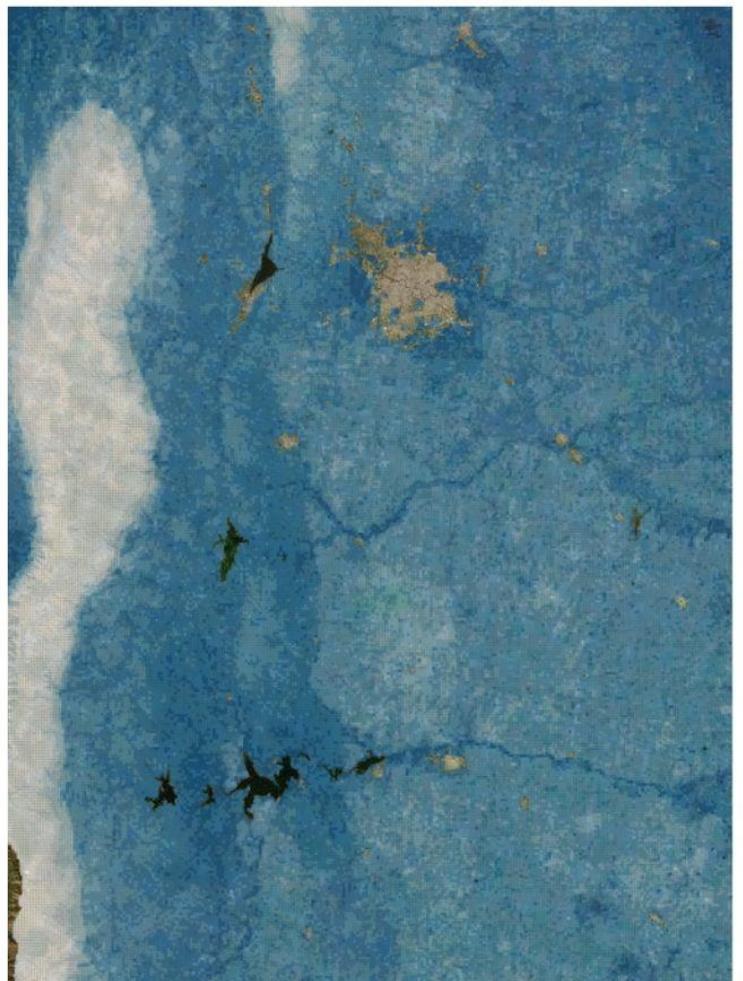
Materia Orgánica



Arcilla



Fósforo



pH

# Organismos participantes y equipo de trabajo

## Desarrollo, covariables, apoyo científico e infraestructura tecnológica

IDECOR (Infraestructura de Datos Espaciales de la Provincia de Córdoba) en convenio con CONICET.

## Equipo de trabajo

- Mariano Córdoba, Investigador Asistente UFYMA CONICET-INTA, FCA-UNC (responsable técnico).
- Catalina Bozzer, IDECOR, UNRC, asistencia técnica, desarrollo de datos y covariables.
- Carolina Álvarez, INTA Manfredi, asistencia técnica.
- Hernán Morales y Ezequiel Pozzi, desarrollo de datos y covariables, IDECOR.
- Juan Pablo Carranza y Federico Monzani, apoyo metodológico, IDECOR.
- Mario Piumetto, Coordinador IDECOR.

## Instituciones/participantes que dieron seguimiento al proceso y aportaron datos para el estudio

- Instituto Nacional de Tecnología Agropecuaria (Juan Cruz Molina, Carolina Álvarez, Lautaro Faule).
- Secretaría de Agricultura de la Provincia de Córdoba (Marcos Blanda, Paula Veliz).
- Facultad de Agronomía y Veterinaria, Universidad Nacional de Río Cuarto (Catalina Bozzer, Marcos Bongiovanni).
- Facultad de Ciencias Agropecuarias, Universidad Nacional de Córdoba (Susana Hang).
- Instituto Multidisciplinario de Biología Vegetal - IMBIV CONICET (Esteban Kowaljow).
- Servicios Tecnológicos AGD S.A. (Sebastián Storti, Mariano Granatelli).
- RAVIT (Esteban Tronfi).
- Orbely (Franco Vizzio).
- Seiker (Manuel Reynoso).

## Versión y Licencia

Esta es la Versión 1, 10 de noviembre del 2021.

MAPEO DE PROPIEDADES DE SUELO EN LA PROVINCIA DE CÓRDOBA, 2021. Está distribuido bajo una Licencia Creative Commons Atribución 4.0 Internacional. Libre para compartir, distribuir, copiar y adaptar.



Citar como: Córdoba M., Bozzer C., Morales H., Álvarez C., Carranza J., Monzani F. Mapeo de Propiedades de Suelo en la Provincia de Córdoba, 2021. Infraestructura de Datos Espaciales de Córdoba (IDECOR), noviembre de 2021.

### Aviso de uso

Los datos desarrollados en el marco del presente trabajo son parte del trabajo de mapeo de variables de suelo, desarrollado por IDECOR con el apoyo de CONICET, para la realización de estudios territoriales e inmobiliarios en particular. No obstante, las características técnicas de los resultados obtenidos posibilitan otros usos científicos y técnicos, quedando éstos a criterio y responsabilidad de los usuarios.

Los mapas se diseñaron para servir como herramienta cartográfica a escala regional y provincial; no fueron creados con objetivos específicos y/o para trabajos que demanden escalas y detalles mayores.

El equipo técnico se desliga de cualquier uso indebido que pueda realizarse de los mapas y datos desarrollados fuera del ámbito para el cual fueron diseñados y/o sus características técnicas posibilitan, quedando estos otros usos bajo responsabilidad de los usuarios.

## Contenido

1. Antecedentes.....	6
2. Alcance de los productos .....	7
3. Datos.....	7
4. Metodología .....	12
4.1. Covariables .....	12
4.2. Modelación .....	14
5. Resultados.....	15
6. Referencias Bibliográficas.....	24

## 1. Antecedentes

En 2015, el Centro de Transferencia Terra de la Facultad de Ciencias Agropecuarias de la Universidad Nacional de Córdoba (FCA-UNC), presentó el libro Suelos de Córdoba, resultado de tres años de trabajo en que se tomaron 354 muestras a lo largo de 20.000 km de la provincia de Córdoba. Mediante el empleo de estas muestras, se caracterizaron los suelos a partir de 11 variables, entre las que se destacan: materia orgánica, pH, conductividad eléctrica, micro y macronutrientes. Esta información fue publicada y se encuentra disponible desde la web de la FCA ([agro.unc.edu.ar](http://agro.unc.edu.ar)). La idea inicial de este proyecto fue disponer de datos reales de propiedades edáficas y climáticas, para avanzar en la modelación del comportamiento de fitosanitarios.

En 2018, se iniciaron estudios específicos en el sector rural que alcanzaron a zonas de usos agropecuarios, sectores naturales y sectores con perfil de usos más intensivos (turismo, residencial rural, actividades periurbanas), en el marco de un análisis integral de la dinámica territorial e inmobiliaria de la Provincia de Córdoba, llevado adelante por IDECOR para la Dirección General de Catastro. El enfoque de dicho estudio implicó el modelado de distintas variables utilizando algoritmos de aprendizaje computacional (*machine learning*) y gran cantidad y diversidad de datos, como estructura de la propiedad (catastro), usos del suelo, ambiente, tipos de suelos, topografía, clima, entre otros. A partir de un primer conjunto de datos del Programa Buenas Prácticas Agropecuarias (BPA) de la Provincia de Córdoba y de la FCA-UNC, se desarrollaron mapas actualizados de diversas propiedades, como el contenido de materia orgánica (MO) en suelo, pero fueron igualmente acotados considerando el volumen de muestras utilizadas, las técnicas aplicadas y el tiempo disponible.

Como parte del plan de trabajo 2019-2020 de IDECOR, en conjunto con la Secretaría de Agricultura de la Provincia e INTA Regional Córdoba, se fijó como objetivo profundizar la investigación en metodologías para el mapeo de estas variables y en particular, desarrollar un mapa de MO maximizando la cantidad de datos de suelo posibles de integrar, mejorando los enfoques de procesamiento y considerando la inclusión, en el modelado, de covariables disponibles o desarrollables desde la IDE provincial. En ese marco, la Secretaría de Agricultura facilitó el acceso a la base de datos del Programa BPA, como también INTA a sus datos disponibles. Se realizaron, además, gestiones para integrar datos de instituciones públicas, como la FCA-UNC, el IMBIV (Instituto Multidisciplinario de Biología Vegetal, CONICET-UNC), la Universidad Nacional de Río Cuarto (UNRC) y de empresas privadas, participando AGD, Seiker y Orbely.

Durante dicho período, se trabajó adicionalmente en la construcción de covariables específicas que en muchos casos implicó el desarrollo de modelos en sí mismos. Entre estas, pueden mencionarse la mejora del Mapa de Cobertura de Suelo (*Land Cover*) de la Provincia de Córdoba elaborado por IDECOR en 2018, llevando la unidad mínima mapeable (UMM) de 2,5 ha a 1 ha; también, el desarrollo de datos topográficos de mayor detalle, a partir de la incorporación de un Modelo Digital de Elevaciones (DEM) de 5 m para la zona central de la provincia (derivado de un vuelo del Instituto Geográfico Nacional) y el DEM Merit, de mejor calidad en zonas de llanura. También se trabajó para la incorporación de información de humedad en suelo, a partir de series históricas desde 2015 del programa SMAP (NASA), facilitadas por CONAE.

Las versiones iniciales de 2018 se basaron esencialmente en un modelado geoestadístico, mientras que los desarrollos iniciados en 2019 tuvieron importantes innovaciones en el proceso de modelado. Se incorporaron algoritmos de aprendizaje computacional que fueron ajustados siguiendo el esquema metodológico del Mapeo Digital de Suelo. De esta forma en octubre de 2020 fue publicada la primera versión del mapa de MO ([ver publicación](#)), el cual informa los niveles de MO en el horizonte superficial (en %) a escala provincial y para una resolución de 25 ha (celdas de 500 m de lado). El trabajo fue realizado a partir de más de 3.200 muestras de suelo utilizando en el modelo predictivo una serie de variables explicativas que fueron procesadas y desarrolladas por la IDE provincial.

