

# Mapa digital del perfil del carbono orgánico en los suelos de Andalucía, España

D. Armas<sup>1</sup>, M. Guevara<sup>2</sup>, D. Alcaraz-Segura<sup>1,3,4</sup>, R. Vargas<sup>2</sup>, M.A. Soriano-Luna<sup>5</sup>, P. Durante<sup>6,7</sup>, C. Oyonarte<sup>3,6,\*</sup>

(1) Departamento de Botánica, Instituto Interuniversitario de Investigación del Sistema Tierra en Andalucía (IISTA). Universidad de Granada, Av. Fuente Nueva s/n. 18071 Granada. España.

(2) Department of Plant and Soil Science, University of Delaware, 531 South College Ave., 152, Townsend Hall, Newark DE, EEUU, 19716.

(3) Centro Andaluz para la Evaluación y Seguimiento del Cambio Global (CAESCG). Universidad de Almería. Crta. Sacramento s/n. 04120 La Cañada, Almería. España.

(4) Iecolab. Universidad de Granada, Av. del Mediterráneo, 18006, Granada, España.

(5) Postgrado en Ciencias Forestales, Colegio de Post graduados. Carretera México-Tezcoco Km. 36.5, Montecillo. Tezcoco 56230, Estado de México.

(6) Departamento de Agronomía, Edif. CITEIIB. Universidad de Almería. 04120 La Cañada, Almería. España.

(7) Agresta Sociedad Cooperativa. C/ Duque de Fernán Núñez, 2, 1º. 28012 Madrid. España.

\* Autor de correspondencia: C. Oyonarte [[coyonart@ual.es](mailto:coyonart@ual.es)]

> Recibido el 06 de julio de 2017 - Aceptado el 19 de septiembre de 2017

**Armas, D., Guevara, M., Alcaraz-Segura, D., Vargas, R., Soriano-Luna, M.A., Durante, P., Oyonarte, C. 2017. Mapa digital del perfil del carbono orgánico en los suelos de Andalucía, España. *Ecosistemas* 26(3):80-88. Doi.: 10.7818/ECOS.2017.26-3.10**

Conocer y comprender la distribución espacial del carbono orgánico del suelo (COS) es necesario para el manejo de este reservorio del ciclo global del carbono, y la planificación de acciones para mitigar el cambio climático. El objetivo fue generar mapas de porcentaje de COS en Andalucía mediante modelos consistentes, cuantificando la incertidumbre asociada, e identificando los factores que controlan su variabilidad. Se empleó una base de datos patrimonial con 1500 perfiles de suelo, y 20 covariables ambientales como factores predictivos descriptores del clima, topografía, y atributos funcionales de los ecosistemas. Se utilizó una combinación de modelos lineales y un ensamble de árboles de regresión combinado con geoestadística para estimar la distribución espacial (horizontal y vertical) del COS. Se generaron mapas de la distribución del COS a seis intervalos de profundidad (0-5, 5-15, 15-30, 30-60, 60-100 y 100-200 cm). La varianza explicada por los modelos osciló entre el 57 y 63.0 %, pero con alta incertidumbre en los sitios con mayor concentración de COS (hasta el 8 %). La variabilidad del COS respondió a una compleja combinación de factores, siendo la precipitación el predictor más importante en todas las profundidades, el EVI (Indicador de la productividad) en los horizontes superficiales, y la topografía en los profundos. Los mapas y modelos producidos resultan herramientas útiles para la gestión ambiental, al facilitar la actualización periódica de los contenidos del COS y aportar información para el manejo de este reservorio.

