

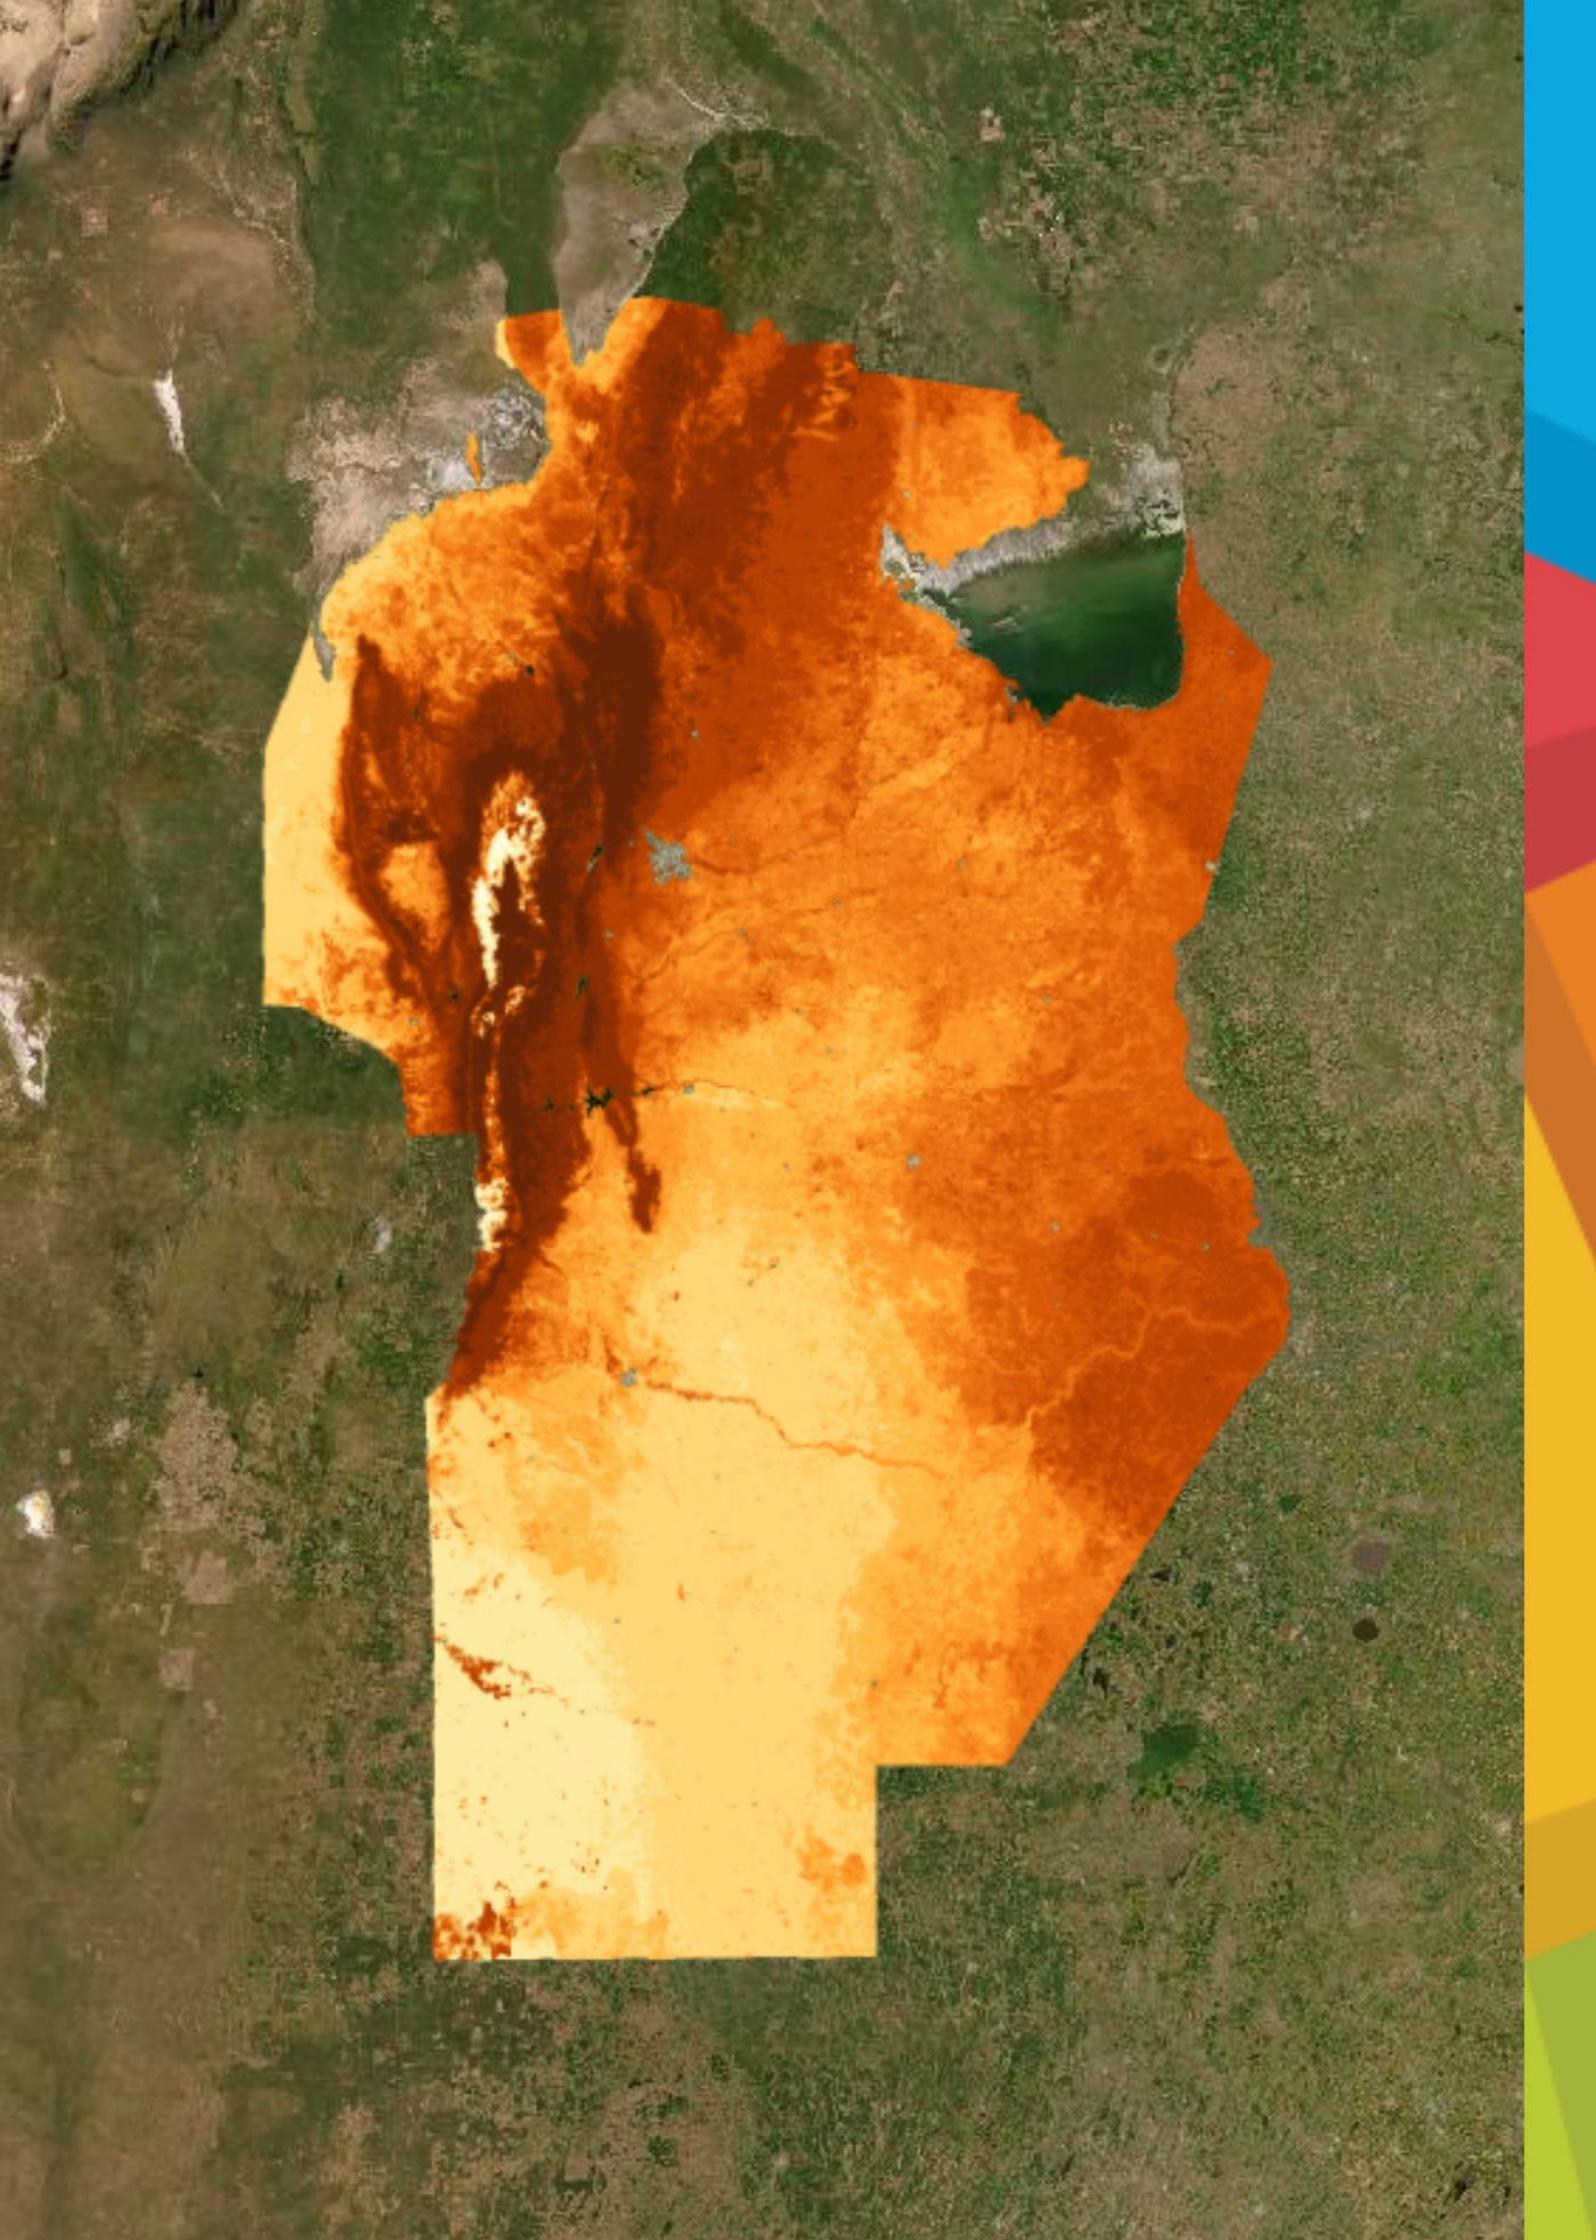
INFORME

MAPEO DE MATERIA ORGÁNICA DEL SUELO

EN LA PROVINCIA DE
CÓRDOBA

SEPTIEMBRE 2020

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



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 CONICET, FCA-UNC (responsable técnico).
- Hernán Morales, Luz Fuentes y Paula Álvarez, desarrollo de datos y covariables, IDECOR.
- Juan Pablo Carranza y Federico Monzani, apoyo metodológico, IDECOR.
- Mario Piumetto, Coordinador IDECOR, Gobierno de la Provincia de Córdoba.

Instituciones que dieron seguimiento al proceso y principal fuente de datos de suelo

- INTA Regional Córdoba.
- Secretaría de Agricultura de la Provincia de Córdoba.
- Instituto Multidisciplinario de Biología Vegetal - IMBIV CONICET.

Referentes por instituciones y colaboraciones

- Lautaro Faule, Verónica Bustos y Diego Pons, INTA Córdoba.