Para el 2021, se tuvo como objetivo actualizar el mapa creado a partir de la recolección de una mayor cantidad de muestras, y generar otros mapas de las variables de suelo fósforo, pH y las fracciones

granulométricas arena, arcilla y limo. A la iniciativa se sumaron otras empresas privadas como RAVIT. Para estos nuevos desarrollos se actualizaron las covariables calculadas por la IDE además de incorporar otras como el mapa geológico de la provincia de Córdoba, edición 2021 (SEGEMAR). El presente informe documenta las actividades desarrolladas y comparte los resultados obtenidos, al tiempo que acompaña la publicación online y en formato de datos abiertos, de los mapas de Materia Orgánica, Fósforo, pH, Arena, Arcilla y Limo de los suelos de la Provincia de Córdoba para 2021.

Estos desarrollos se suman a otras acciones y proyectos llevados adelante en la Provincia de Córdoba en esta temática, como la reactivación y sostenimiento del Plan Mapa de Suelos entre INTA y el Gobierno de la Provincia de Córdoba, que genera información fundamental para conocer los suelos y su distribución, permitiendo definir estrategias de uso, manejo y conservación del recurso; el Programa BPA de la Secretaría de Agricultura, que desde 2017 incorporó más de 10.800 productores en un trabajo que contribuye al desarrollo sostenible de la actividad agropecuaria y el mapeo de cobertura de suelo<sup>1</sup> (*Land Cover*) iniciado en 2018 por IDECOR, como herramienta de apoyo a diversos estudios territoriales.

## 2. Alcance de los productos

Los mapas de Materia Orgánica (MO), Fósforo (P), pH y contenidos de Arena, Arcilla y Limo informan los niveles de estas variables en el horizonte superficial (20 cm) a escala provincial y para una resolución de 25 ha (celdas de 500 m). El trabajo fue realizado siguiendo los protocolos definidos en el Mapeo Digital de Suelo (MDS), a partir de muestras de suelo provenientes de organismos públicos provinciales, nacionales y empresas privadas, con un importante conjunto de covariables procesadas por la IDE provincial. Los productos generados se complementan con mapas de incertidumbre de la predicción, que permite ponderar en forma local la calidad de las estimaciones obtenidas. Se delimitaron zonas (máscaras) donde no se informan valores de las propiedades del suelo, correspondientes con manchas urbanas, cuerpos de agua o inundación recurrente y salinas.

## 3. Datos

Los datos utilizados para el mapeo de variables de suelo fueron apartados por instituciones públicas y privadas, logrando sistematizar más de 5.400 observaciones georreferenciadas. Las fuentes de esta información provinieron del Programa de Buenas Prácticas Agrícolas (BPA, Secretaría de Agricultura de Córdoba), el Plan Mapas de Suelo (Ministerio de Agricultura y Ganadería de Córdoba-INTA), la Facultad de Ciencias Agropecuarias de la Universidad Nacional de Córdoba, la Facultad de Agronomía y Veterinaria de la Universidad Nacional de Río Cuarto y el Instituto Multidisciplinario de Biología Vegetal. Por su parte, las empresas privadas aportantes fueron Seiker (en 2020 y 2021), Orbely (en 2020 y 2021), RAVIT (2021) y AGD (2020).

Las unidades seleccionadas para expresar los valores fueron partes por millón (ppm) para P y porcentaje (%) para materia orgánica y partículas primarias. Todos los datos recolectados de perfiles de suelo o con más de una medición en profundidad, fueron estandarizados en una profundidad de 0-20 cm mediante funciones de suavizado de áreas equivalentes (*splines*) (Malone et al., 2009). Se descartaron datos de mediciones de más de 10 años, en particular para las variables MO y P. Así los registros de las muestras recolectadas entre los años 2016 y 2021 representaron el 90% de los datos de MO y 85%, 83% y 66%, en P, pH y Arcilla, respectivamente. Las bases de datos (muestras) usadas como input para el mapeo de las variables presentaron entre 1379 (Arcilla) a 4436 (MO) observaciones (Tabla 1).

---

<https://idecor.cba.gov.ar/land-cover-cordoba-que-es-el-nuevo-mapa-de-cobertura-de-suelo-de-la-provincia/>

<https://www.conicet.gov.ar/mapa-de-cobertura-del-suelo-de-la-provincia-de-cordoba/>

<https://gn-idecor.mapascordoba.gob.ar/maps/22/view>

Tabla 1. Cantidad de observaciones (n), media, coeficiente de variación (CV), valor mínimo (Mín), máximo (Max) y percentiles 25, 50 y 75 (P(25), P(50) y P(75), respectivamente) para la muestra de valores de variables de suelo de la Provincia de Córdoba.

Variable	n	Media	CV	Mín.	Máx.	P(25)	P(50)	P(75)
MO (%)	4436	2,24	55	0,10	13,20	1,59	2,10	2,64
P (ppm)	3907	27,90	87	0,10	192,38	11,40	19,98	36,03
pH	3778	6,54	10	4,10	11,00	6,15	6,50	6,90
Arcilla (%)	1379	12,19	62	<0,00	44,60	6,80	10,66	16,30
Limo (%)	1379	37,57	47	<0,00	89,10	24,32	36,60	54,53
Arena (%)	1379	47,72	48	0,05	96,60	27,35	51,60	65,83

Las medidas resumen (Tabla 1) muestran que el valor promedio del contenido de MO fue de 2,24%, con una variabilidad relativa a la media del 55%. Los valores mínimos y máximos fueron de 0.10% y 13.20%, respectivamente. Un 25% de los datos tuvieron valores por encima de 2,64% o por debajo de 1.59%. La variable P fue la de mayor variabilidad relativa (CV=87%) con un valor promedio de 27,9 ppm. Para las variables granulométricas los valores promedios de Arcilla, Arena y Limo fueron de 12,19, 47,72 y 37,57%, respectivamente. Entre estas variables, la Arcilla fue la de mayor variabilidad (62%). La distribución espacial de las muestras de MO, P, pH, Arcilla, Limo y Arena se muestra en las Figuras 1, 2 y 3.

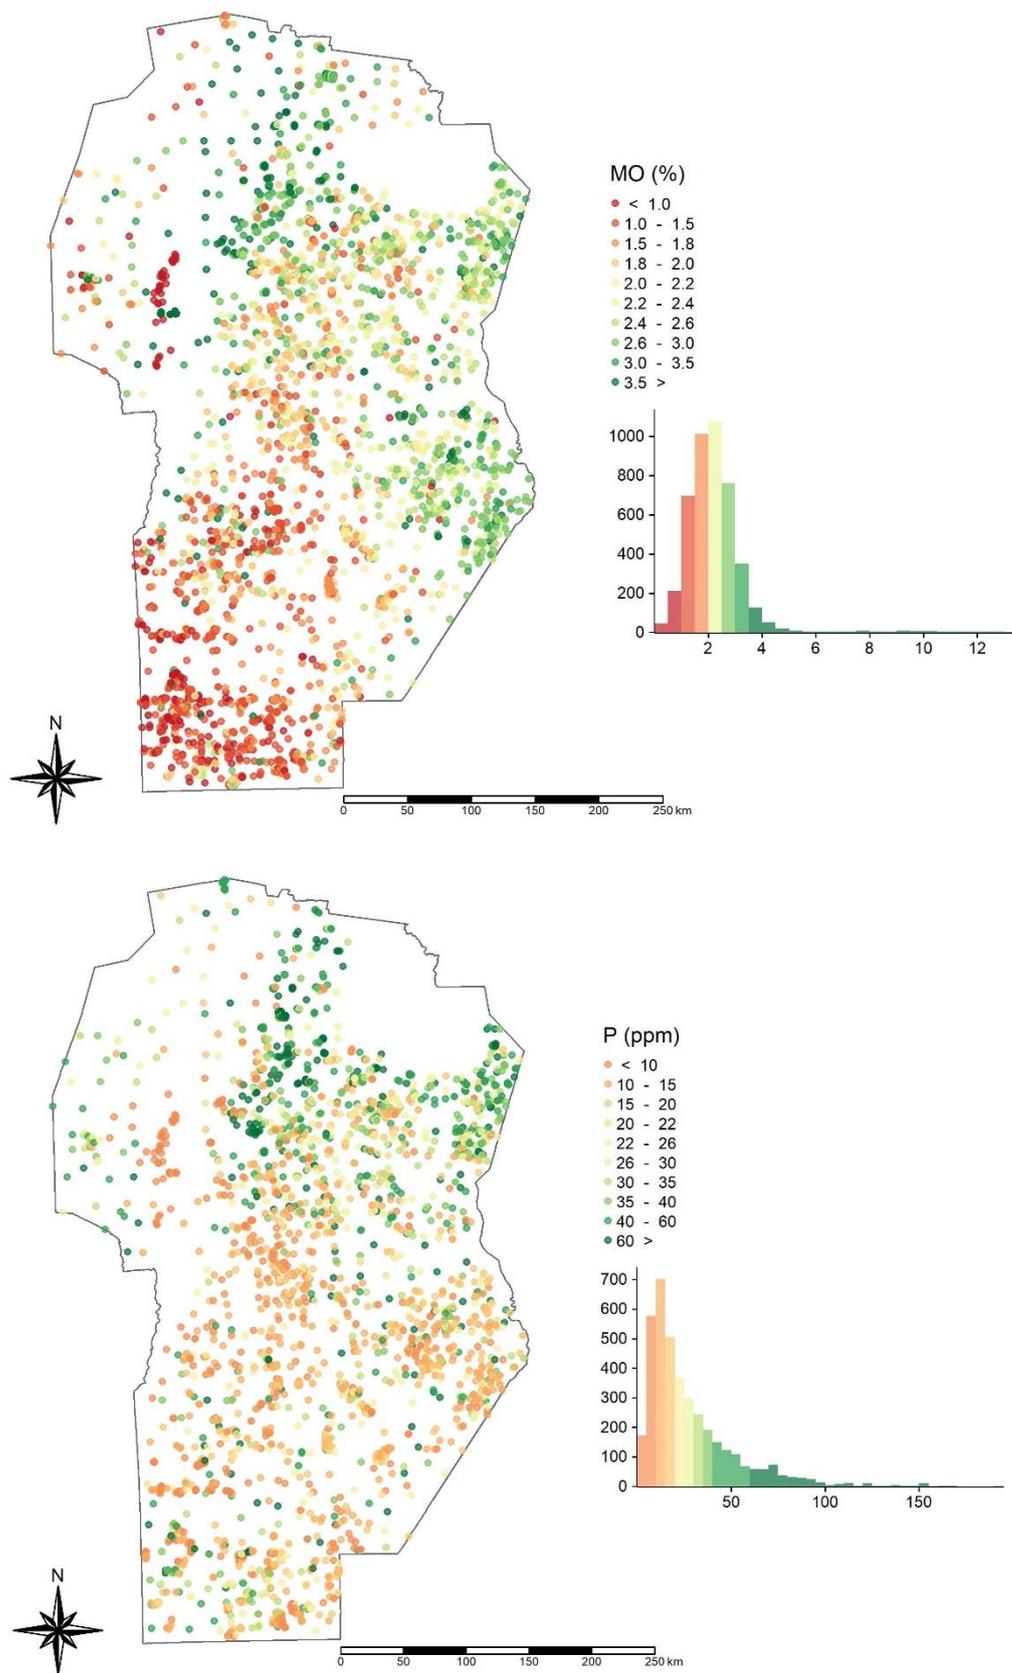


Figura 1. Distribución espacial de puntos de muestreo e histograma de frecuencias absolutas de valores de materia orgánica del suelo (MO) y fósforo (P) en la Provincia de Córdoba.