**Palabras clave:** distribución vertical del carbono; mapa de incertidumbre; modelos lineales; bosques aleatorios (*random forest*); *quantile regression forests* (QRF)

**Armas, D., Guevara, M., Alcaraz-Segura, D., Vargas, R., Soriano-Luna, M.A., Durante, P., Oyonarte, C. 2017. Digital map of the organic carbon profile in the soils of Andalusia, Spain. *Ecosistemas* 26(3):80-88. Doi.: 10.7818/ECOS.2017.26-3.10**

To know and understand the spatial distribution of soil organic carbon (SOC) is the first step for management of this important pool in the global carbon cycle, and to develop actions to address climate change. The objective of this work was to generate maps of percent SOC across Andalucía through the use of consistent models, quantifying the associated uncertainty and identify controls of the spatial variability. We used a legacy soil profile collection with 1500 soil profiles and 20 environmental covariates as prediction factors for climate, topography, and ecosystem functional attributes related to the dynamic of primary production. A combination of linear models and an ensemble of regression trees coupled with geostatistics was used to estimate the spatial distribution (horizontal and vertical) of SOC, maps of SOC distribution across six soil depths (0-5, 5-15, 15-30, 30-60, 60-100 y 100-200 cm). Explained variance of our models varied between 57 to 63 %, with high uncertainty at sites with the highest values of SOC (up to 8 %). The variability of SOC corresponded to a complex interaction of factors, whereas precipitation is an outstanding predictive factor across all depths, annual primary production (EVI) at the superficial horizons, and topography across deep horizons. Generated maps result in a useful tool for environmental policy, because they facilitate the periodical update of SOC and provide information for the management of this pool.

**Key words:** carbon vertical distribution; uncertainty mapping; lineal models; *random forests*; *quantile regression forests* (QRF)

## Introducción

Los suelos son el mayor de los reservorios de carbono en los ecosistemas terrestres con aproximadamente 1500 Gt C, el doble que la vegetación y el triple que la atmósfera (Bert et al. 2005). Ocupan una posición crucial en la regulación del ciclo del carbono, señalándose como un componente básico en el control del cambio climático ya que dependiendo del uso y manejo pueden actuar como fuentes o sumideros de carbono atmosférico (Lal 2004). Aunque existe una estima global del carbono almacenado en los suelos, que oscila entre 2300 y 3300 Gt C, y se conocen en gran medida los factores ambientales que controlan su dinámica (Lal 2001), no existe un conocimiento detallado acerca de la variabilidad espacial o de las emisiones asociadas a cambios de uso y cobertura del suelo (Scharlemann et al. 2014), aspectos que resultan relevantes para la formulación de políticas públicas en el contexto del control del cambio climático.

La variabilidad espacial y temporal del contenido de carbono orgánico del suelo (COS) depende de la interacción de distintos factores formadores de suelo como la topografía, el clima, la vegetación y el uso y manejo de la tierra así como de otras propiedades fisicoquímicas del suelo (Batjes 2016). Esta complejidad hace que la elaboración de mapas de COS por estimación directa resulte costosa y lenta. Sin embargo, el estudio de las relaciones entre los valores de COS medidos y los factores establecidos en la ecuación de estado de los factores formadores del suelo (Jenny 1941), facilita la generación de mapas digitales continuos derivados de modelos predictivos (Gessler et al. 1995; McBratney et al. 2003), así como sus incertidumbres asociadas (Viscarra-Rossel et al. 2015). La cartografía digital ofrece una aproximación flexible para generar predicciones espaciales de COS empleando los datos provenientes de descripciones patrimoniales de perfiles de suelo. Estas bases de datos generalmente son una combinación de diversos muestreos de suelo, de distintas investigaciones en diferentes periodos de tiempo (Minasny et al. 2013).