- María Paula Veliz y Pablo Candiani, Secretaría de Agricultura de la Provincia de Córdoba.
- Esteban Kowaljow, IMBIV CONICET.

Se agradecen las colaboraciones y aportes de Cesar García, Investigador Asistente CONICET, INA-CIRSA y Marcos Angelini, INTA.

Versión y Licencia

Esta es la Versión 1, 10 de septiembre del 2020.

MAPA DE MATERIA ORGÁNICA DEL SUELO DE LA PROVINCIA DE CÓRDOBA 2020. Está distribuido bajo una Licencia Creative Commons Atribución 4.0 Internacional. Libre para compartir, distribuir, copiar y adaptar.



Citar como: Córdoba M., Morales H., Fuentes L., Álvarez P., Carranza J., Monzani F., Piumetto M. Mapa de Materia Orgánica del Suelo 2020. Infraestructura de Datos Espaciales de Córdoba (IDECOR), septiembre 2020.

Aviso de uso

Los datos desarrollados en el marco del presente trabajo son parte del Mapa de Materia Orgánica del Suelo 2020, 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 del producto	7
3. Datos	7
4. Metodología.....	8
4.1. Covariables.....	9
4.2. Modelación	11
5. Resultados	12
6. Referencias Bibliográficas	15

1. Antecedentes

En el marco de un estudio integral de la dinámica territorial e inmobiliaria en la Provincia de Córdoba, llevado adelante por IDECOR para la Dirección General de Catastro, 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).

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. Entre las variables específicas modeladas, a partir de un primer conjunto de datos del Programa Buenas Prácticas Agropecuarias (BPA) de la Provincia de Córdoba, se desarrollaron mapas iniciales de diversas temáticas, entre ellas contenido de materia orgánica (MO) en suelo. Los mapas obtenidos a fines de 2018 fueron acotados, considerando el volumen de muestras utilizadas, las técnicas aplicadas y el tiempo disponible.