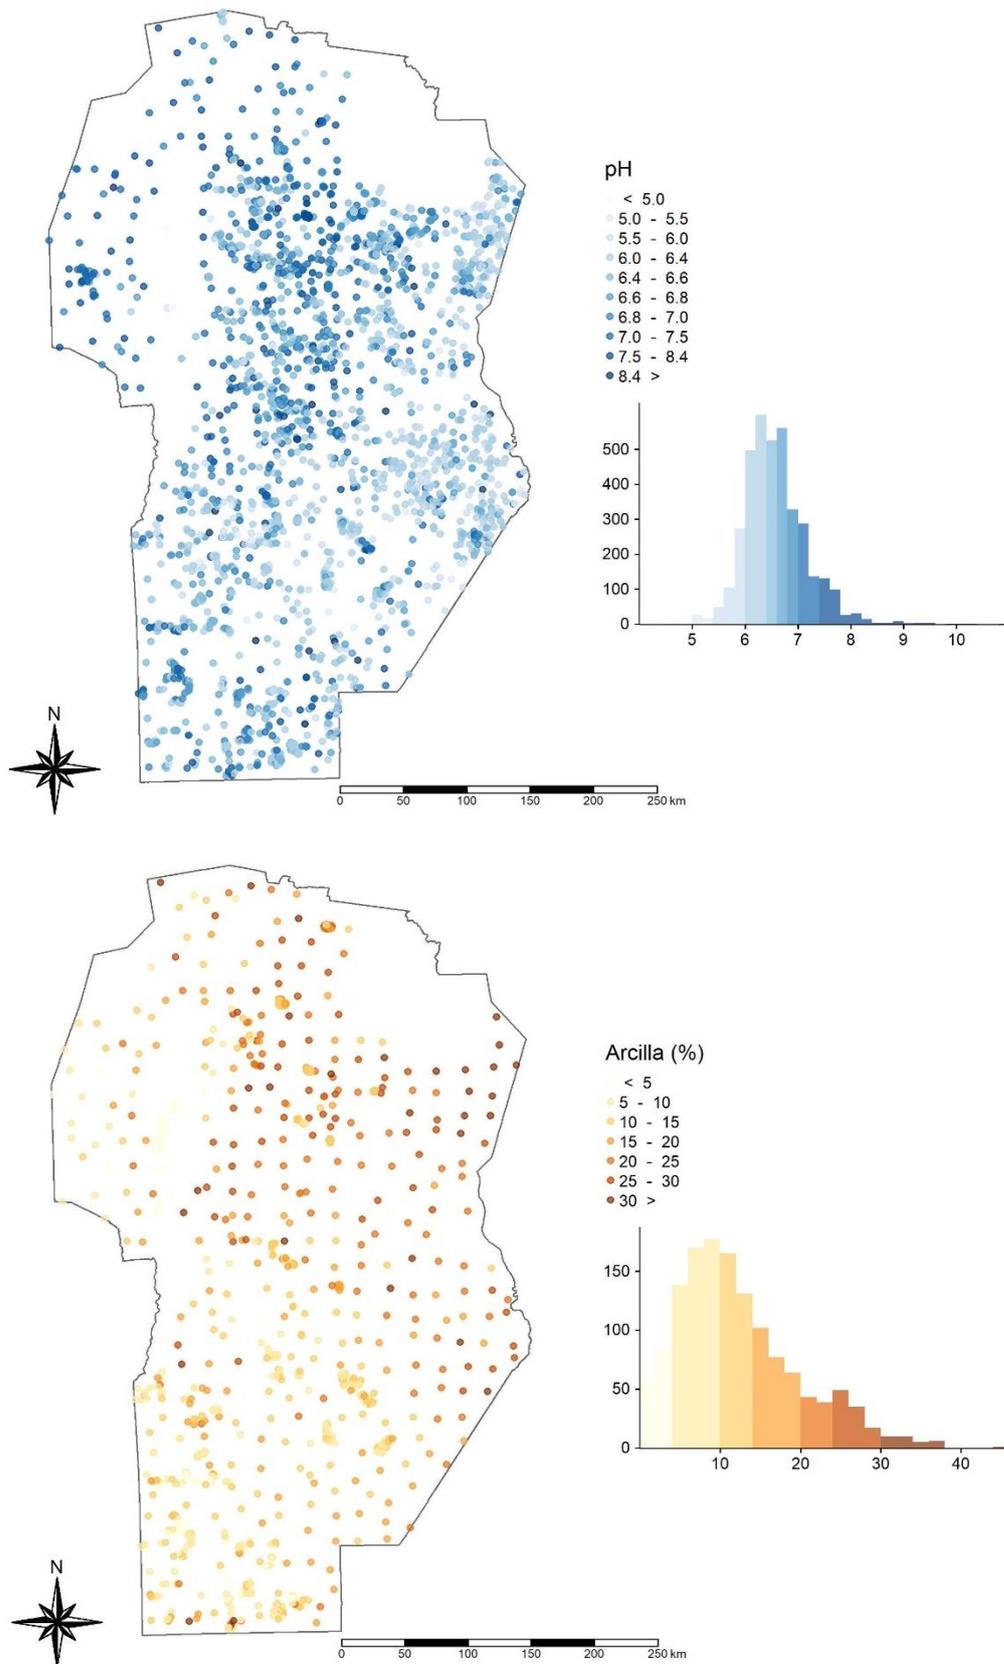


Figura 2. Distribución espacial de puntos de muestreo e histograma de frecuencias absolutas de valores de pH y Arcilla en la Provincia de Córdoba.

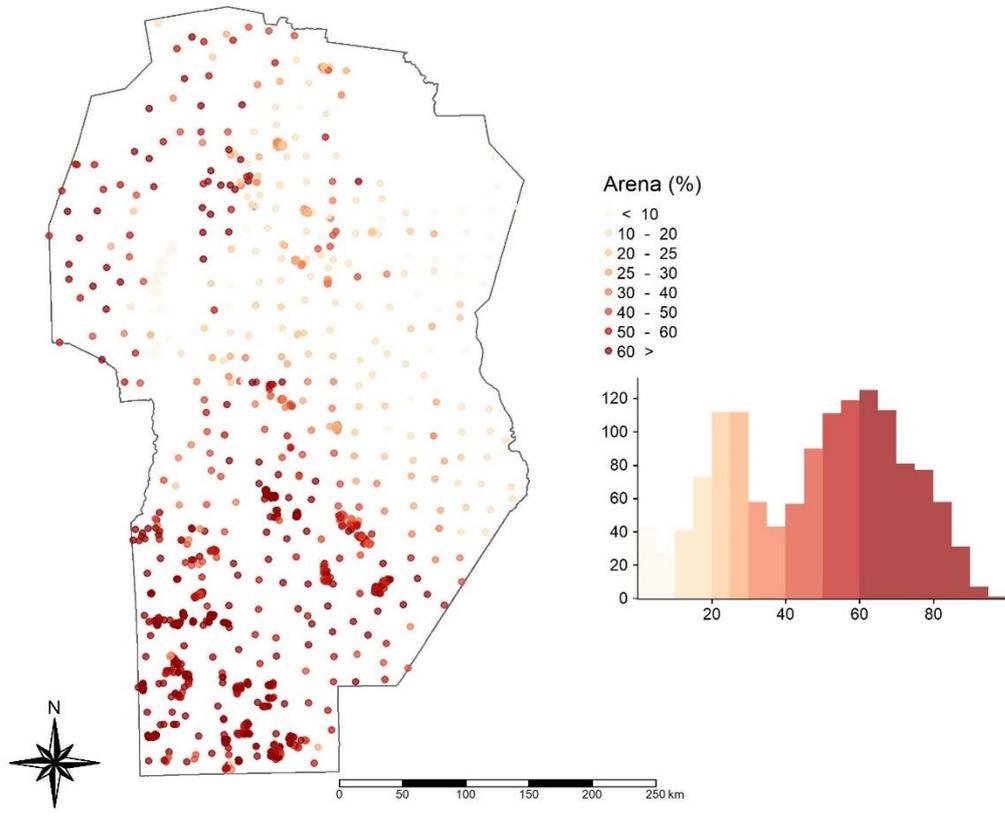
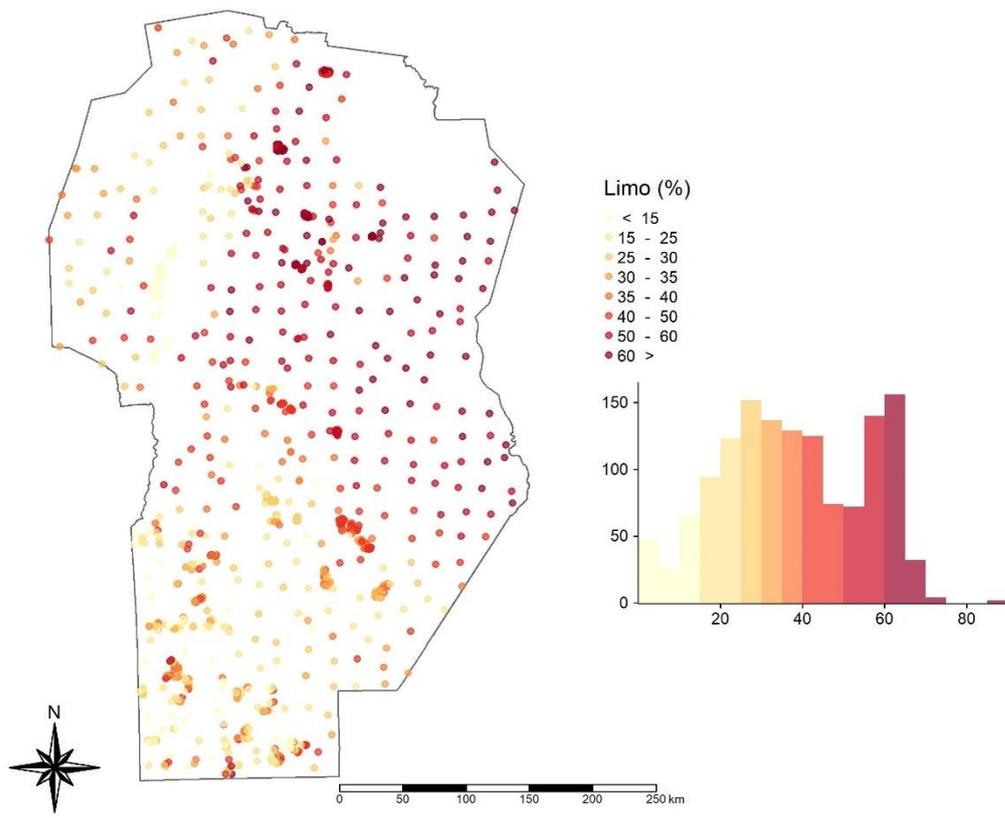