La elaboración de estos mapas digitales de COS requiere herramientas para analizar la variabilidad espacial. Métodos como la geoestadística (*Kriging*) permiten interpolar valores de COS a sitios sin información disponible empleando para ello el supuesto de autocorrelación espacial (Webster y Oliver 2007; Cruz-Cárdenas 2014). Sin embargo, las técnicas de inteligencia artificial basadas en el aprendizaje supervisado se han mostrado más eficientes para modelar el COS (Hengl et al. 2014), aunque debido a su complejidad (e.g. no lineales) sus resultados son más difíciles de interpretar en términos ecológicos (Hastie et al. 2008; Viscarra-Rossel y Behrens 2010; James et al. 2013). Las técnicas de aprendizaje supervisado, como los ensambles de árboles de regresión tipo *random forest* (Breiman 2001), suelen preferirse para modelar relaciones complejas entre covariables y propiedades del suelo porque tienden a generar mejores predicciones (Grimm et al. 2008; Blanco 2015; Rial et al. 2015), y no tienen supuestos asociados a la estructura espacial de los datos como la geoestadística. *Random forest* es un método flexible con alto poder predictor, si bien su interpretabilidad es limitada (Richardson et al. 2017).

A nivel global, existe información espacialmente explícita disponible sobre el COS (Hengl et al. 2017), incluida la variabilidad vertical a lo largo del perfil (Willaarts et al. 2016), aunque esta información muestra elevados niveles de incertidumbre (Stockmann et al. 2015; Folberth et al. 2016). La incertidumbre del COS depende de inconsistencias entre las bases de datos empleadas y la complejidad de las relaciones entre el suelo y su ambiente de formación a la escala global (O'Rourke et al. 2015). La incertidumbre en la información espacial de carbono orgánico es la información sobre la variabilidad de COS que no podemos explicar dados los datos y covariables disponibles. La incertidumbre en los modelos de COS podría estar afectando nuestra capacidad de detectar cambios en el clima y sus efectos en la productividad de la vegetación (Folberth et al. 2016).

En España, varios trabajos han estimado el COS a escala nacional y regional basándose en diferentes bases de datos y esquemas metodológicos. Doblas-Miranda et al. (2013) utilizan una base de datos patrimonial para estimar mediante modelos lineales el COS a 1 m de profundidad, sin diferenciación entre horizontes. Rodríguez-Martín et al. (2016) se basan en la información de capas arables para elaborar un mapa de carbono superficial, utilizando modelos geoestadísticos. A nivel regional, la información del COS en España es escasa y dispersa, pero se encuentran trabajos como el mapa de COS de Galicia (Rodríguez-Lado y Martínez-Cortizas 2015) y el de Murcia (Blanco 2015), ambos modelizados para los primeros 30 cm de suelo y generados, respectivamente, mediante técnicas de regresión por mínimos cuadrados y *random forest*. Muñoz-Rojas et al. (2012) genera el mapa del COS de Andalucía a partir de una base de datos patrimonial de 1400 perfiles y un mapa de tipos de usos mediante asignación de valores a polígonos según las tipologías de usos incluidas. Calvo de Antas et al. (2015) analizan la relación de la densidad y el stock de carbono en los suelos del nordeste español, generando mapas de estas variables para los 30cm superficiales mediante aplicaciones SIG. La mayoría de los trabajos no incluyen información de la incertidumbre asociada a los valores estimados. Blanco (2015), así como Rodríguez-Lado y Martínez-Cortizas (2015), incluyen el cálculo de la incertidumbre para cada dato estimado, pero esa información no es espacialmente explícita.