Como parte del plan de trabajo 2019-2020 de IDECOR, 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 metodológicos y considerando la inclusión, en el modelado, de covariables disponibles o desarrollables desde la IDE provincial.

En ese marco, la Secretaría de Agricultura de la Provincia facilitó el acceso a toda la base de datos del Programa BPA, como también INTA a sus datos disponibles. Se realizaron también, gestiones para integrar datos de instituciones públicas, como la Facultad de Cs. Agropecuarias (FCA) de la Universidad Nacional de Córdoba (UNC), el IMBIV (Instituto Multidisciplinario de Biología Vegetal, CONICET-UNC), la Universidad Nacional de Río Cuarto (UNRC) y de empresas privadas (colaboraron AGD, Seiker y Orbely).

Por otra parte, se trabajó 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), datos provistos por CONAE¹.

La versión inicial, realizada en 2018, se basó esencialmente en un modelado geoestadístico, mientras que los desarrollos iniciados en 2019 tuvieron mejoras en el proceso de modelado. Se incorporaron algoritmos de aprendizaje computacional que fueron ajustados siguiendo el esquema metodológico del Mapeo Digital de Suelo.

En noviembre de 2019, en la sede de INTA Córdoba, se realizó un taller con profesionales del INTA y la Secretaría de Agricultura de la Provincia de Córdoba, donde se presentó una síntesis de los avances realizados y el plan de finalización de una versión para su evaluación, prevista para el primer trimestre de 2020. En el mes de abril de 2020 se llevó a cabo una presentación del mapa de MO preliminar, en la cual se recibieron devoluciones de mejoras técnicas, incorporadas en la versión final.

¹ Con relación a datos de humedad en suelo, IDECOR está iniciando con el uso de datos SAOCOM y sus derivados, con el fin de incluirlos en modelados futuro.

El presente desarrollo no escapa a otras acciones y proyectos llevados adelante en la Provincia de Córdoba en este tema, 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 7.500 productores en un trabajo que contribuye al desarrollo sostenible de la actividad agropecuaria; y el mapeo de cobertura de suelo² (land cover) iniciados en 2018 por IDECOR, como herramienta de apoyo a diversos estudios territoriales en la provincia.

2. Alcance del producto

El Mapa de Materia Orgánica del Suelo en la Provincia de Córdoba informa los niveles de MO del suelo en el horizonte superficial (en %) 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 más de 3.200 muestras de suelo provenientes de organismos públicos provinciales, nacionales y empresas privadas, con un importante conjunto de covariables procesadas por la IDE provincial. El producto se complementa con un mapa de incertidumbre de la predicción, que permite ponderar en forma local la calidad de la misma. Se delimitaron zonas (máscaras) donde no se informan valores de MO, las que corresponden con manchas urbanas, cuerpos de agua o inundación recurrente y salinas.

3. Datos

Los datos provenientes de diversas fuentes fueron sistematizados y depurados. En una primera instancia los recolectados de perfiles de suelo o con más de una medición en profundidad, fueron estandarizados en una profundidad específica 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, quedando un 94% de los registros de muestras tomados entre los años 2016 y 2020. La base para el modelado se conformó con 3.219 observaciones (Figura 1), más 15 puntos auxiliares generados como datos de control en áreas de cobertura rocosa. La media de la muestra fue de 2.39 %, valor mayor a la mediana (2.19%). El coeficiente de variación fue del 56%. En un 25% de las observaciones los valores de MO fueron mayores a 2.70% y un porcentaje similar presentó valores menores a 1.73% (Tabla 1).

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 materia orgánica de suelo (MOS) de la Provincia de Córdoba.