Figura 3. Distribución espacial de puntos de muestreo e histograma de frecuencias absolutas de valores de Limo y Arena en la Provincia de Córdoba.

## 4. Metodología

El enfoque metodológico utilizado para la predicción de las variables de suelo se basó en técnicas de MDS. El concepto de MDS hace referencia a la creación de sistemas de información espacial del suelo basados en modelos estadísticos que permiten explicar la variación espacial de propiedades y tipos de suelo. Los fundamentos teóricos del MDS radican en el esquema conceptual SCORPAN (1) (McBratney et al., 2003) que sintetiza y hace una analogía entre los factores formadores de suelo clásicos y las covariables necesarias para predecir características edáficas.

$$S = f(s, c, o, r, p, a, n) + e \quad (1)$$

donde  $S$  representa la clase o propiedad del suelo a predecir,  $s$  otras propiedades del suelo;  $c$  el clima;  $o$  los organismos, vegetación biomasa, fauna, actividad humana;  $r$  el relieve;  $p$  el material parental, litología;  $a$  la edad, el factor tiempo;  $n$  el espacio, posición espacial y  $e$  la parte no explicada por el modelo (error). Dada la geolocalización de los datos, es posible incorporar en el modelo predictivo la estructura de correlación espacial entre los errores, asociados a las observaciones registradas en distintos sitios del dominio espacial en estudio.

### 4.1. Covariables

Un punto crucial en el modelado es la identificación de las covariables que presentan mayor contribución en la explicación de la variabilidad espacial de la propiedad de suelo a predecir (Yigini et al., 2018). Suelen actuar como covariables las variables georreferenciadas de otras propiedades de suelos, mapas de suelos preexistentes, datos de cobertura del suelo, datos satelitales a partir de los cuales se pueden derivar índices de vegetación como NDVI, mapas litológicos y variables extraídas desde modelos digitales de elevación (MDE), como atributos topográficos primarios y secundarios.

La información relativa a cobertura/uso del suelo es un componente fundamental para el MDS (Nussbaum et al., 2018) ya que, por ejemplo, determinan la cantidad y calidad de los aportes de MO del suelo e influyen en su descomposición y estabilización (Dorji et al., 2014). En este sentido, la construcción de un mapa de cobertura de suelo para la Provincia de Córdoba ha resultado ser un hecho decisivo y diferencial para obtener un producto de calidad. Históricamente, la información relativa a coberturas de cultivos en regiones agrícolas se ha colectado en base a encuestas y recorridas en terreno, datos costosos de obtener que no proporcionan suficiente detalle en cuanto a la distribución espacio-temporal de los cultivos. Aprovechando los avances en teledetección y capacidad de cómputo en la nube, es posible usar datos provenientes de sensores remotos para monitorear los cambios temporales de coberturas agrícolas con alta resolución espacial en grandes superficies (Zhang et al., 2012; Piumetto et al., 2018). Además de la cobertura del suelo, el cambio de su productividad a lo largo del tiempo es otro indicador asociado a factores de degradación de suelo que pueden ser estimados con estas técnicas (Teich et al., 2019). Otro tipo de datos, particularmente útiles para predecir propiedades edáficas, son aquellos obtenidos a partir de estaciones meteorológicas o productos derivados de satélites meteorológicos, que caracterizan la variabilidad climática (Yigini et al., 2018). Un detalle de las covariables implementadas en el modelo de predicción de variables de suelo se encuentra en Tabla 2.

Para llevar a cabo la predicción espacial se generó una grilla regular de 500 m × 500 m en toda el área provincial. Posteriormente se excluyeron áreas correspondientes a cuerpos de agua, zonas urbanas y salinas. En cada celda de la grilla se registraron los valores de cada una de las covariables calculadas. Estas mismas covariables se adicionaron a la base de muestras de cada una de las variables de suelo modeladas, para el ajuste de los modelos predictivos.

Tabla 2. Covariables utilizadas para la predicción de variables de suelo, Provincia de Córdoba

Tipo	Descripción variable	Fuente
<b>Clima</b>	Temperatura media anual (1970-2020)	World Clim version 2
	Radiación solar media (1970-2020)	
	Precipitación media acumulada anual (2001-2020)	TerraClimate
	Temperatura máxima media anual (2001-2020)	
	Temperatura mínima media anual (2001-2020)	
	Déficit hídrico media anual (2001-2020)	
	Índice de Severidad de Sequía media anual (2001-2020)	
Evapotranspiración media mensual acum. (2001-2020)	MOD16 o TerraClimate	
<b>Vegetación</b>	NDVI mediana, serie 2001-2020	Producto MOD13Q1 V6 (Teich et al. 2019)
	SWATI (ESPI). Tendencia NDVI 2001-2018	
	SWATI (AM). Tendencia NDVI 2001-2018	
	SSWATI (ESPI). Tendencia NDVI 2001-2018	
	SSWATI (AM). Tendencia NDVI 2001-2018	
	LTT (ESPI). Tendencia NDVI 2001-2018	
	LTT (AM). Tendencia NDVI 2001-2018	
Land Cover 2017/2018 (1 ha)	IDECOR / <a href="#">MapasCordoba</a>	
<b>Suelo</b>	Índice Productividad de suelo	Cartas de Suelo
	Textura	
<b>Topografía</b>	Altura (m.s.n.m.)	MERIT DEM
	Pendiente (%)	
	Orientación (gr)	
	Índice de humedad topográfico (TWI)	
	Índice de Posición Topográfica ( <i>Topographic Position Index</i> )	
	Posición relativa de la pendiente ( <i>Relative Slope Position</i> )	
	Curvatura longitudinal ( <i>Longitudinal Curvature</i> )	
	Acumulación de Flujo ( <i>Flow Accumulate</i> )	
	Depresiones cerradas ( <i>Closed Depressions</i> )	
	Zona de captación ( <i>Catchment area</i> )	
	Zona de captación modificada ( <i>Modified catchment area</i> )	
	Pendiente de captación ( <i>Catchment Slope</i> )	
	Índice de convergencia ( <i>Convergence Index</i> )	
	Distancia a la red de canales ( <i>Channel Network Distance</i> )	
	Distancia vertical a la red de canales ( <i>Vertical Distance</i> )	
LS-Factor		
Profundidad del Valle ( <i>Valley Depth</i> )		
<b>Litología</b>	Mapa Geológico de la Provincia de Córdoba, Edición 2021	SEGEMAR, Secretaría de Minería de la Provincia de Córdoba
<b>Tiempo</b>	Año toma de muestra	
<b>Posición</b>	Coordenadas x e y	

## 4.2. Modelación

Para el modelado de las variables de suelo se implementaron algoritmos de aprendizaje automático, entre los que se destacan los métodos basados en árboles como *Random Forest* (RF) (Breiman, 2001), *Quantile Regression Forest* (QRF) (Meinshausen, 2006) y *Extreme Gradient Boosting* (XGBoost) (Chen and Guestrin, 2016), también se usaron métodos de regresión como *Support Vector Machine* (SVM) (Zhang et al., 2004) y *Cubist* (Kuhn et al., 2016). La implementación de estos algoritmos incluyó el ajuste de sus versiones clásicas, *i.e.* no incluyen la información espacial en el análisis y alternativas basadas en la complementación con técnicas geoestadísticas que permiten contemplar la estructura de correlación espacial residual (Guo et al., 2015; Silatsa et al., 2020; Córdoba et al., 2021).

El ajuste y la evaluación de los hiperparámetros de los modelos ajustados, así como la comparación de su capacidad predictiva, se realizó mediante procedimientos de validación cruzada del tipo *k-fold* ( $k=10$ ) repetido 10 veces. Distintas medidas de cuantificación del error fueron calculadas, entre ellas: error absoluto medio (MAE), raíz cuadrada del error cuadrático medio (RMSE), error porcentual absoluto medio (MAPE), porcentaje de varianza explicada (AVE), y coeficiente de concordancia de Lin (LCC).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

$$AVE = 1 - \frac{\sum_1^n (y_i - \hat{y}_i)^2}{\sum_1^n (y_i - \underline{y})^2}$$

$$LCC = \frac{2 \cdot \rho \cdot \sigma_{\hat{y}} \cdot \sigma_y}{\sigma_{\hat{y}}^2 + \sigma_y^2 + (\underline{\hat{y}} - \underline{y})^2}$$

donde  $N$  es el número de observaciones,  $y_i$  es el valor verdadero en la posición  $i$ ,  $\hat{y}_i$  es el valor predicho en ese punto,  $\underline{y}$  y  $\underline{\hat{y}}$  es el promedio general de los valores observados y predichos de la variable de suelo modelada.

Realizada la selección del modelo mediante estadísticas globales, se procedió a realizar la predicción de cada variable empleando la grilla de predicción generada previamente y al cálculo de la incertidumbre de predicción, empleando la metodología sugerida en el contexto del mapeo digital de suelo (Yigini et al., 2018; Hengl et al., 2018). De esta forma se calcularon los valores predichos y el desvío estándar de la predicción relativo al valor predicho (incertidumbre de predicción en %).

## 5. Resultados

Si bien las diferencias entre algunos de los métodos evaluados no fueron importantes, el algoritmo *Random Forest* mostró un mejor desempeño para todas las variables relevadas, a excepción de Arena, en la mayoría de las métricas utilizadas para la comparación de los modelos (Tabla 3). Los residuos de los modelos ajustados no mostraron estructura de correlación espacial por lo que no fue necesario la modelación de éstos mediante técnicas geoestadísticas complementarias. Los valores más bajos y altos de error de predicción absoluto promedio (MAPE) para los algoritmos predictivos seleccionados, fue de 4,3 % y 35,1% en pH y P. Los mayores niveles de LCC y AVE se observaron para la variable Arena (0,87 y 0,78; respectivamente).

Tabla 3. Evaluación de la capacidad predictiva de los modelos implementados. Se resaltan los valores óptimos de los criterios de comparación de los modelos predictivos en cada variable de suelo.

Variable	Método	MAE	MAPE	RMSE	LCC	AVE
MO	RF	<b>0,39</b>	19,81	<b>0,62</b>	<b>0,86</b>	<b>0,75</b>
	QRF	0,40	<b>19,10</b>	0,63	0,85	0,73
	SVM	0,43	20,64	0,70	0,82	0,68
	XGB	0,42	20,96	0,64	0,85	0,73
	Cubist	0,41	20,31	0,64	0,85	0,73
P	RF	10,50	35,13	<b>14,77</b>	<b>0,67</b>	<b>0,46</b>
	QRF	<b>9,66</b>	<b>28,87</b>	15,31	0,66	0,42
	SVM	10,87	34,87	15,96	0,60	0,37
	XGB	11,19	39,13	15,55	0,63	0,40
	Cubist	10,78	34,86	15,27	0,66	0,42
pH	RF	<b>0,32</b>	<b>4,83</b>	<b>0,46</b>	<b>0,62</b>	<b>0,44</b>
	QRF	<b>0,32</b>	4,79	0,48	0,60	0,41
	SVM	0,35	5,30	0,50	0,55	0,35
	XGB	0,34	5,16	0,48	0,59	0,40
	Cubist	0,33	4,95	0,48	0,61	0,41
Arcilla	RF	3,00	33,07	<b>4,33</b>	<b>0,78</b>	<b>0,64</b>
	QRF	<b>2,98</b>	<b>30,71</b>	4,45	0,77	0,62
	SVM	3,40	36,03	4,76	0,74	0,57
	XGB	3,20	35,28	4,56	0,76	0,61
	Cubist	<b>2,98</b>	32,45	4,36	0,78	<b>0,64</b>
Limo	RF	5,90	25,97	<b>8,35</b>	0,85	<b>0,75</b>
	QRF	<b>5,86</b>	<b>25,39</b>	8,53	0,85	0,74
	SVM	6,56	29,66	9,02	0,83	0,71
	XGB	6,46	27,65	8,84	0,84	0,72
	Cubist	5,87	25,42	8,42	<b>0,86</b>	0,74
Arena	RF	7,37	25,94	10,30	<b>0,87</b>	<b>0,78</b>
	QRF	7,36	23,19	10,47	<b>0,87</b>	0,77
	SVM	8,16	26,30	11,07	0,85	0,74
	XGB	7,88	25,87	10,76	0,86	0,76
	Cubist	<b>7,28</b>	<b>23,02</b>	<b>10,25</b>	<b>0,87</b>	<b>0,78</b>

Los valores predichos de las variables de suelo se presentan en la Tabla 4. La cantidad de celdas de 25 ha sobre las cuales se obtuvieron los valores de predicción fue de 616430. La media de los valores predichos fue similar a la muestra. Las mayores diferencias entre ambas bases de datos se encuentran a nivel de los valores extremos de la distribución (mínimo y máximo).

Tabla 4. Media, coeficiente de variación (CV), valor mínimo (Mín.), máximo (Max.) y percentiles 25, 50 y 75 (P(25), P(50) y P(75) respectivamente) para valores de predicción de variables de suelo de la Provincia de Córdoba.

Variable	Media	CV	Mín.	Máx.	P(25)	P(50)	P(75)
MO (%)	2,33	33	0,10	8,14	1,82	2,28	2,67
P (ppm)	27,80	37	0,08	114,17	20,77	26,11	33,64
pH	6,68	6	4,40	8,86	6,41	6,68	6,94
Arcilla (%)	16,45	35	0,02	33,68	12,29	16,47	20,65
Limo (%)	40,13	32	0,03	76,38	30,72	36,89	52,33
Arena (%)	41,52	42	0,05	89,21	25,33	44,27	55,77

El mapa de predicción de MO se presenta en la Figura 4. Del total de datos predichos, el 1% de los mismos tuvieron valores menores a 0,5% de MO, mientras que un 15% tuvo valores mayores al 3%. Los valores más bajos (<0,5%) se ubicaron en la zona de sierras con cobertura predominante de tipo roca (*Land Cover* 2018/19) y en la zona de piedemonte se registraron los valores más altos (> 4%). Valores en el rango de 1% a 1,5% se ubicaron en la zona sudoeste, mientras que en el centro norte, noreste y sudeste se observan valores entre 2,4% y 3%.

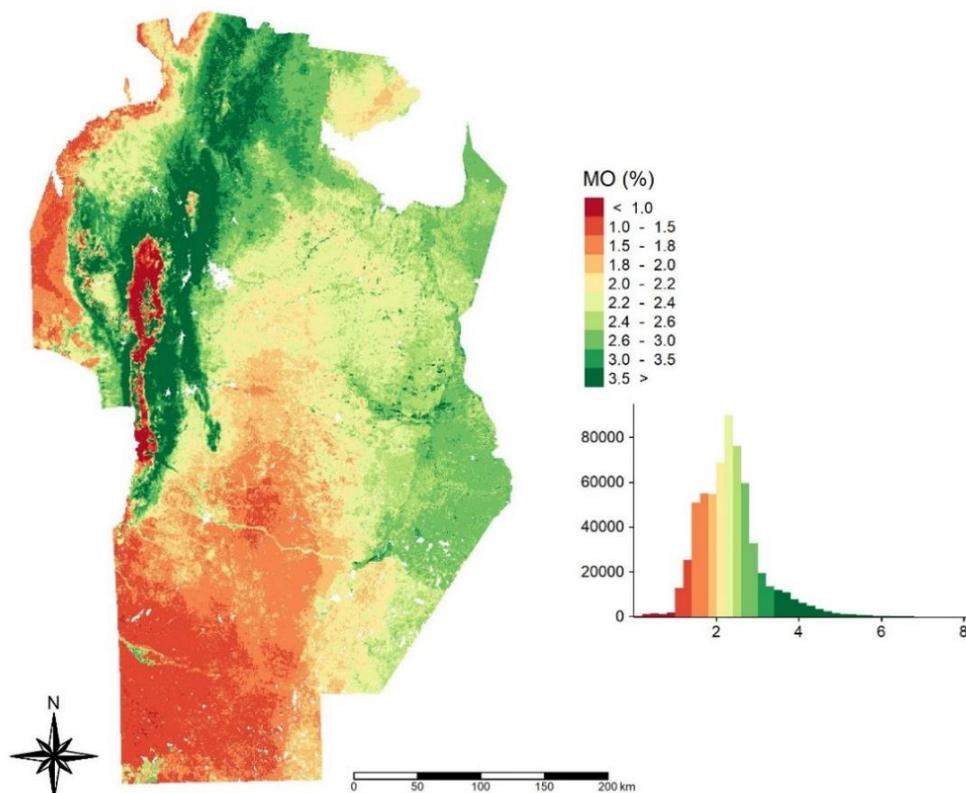


Figura 4. Mapa de predicción de la materia orgánica (MO) del suelo en la provincia de Córdoba.

En la Figura 5 se presenta el mapa del desvío estándar de la predicción relativo al valor predicho de la MO. Los valores de incertidumbre de predicción tuvieron un valor promedio del 28%. Las áreas donde la incertidumbre de predicción fue alta ( $CV > 40$ ) corresponde a la zona noroeste de la provincia donde se dispone de una menor densidad de muestras para realizar la predicción espacial.

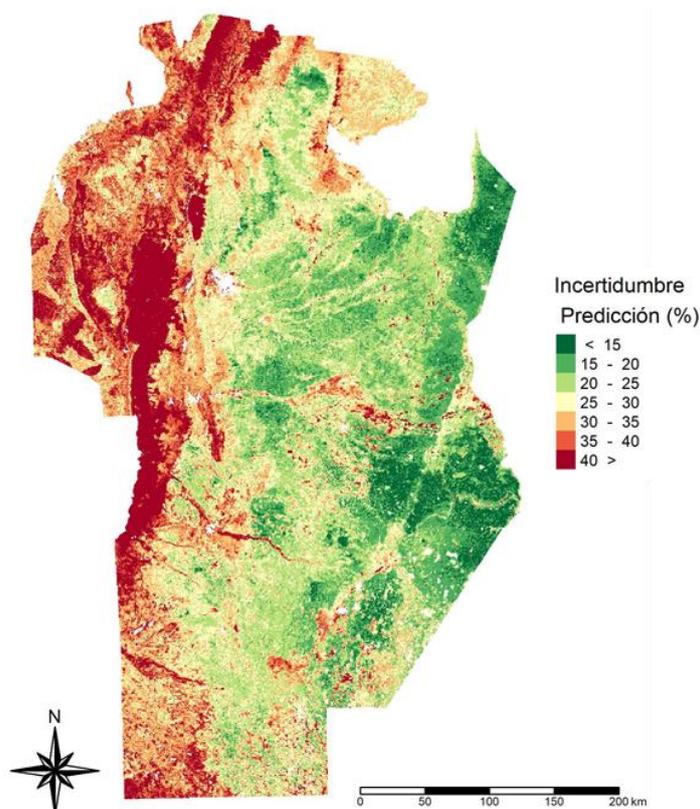


Figura 5. Mapa de incertidumbre de predicción de la materia orgánica (MO) del suelo en la Provincia de Córdoba. Valor porcentual expresado como el desvío estándar de la predicción relativo al valor predicho.