n	Media	CV	Mín	Máx	P(25)	P(50)	P(75)
3219	2.39	56	0.34	13.20	1.73	2.19	2.70

<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>

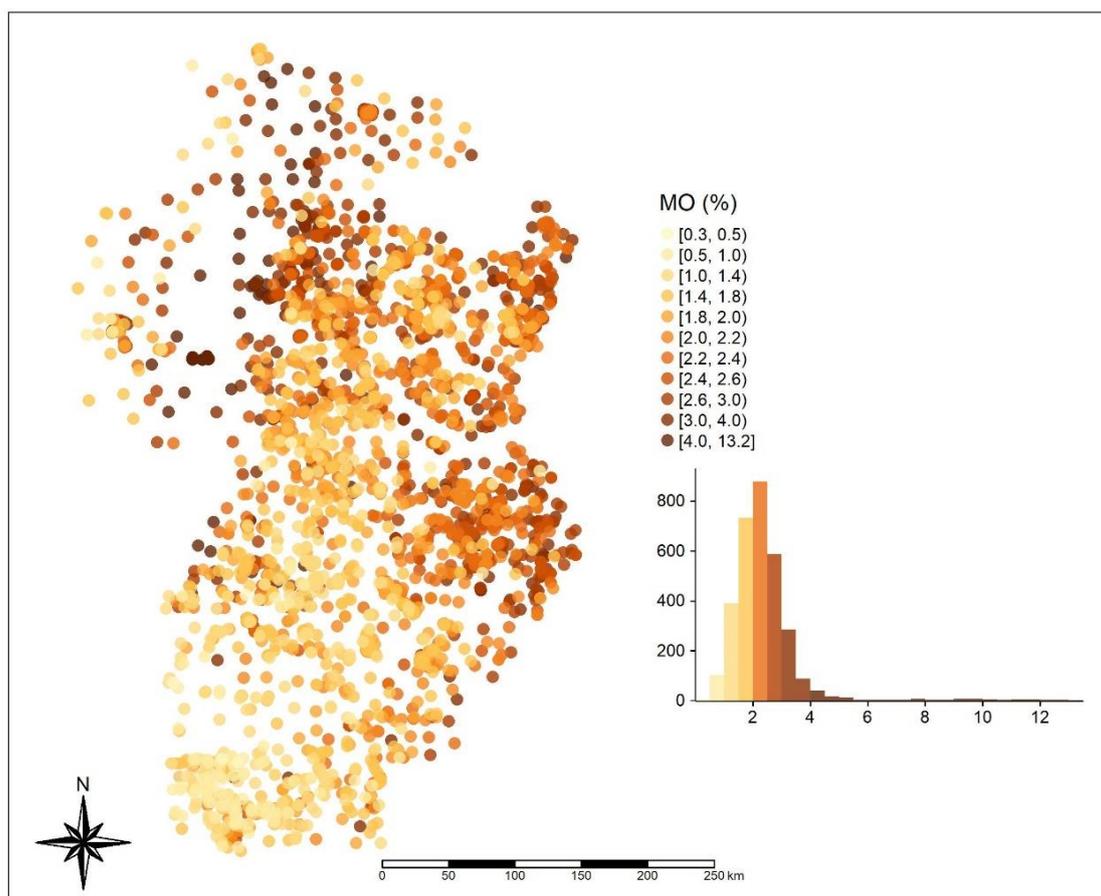


Figura 1. Distribución espacial de puntos de muestreo e histograma de frecuencias absolutas de valores de materia orgánica del suelo en la Provincia de Córdoba.

4. Metodología

El enfoque metodológico utilizado para la predicción de la MO 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 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 disponibilidad de un mapa de cobertura de suelo para la Provincia de Córdoba ha resultado 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 y no proporcionan suficiente detalle de 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 calculado con estas técnicas (Teich et al., 2019). Otro tipo de datos, particularmente útiles para predecir propiedades edáficas, es el obtenido 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 MO se encuentra en Tabla 2.

Para 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 se registraron los valores de cada una de las covariables calculadas. Estas mismas covariables se adicionaron a la base de muestras de 3.234 observaciones, para el ajuste de los modelos predictivos.

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

Tipo	Descripción variable	Fuente
Clima	Precipitación media anual	World Clim version 2
	Temperatura máxima anual	
	Temperatura media anual	
	Temperatura mínima anual	
	Radiación solar media	TerraClimate
	Déficit hídrico (media 2001-2020)	
	Índice de Severidad de Sequía (media 2001-2020)	
Evapotranspiración media mensual acum. (media 2001-2018)	MOD16	
Vegetación	NDVI mediana, serie 2001-2020	Producto MOD13Q1 V6 (Teich et al. 2019)
	NDVI DE, serie 2001-2020	
	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	
	Superficie en celda de Monte	
	Superficie en celda de Arbustales y matorrales	
	Superficie en celda de Pastizal natural	
	Superficie en celda de Pastizal con rocas o suelo desnudo	
	Superficie en celda de Pastizal con rocas	Land Cover 2017/2018
	Superficie en celda de Cultivos anuales de secano	(1 ha) (MapasCordoba)
	Superficie en celda de Pasturas implantadas	
	Superficie en celda de Pasturas naturales manejadas	
	Clase de cobertura de Suelo	
Suelo	Índice Productividad de suelo	
	Drenaje	
	Profundidad efectiva	
	Textura	Cartas de Suelo
	Alcalinidad	
	Salinidad	
	Tipo de suelo - Orden 1	
	Arcilla (Mapa MDS)	UNC + SISINTA + AGD
Topografía	Altura (m.s.n.m.)	
	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>)	MERIT DEM
	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>)	
Tiempo	Año toma de muestra	
Posición	Coordenadas x e y	

4.2. Modelación

Se implementaron versiones clásicas de técnicas geoestadísticas para la predicción espacial como kriging ordinario, regresión kriging y kriging con deriva externa (Hengl et al., 2003; Oliver and Webster, 2015). Se implementaron además algoritmos computacionales de aprendizaje automático. Entre ellos destacan los métodos basados en árboles como *Random Forest* (Breiman, 2001), *Quantile Regression Forest* (Meinshausen, 2006) y *Boosted Regression Tree* (Elith et al., 2008), *Support Vector Machine* (Zhang et al., 2004) y *Partial Least Square Regression* (Abdi, 2003). La implementación de estos algoritmos incluyeron 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 (Li et al., 2011; Guo et al., 2015; Silatsa et al., 2020).

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), error cuadrático medio (MSE), raíz cuadrada del error cuadrático medio (RMSE), error absoluto medio relativo a la media (MAPE) y porcentaje de varianza explicada (AVE).

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

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

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

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

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

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 y \bar{y} es el promedio general de los valores observados de MO.

Realizada la selección del modelo mediante estadísticas globales, se procedió al cálculo de la incertidumbre de la predicción o error de predicción, empleando la metodología sugerida en el contexto del mapeo digital de carbono orgánico a nivel mundial (Hengl et al., 2018; Yigini et al., 2018).

5. Resultados

Si bien las diferencias entre algunos de los métodos evaluados no fueron importantes, el algoritmo de *Quantile Regression Forest* con restricción espacial mostró un mejor desempeño (Tabla 3). El error de predicción promedio relativo a la media de los valores observados (RMSE, %) fue del 26 %, el error porcentual absoluto medio (MAPE) del 18,5%, mientras que la varianza explicada por el modelo fue del 78%.

Tabla 3. Evaluación de la capacidad predictiva del modelo implementado.

MSE	RMSE	RMSE (%)	MAPE	AVE (%)
0.39	0.62	26,1	18,5	78

En los valores predichos la media fue similar superior a la muestra (2.35% vs. 2.39%). El valor mínimo fue menor al de la muestra sin considerar puntos auxiliares en zona de roca (0.1% vs. 0.34%). Lo mismo se observó con el valor máximo (9.5% vs. 13.2%) y CV (34 % vs. 56%), mientras que los percentiles 25, 50 y 75 fueron similares respecto a los obtenidos en la muestra.

Tabla 4. Cantidad de puntos de predicción (*n pred*), 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 la predicción de materia orgánica del suelo (MOS) de la Provincia de Córdoba.

n pred	Media	CV	Mín	Máx	P(25)	P(50)	P(75)
624715	2.35	33	0.10	9.80	1.84	2.26	2.62

Del total de datos predichos menos del 0.1% tuvieron valores menores a 0.6% de MO mientras que un 15% tuvo valores mayores al 3%. Los valores predichos de MO se presentan en la Figura 2. Los valores más bajos (<0,6%) se ubicaron en la zona de sierras con cobertura predominante de tipo rocoso. En la zona de piedemonte se registraron los valores más altos (> 4%). Valores en el rango de 1% a 1.4% se ubicaron en la zona sudoeste, mientras que en el centro norte, noreste y sudeste se observan valores entre 2.4% y 3%.