En la Figura 6 se presenta el mapa de predicción de P. Los valores promedio estimados para la Provincia de Córdoba se ubicaron entorno a las 27,8 ppm. Valores bajos (<10 ppm) se ubicaron en la zona alta de la provincia (sierras), valores entre 10 y 20 ppm se presentan en la zona centro sur y valores por encima de 30 ppm se ubican en el noreste y noroeste provincial. La Figura 7 presenta los mapas de incertidumbre de predicción. Al igual que para la variable MO, los valores de incertidumbre más altos se ubican en la zona de las sierras, ya que ésta es un área con baja densidad de datos para el modelado.

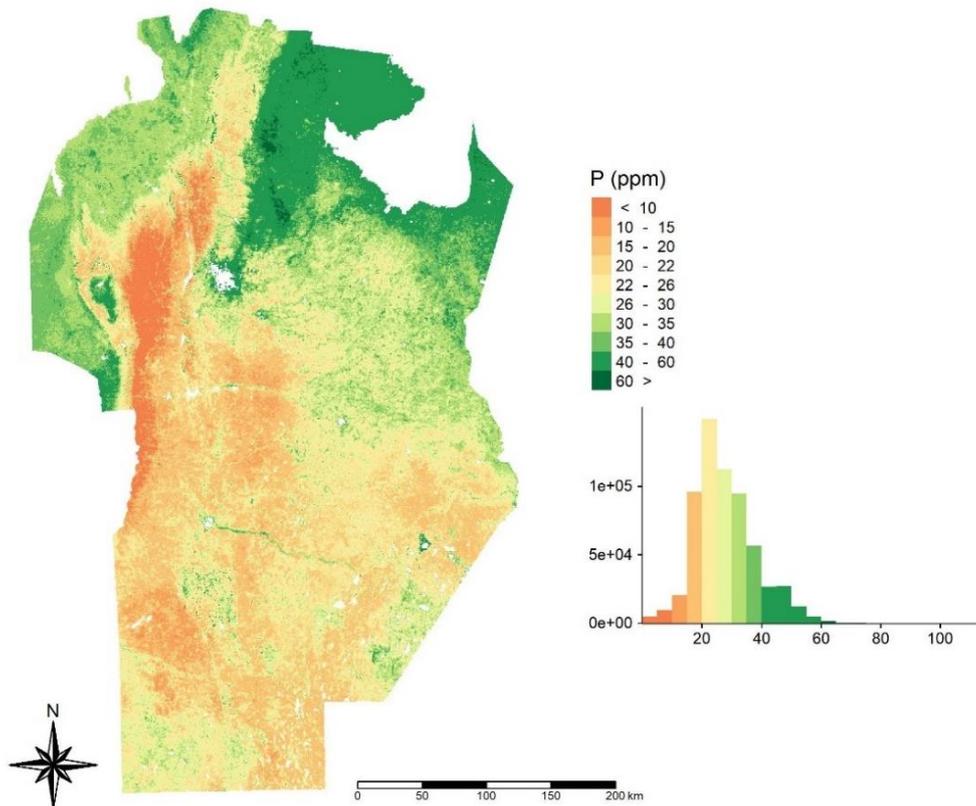


Figura 6. Mapa de predicción del contenido de Fósforo (P) del suelo en la provincia de Córdoba.

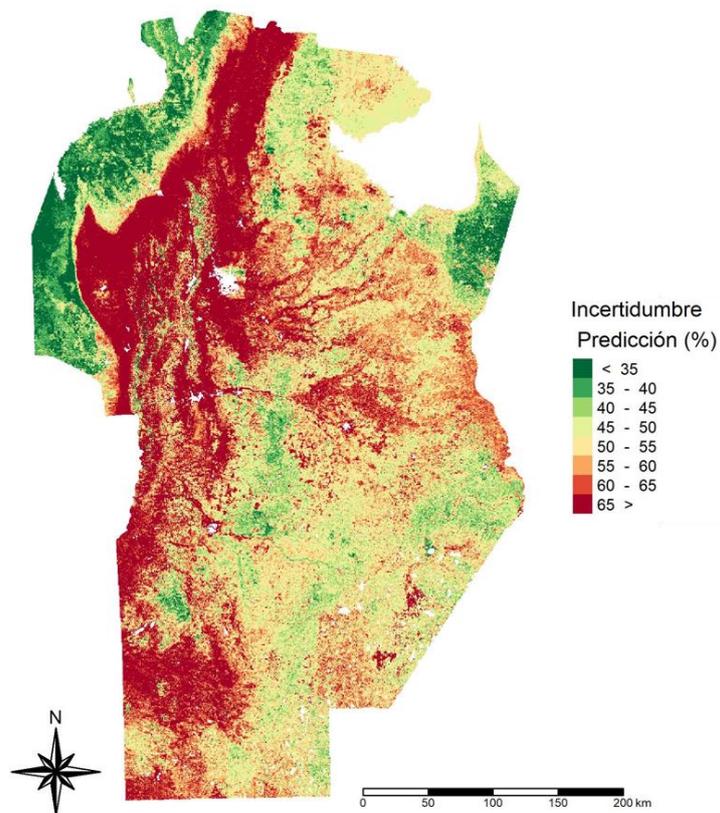


Figura 7. Mapa de incertidumbre de predicción del contenido de Fósforo (P) del suelo en la Provincia de Córdoba. Valor porcentual expresado como el desvío estándar de la predicción relativo al valor predicho.

El mapa del pH del suelo se muestra en la Figura 8. El valor promedio de la predicción fue de 6,68. Los valores más bajos (<5), menos del 2% de los datos, se ubicaron en la zona de las sierras mientras que valores por encima de 7 se presentaron en la zona noroeste de la provincia y en áreas de bañados y lagunas del sureste. Los valores de incertidumbre de predicción de esta variable fueron en promedio del 8%. Las áreas de mayor incertidumbre (Figura 9) se corresponden a las mismas para MO, P y variables granulométricas.

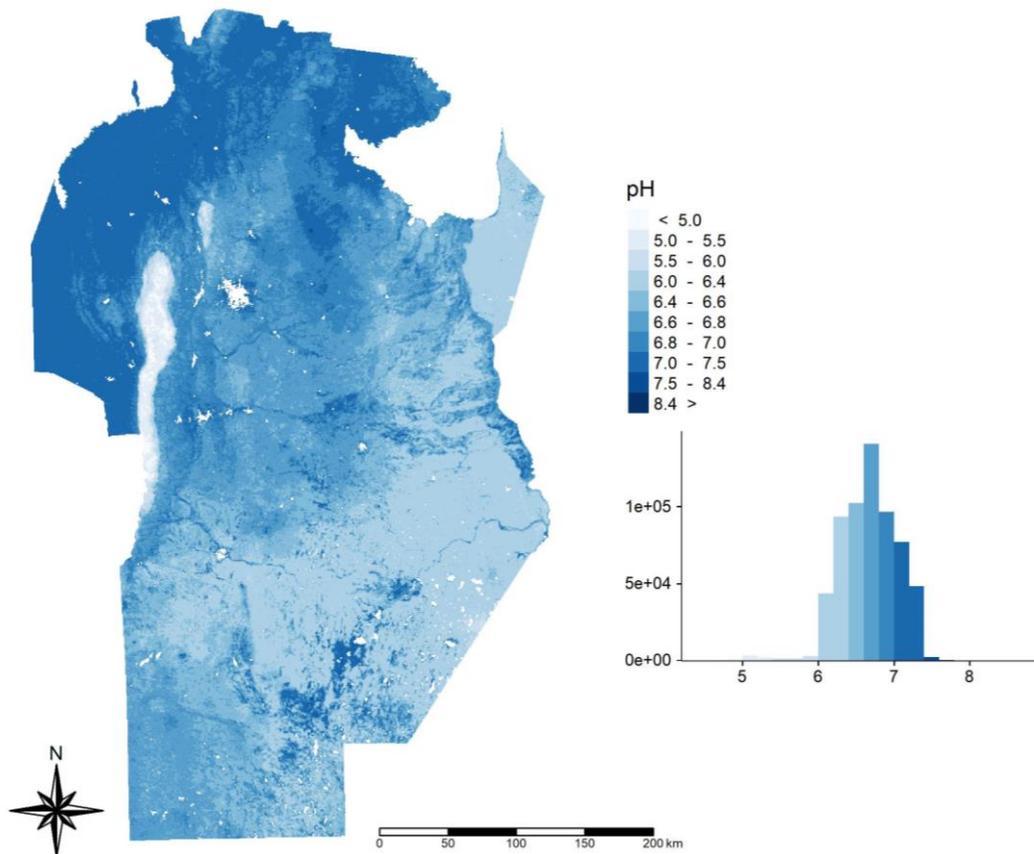


Figura 8. Mapa de predicción del pH del suelo en la provincia de Córdoba.