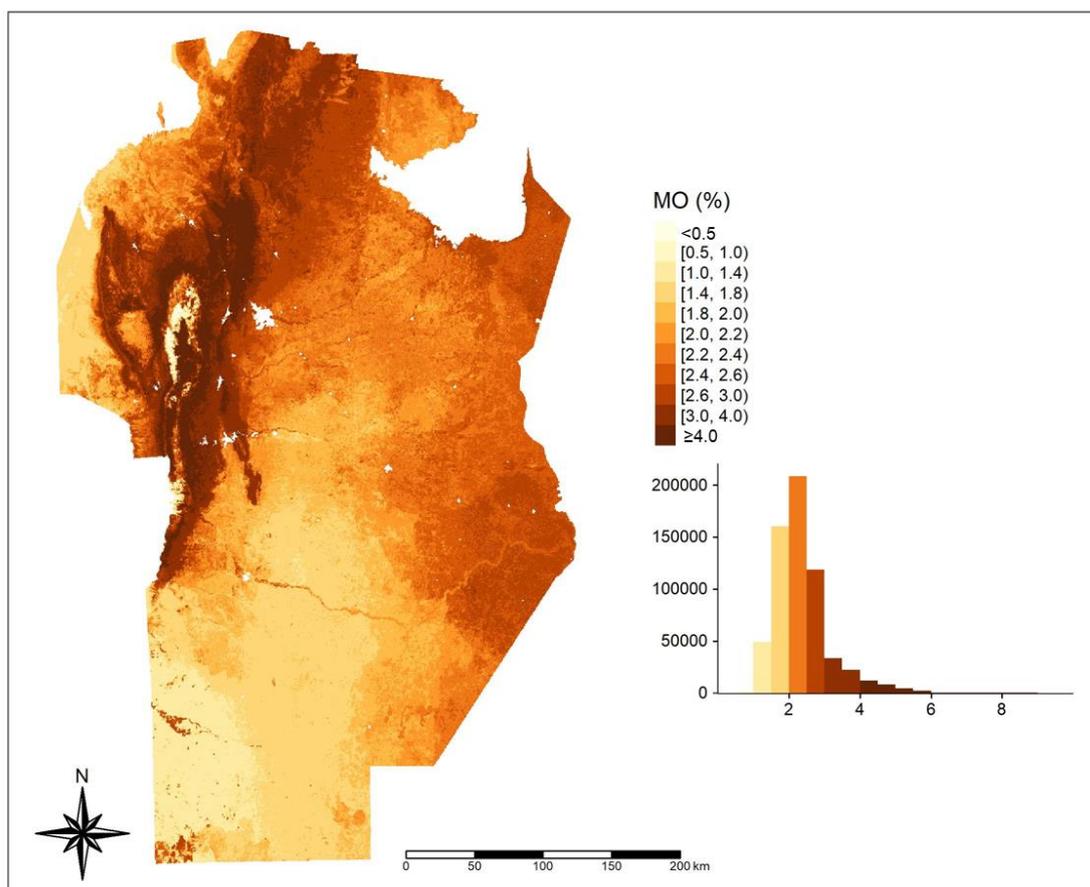


Figura 2. Mapa de predicción de la materia orgánica (MO) del suelo en la provincia de Córdoba, 2020.

Fuente: www.mapascordoba.gob.ar

En la Figura 3 se presenta el mapa del desvío estándar de la predicción relativo al valor predicho (incertidumbre de predicción en %) y los límites inferior y superior de la predicción (cuantil 0,05 y 0,95, respectivamente). La estadística descriptiva muestra que el promedio de la incertidumbre de predicción fue del 30%. Un 5% de los valores predichos tuvieron una incertidumbre alta (>45%), mientras que en el 85% de los datos predichos la incertidumbre de predicción fue menor al 40%. Los valores extremos se ubicaron en la zona de montaña y en un área pequeña con cobertura de monte en el sur de la provincia. El rango de incertidumbre alto en la zona noroeste de la provincia es coincidente con el hecho que en dicha zona se dispone de una menor densidad de muestras para realizar el estudio.