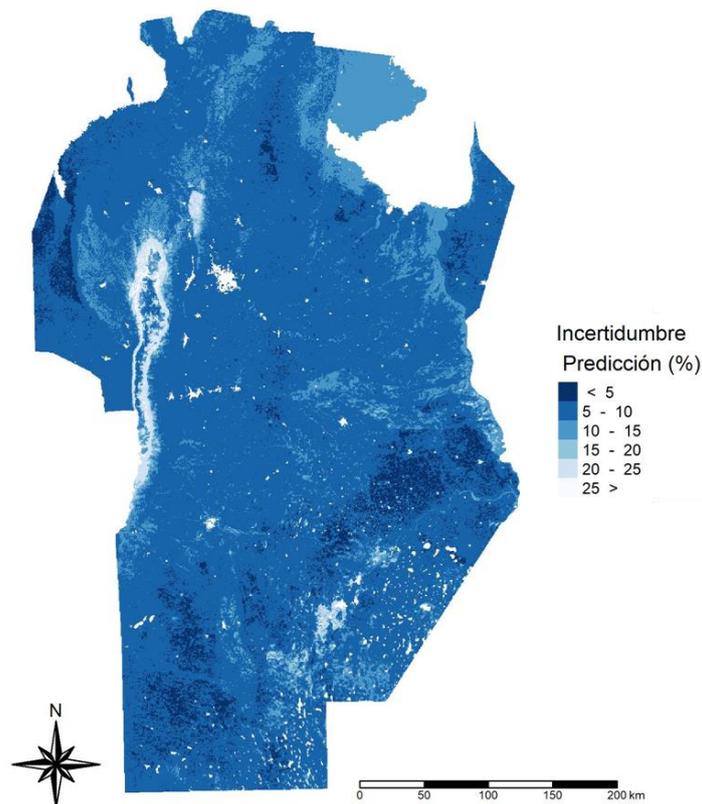


Figura 9. Mapa de incertidumbre de predicción del pH del suelo en la Provincia de Córdoba. Valor porcentual expresado como el desvío estándar de la predicción relativo al valor predicho.

En las Figuras 10, 12 y 14 se presentan los mapas de predicción de las variables granulométricas y sus mapas de predicción porcentual (Figuras 11, 13, 15, respectivamente). Los valores promedios de las predicciones fueron del 16, 40 y 42% para el contenido de arcilla, limo y arena, respectivamente. El gradiente textural se observa en el sentido suroeste-noreste, presentando desde la dirección inicial valores bajos de arcilla y limo (<10%) y altos de arena (>50%), patrón que se invierte en el extremo noreste. En cuanto los valores de incertidumbre de predicción se ubicaron en promedio en torno al 40, 31 y 39% para arcilla, limo y arena, respectivamente.

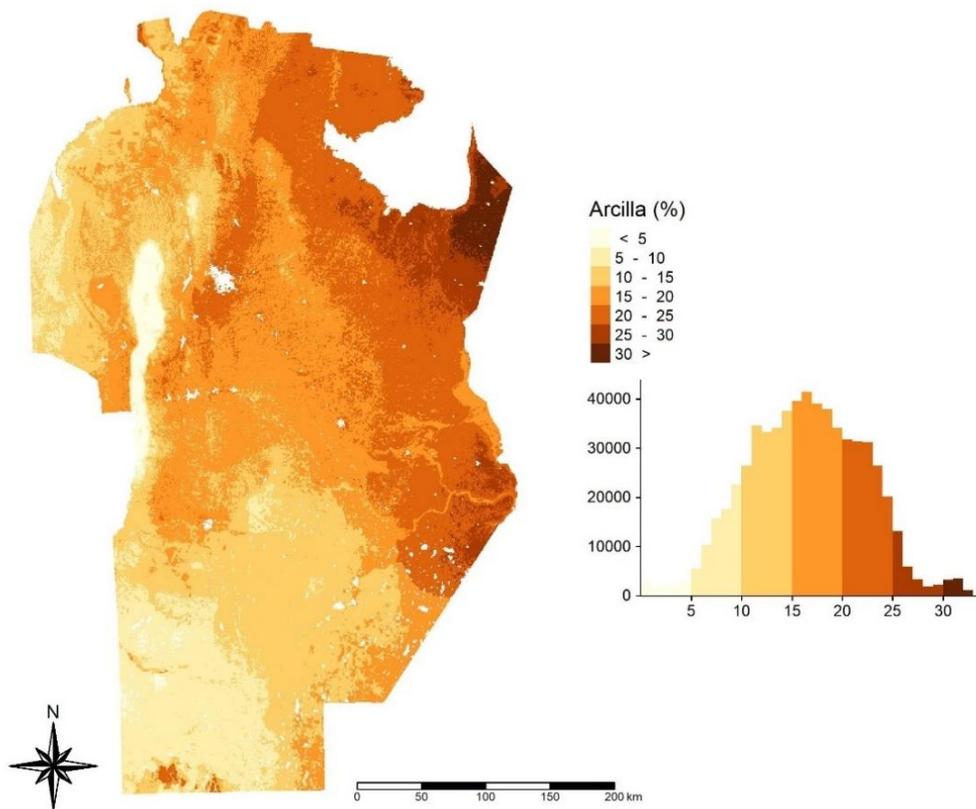


Figura 10. Mapa de predicción del contenido de Arcilla (%) del suelo en la provincia de Córdoba.

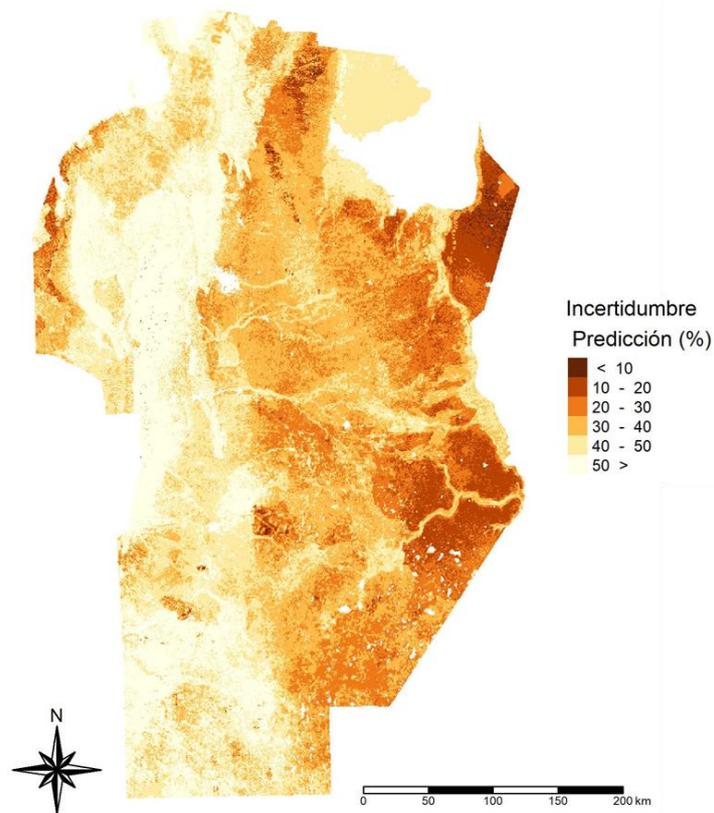


Figura 11. Mapa de incertidumbre de predicción del contenido de Arcilla (%) del suelo en la Provincia de Córdoba. Valor porcentual expresado como el desvío estándar de la predicción relativo al valor predicho.

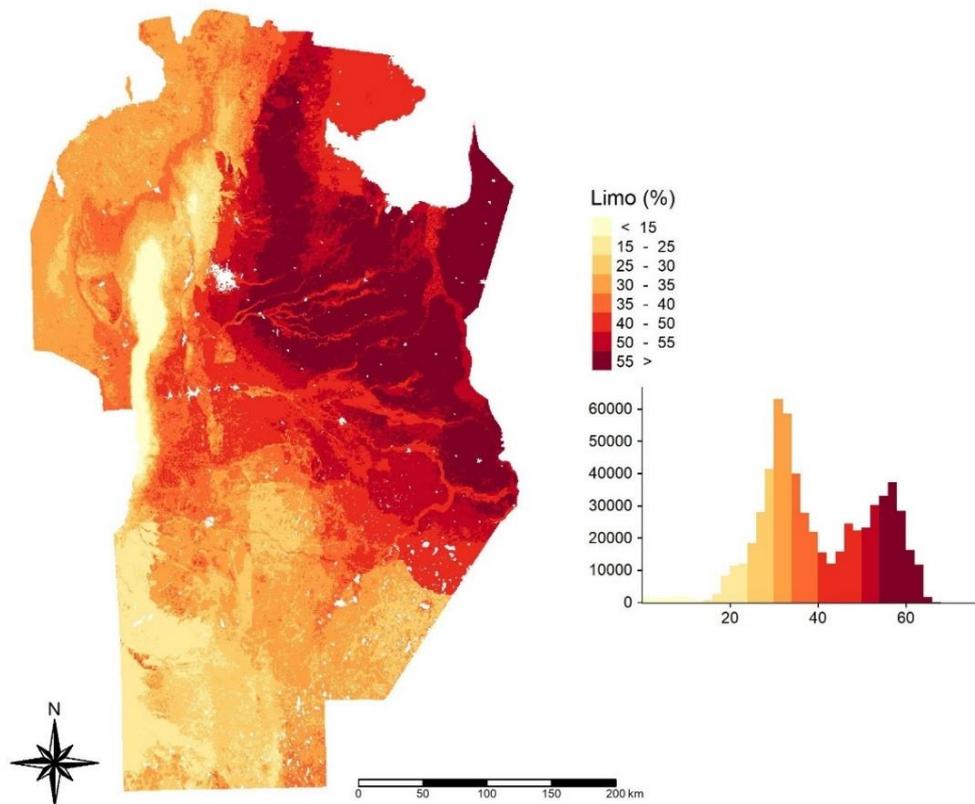


Figura 12. Mapa de predicción del contenido de Limo (%) del suelo en la provincia de Córdoba.