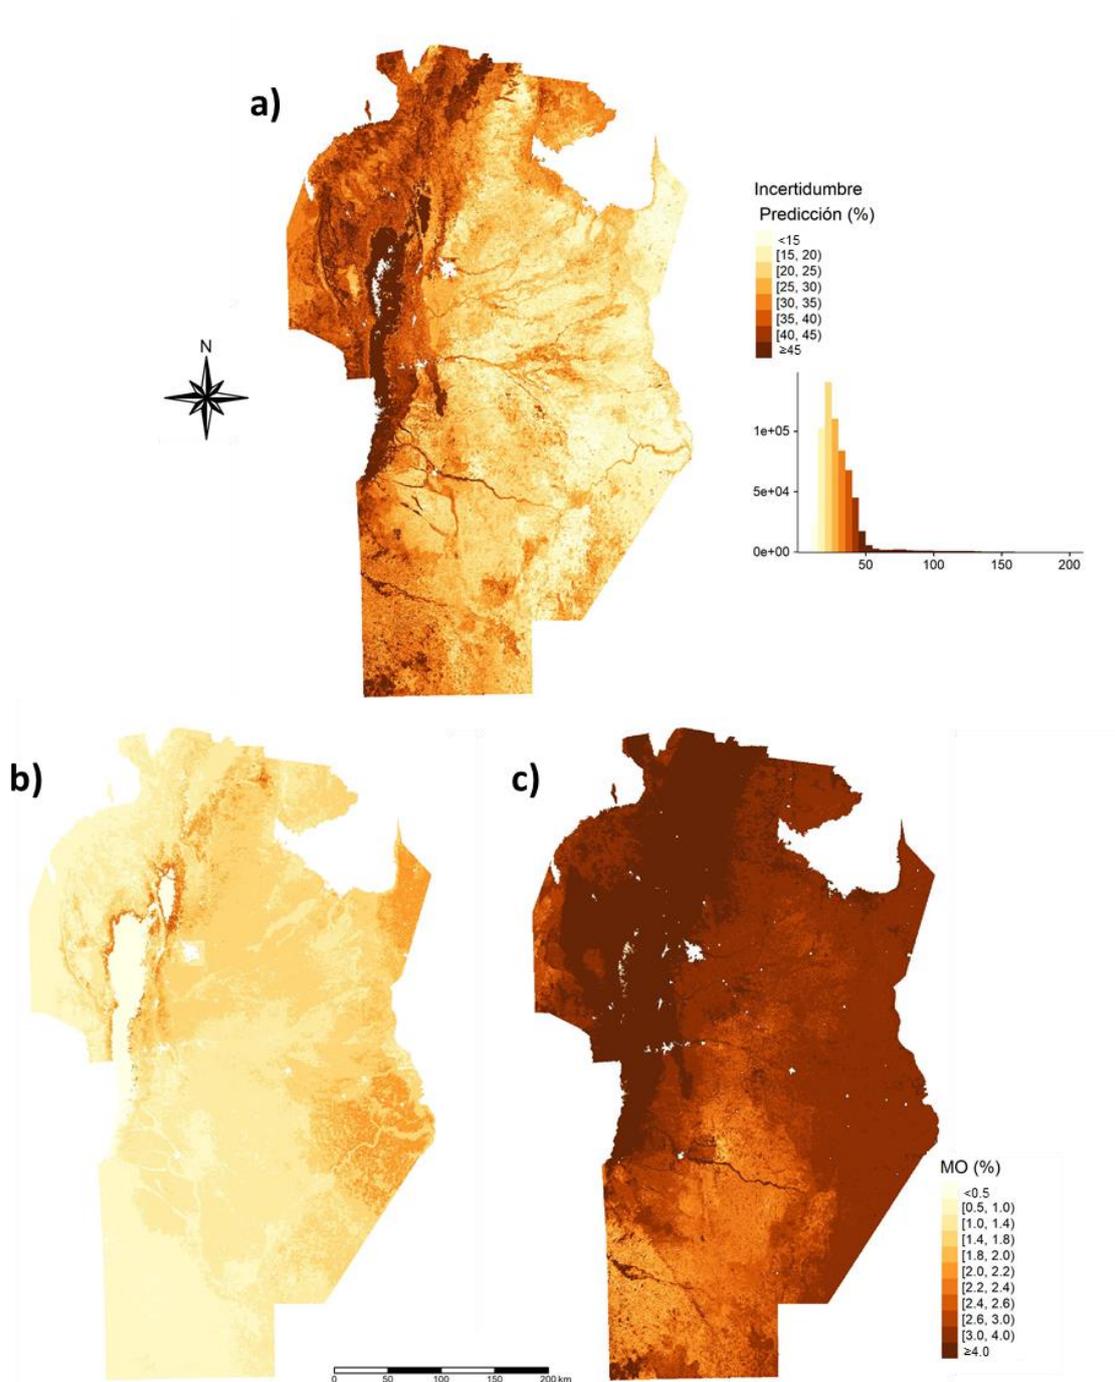


Figura 3. Mapa de incertidumbre de predicción de la materia orgánica (MO) del suelo en la Provincia de Córdoba. a) Incertidumbre de predicción relativa al valor predicho, b) Límite Inferior de Predicción, Cuantil 0,05, c) Límite Superior de Predicción, Cuantil 0,95.

6. Referencias Bibliográficas

- Abdi, H. 2003. Partial least square regression (PLS regression). *Encycl. Res. methods Soc. Sci.* 6(4): 792–795.
- Breiman, L. 2001. Random Forests. *Mach. Learn.* 45(1): 5–32. doi: 10.1023/A:1010933404324.
- 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.
- Elith, J., J.R. Leathwick, and T. Hastie. 2008. A working guide to boosted regression trees. (MI): 802–813. doi: 10.1111/j.1365-2656.2008.01390.x.
- 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., G. Heuvelink, and A. Stein. 2003. Comparison of kriging with external drift and regression-kriging. *Tech. note, ITC*: 17.
- 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.
- Li, J., A.D. Heap, A. Potter, and J.J. Daniell. 2011. Performance of Machine Learning Methods and Their Combinations with Ordinary Kriging and Inverse Distance Squared Predicting Seabed Mud Content across the Australian Margin II.
- 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.
- Oliver, A.M., and R. Webster. 2015. *Basic Steps in Geostatistics: The Variogram and Kriging*. Springer, Berlin.
- Piumetto, 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. XIII Jornadas IDERA (San Juan, Argentina).
- 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_x 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.



Ministerio de
FINANZAS



mapascordoba.gob.ar idecor.cba.gov.ar

idecor@cba.gov.ar