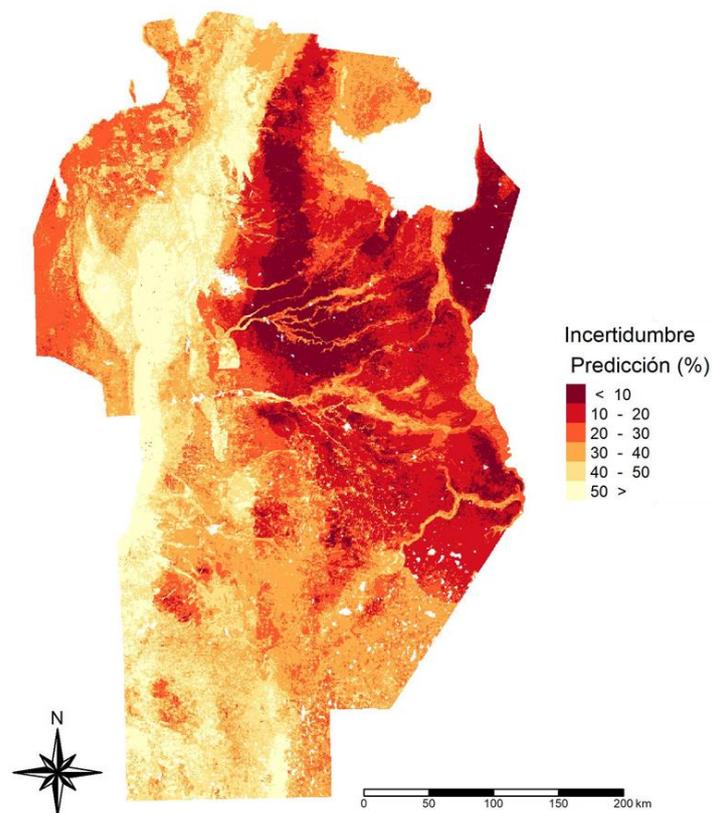


Figura 13. Mapa de incertidumbre de predicción del contenido de Limo (%) del suelo en la Provincia de Córdoba. Valor porcentual expresado como el desvío estándar de la predicción relativo al valor predicho.

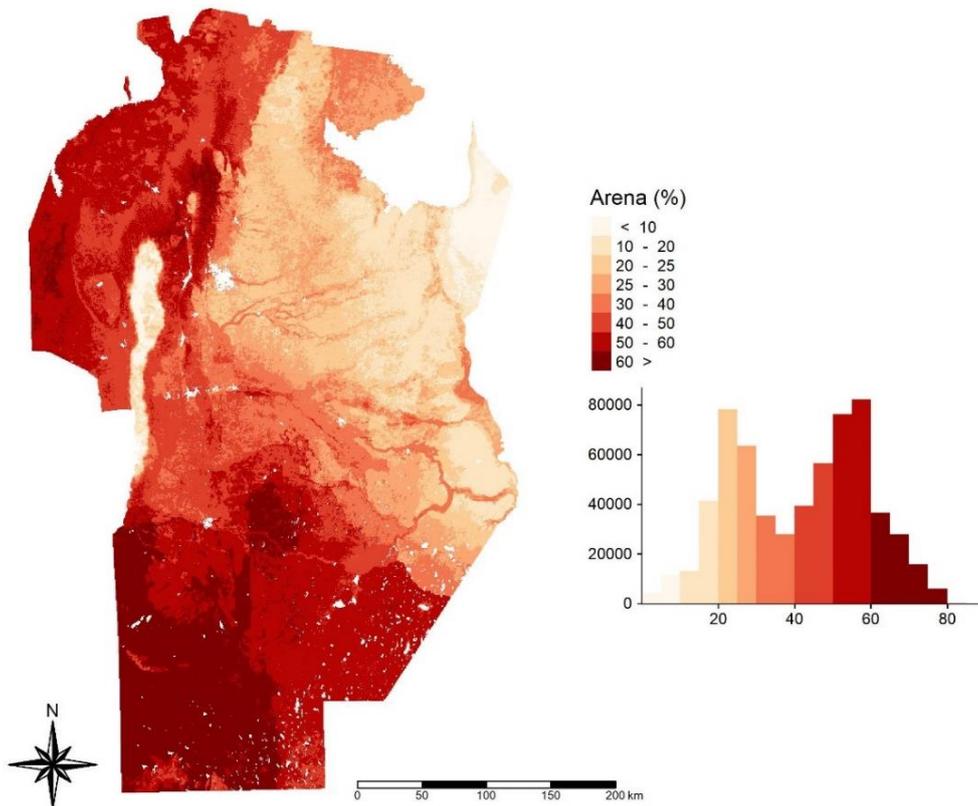


Figura 14. Mapa de predicción del contenido de Arena (%) del suelo en la provincia de Córdoba.

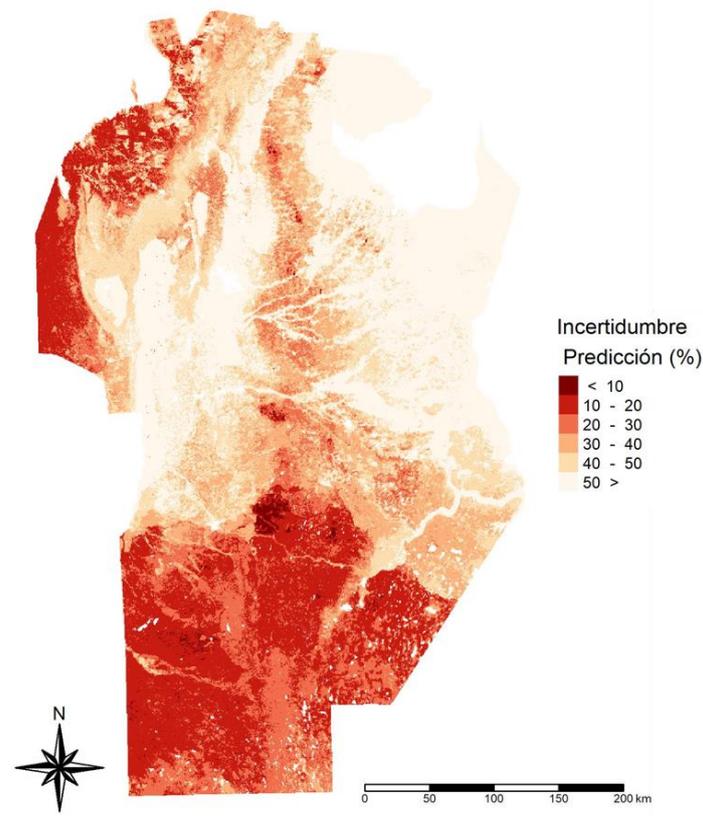


Figura 15. Mapa de incertidumbre de predicción del contenido de Arena (%) del suelo en la Provincia de Córdoba. Valor porcentual expresado como el desvío estándar de la predicción relativo al valor predicho.

## 6. Referencias Bibliográficas

- Breiman, L. 2001. Random Forests. *Mach. Learn.* 45(1): 5–32.
- Chen, T., and C. Guestrin. 2016. XGBoost. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM, New York, NY, USA. p. 785–794
- Córdoba, M., J.P. Carranza, M. Piometto, F. Monzani, and M. Balzarini. 2021. A spatially based quantile regression forest model for mapping rural land values. *J. Environ. Manage.* 289(November 2020):
- Dorji, T., I.O.A. Odeh, D.J. Field, and I.C. Baillie. 2014. Digital soil mapping of soil organic carbon stocks under different land use and land cover types in montane ecosystems, Eastern Himalayas. *For. Ecol. Manage.* 318(2014): 91–102.
- Guo, P.T., M.F. Li, W. Luo, Q.F. Tang, Z.W. Liu, et al. 2015. Digital mapping of soil organic matter for rubber plantation at regional scale: An application of random forest plus residuals kriging approach. *Geoderma* 237–238: 49–59.
- Hengl, T., M. Nussbaum, M.N. Wright, G.B.M. Heuvelink, and B. Gräler. 2018. Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. *PeerJ* 6: e5518.
- Kuhn, M., S. Weston, C. Keefer, and N. Coulter. 2016. *Cubist Models For Regression*. R Packag. Vignette R Packag. version 0.0 (1992).
- Malone, B.P., A.B. Mcbratney, B. Minasny, and G.M. Laslett. 2009. Geoderma Mapping continuous depth functions of soil carbon storage and available water capacity. *Geoderma* 154(1–2): 138–152.
- McBratney, A.B., M.L.M. Santos, and B. Minasny. 2003. On digital soil mapping. *Geoderma* 117(1–2): 3–52.
- Meinshausen, N. 2006. Quantile regression forests. *J. Mach. Learn. Res.* 7(Jun): 983–999.
- Nussbaum, M., K. Spiess, A. Baltensweiler, U. Grob, A. Keller, et al. 2018. Evaluation of digital soil mapping approaches with large sets of environmental covariates. *SOIL* 4(1): 1–22. doi: 10.5194/soil-4-1-2018.
- Piometto, M., C. García, and H. Morales. 2018. Mapa de Cobertura de Suelo (Land Cover) de Córdoba, Argentina. Su desarrollo y publicación en la IDE provincial. In: Reynoso, L. and Massera, C., editors, XIII Jornadas de Infraestructuras de Datos Espaciales de la República Argentina. *Infraestructuras de Datos Espaciales de la República Argentina*, San Juan, Argentina. p. 144–160
- Silatsa, F.B.T., M. Yemefack, F.O. Tabi, G.B.M. Heuvelink, and J.G.B. Leenaars. 2020. Assessing countrywide soil organic carbon stock using hybrid machine learning modelling and legacy soil data in Cameroon. *Geoderma* 367(September 2019): 114260.
- Teich, I., M.G. Roglich, M.L. Corso, and C.L. García. 2019. Combining earth observations, cloud computing, and expert knowledge to inform national level degradation assessments in support of the 2030 development agenda. *Remote Sens.* 11(24).
- Yigini, Y., G.F. Olmedo, S. Reiter, R. Baritz, K. Viatkin, et al. 2018. *Soil Organic Carbon Mapping Cookbook* 2nd edition (R. Olmedo, G.F., Reiter, S., Baritz, R., Viatkin, K. and Vargas, editor). FAO. Rome.
- Zhang, Q., G. Geng, S. Wang, A. Richter, and K. He. 2012. Satellite remote sensing of changes in NO<sub>x</sub> emissions over China during 1996–2010. *Chinese Sci. Bull.* 57(22): 2857–2864.
- Zhang, L., W. Zhou, and L. Jiao. 2004. Wavelet support vector machine. *IEEE Trans. Syst. Man, Cybern. Part B* 34(1): 34–39.



---

[mapascordoba.gob.ar](http://mapascordoba.gob.ar) [idecor.cba.gov.ar](http://idecor.cba.gov.ar)  
[idecor@cba.gov.ar](mailto:idecor@cba.gov.ar)