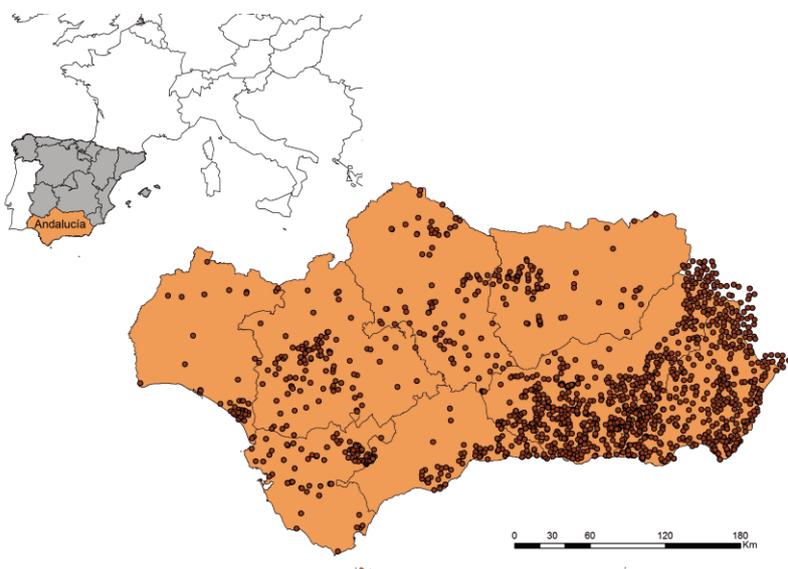
Incrementar los niveles de precisión y exactitud de las predicciones del COS, y cuantificar la incertidumbre asociada a estas predicciones son las motivaciones principales de este trabajo. A la vez pretendemos establecer los controles de variabilidad espacial del COS a diferentes profundidades, prestando especial atención a variables dinámicas que faciliten la estima de los cambios en los stocks a escalas temporales compatibles con su seguimiento y la toma de decisiones sobre su gestión. Entendemos que mejorar la calidad de la información disponible, en este caso para el territorio andaluz, podría facilitar la capacidad de planificar mejor las acciones de manejo del COS requeridas para mitigar los efectos del cambio climático.

Como hipótesis de trabajo establecimos que, con la información de campo disponible (e.g. descripciones de perfiles de suelo), la aplicación de un enfoque de aprendizaje supervisado (e.g., *random forest*), sustentado con modelos lineales y geoestadística básica, se podría incrementar los niveles de estimación de la actual información geoespacial de COS, a la vez que mantendría la interpretabilidad de los factores que lo controlan. Este trabajo se basa en la utilización de una extensa base de datos patrimonial de Andalucía a partir de la cual, y mediante un enfoque de mapeo digital de suelos, se plantean como objetivos (i) generar mapas del porcentaje del COS a diferentes profundidades en Andalucía, (ii) identificar los factores que controlan su variabilidad a cada profundidad, y (iii) aportar información espacialmente explícita de la incertidumbre asociada a los modelos predictivos generados.

## Materiales y métodos

### Área de estudio

Andalucía es una región del sur de España con una extensión aproximada de 87 000 km<sup>2</sup> (Fig. 1), con clima Mediterráneo y un claro gradiente longitudinal en la distribución de precipitaciones, con un máximo de 2000 y un mínimo de 200 mm·año<sup>-1</sup>, decreciendo desde el Oeste (Atlántico) al Este (Mediterráneo). La temperatura media anual varía entre 5 y 18°C, respondiendo a un gradiente altitudinal. El relieve es complejo, con una variedad de paisajes y un gran rango altitudinal entre 0 a 3479 m. Las tipologías de suelos más comunes son Cambisoles (33%), Regosoles (20%), Luvisoles (13%) y Leptosoles (11%) (De la Rosa 1984). Respecto al uso, aproximadamente un 44% de la región está ocupada por zonas agrícolas y un 51% por áreas naturales, destacando matorrales y bosques esclerófilos y de coníferas (Bermejo et al. 2011).



**Figura 1.** Localización del área de estudio (Andalucía) y ubicación de los perfiles incluidos en la base de datos de suelos.

**Figure 1.** Location of the study area (Andalusia) and of the profiles of the soils database.

### Bases de datos

Se usó una base de datos de 1551 perfiles recopilados por la Junta de Andalucía (CMAyOT), que constituyen un legado patrimonial procedente de diversos proyectos, principalmente cartográficos, realizados en el territorio entre las décadas de los '60 y '90. Para su inclusión en la base de datos se consideró la existencia de una correcta georreferenciación, información sobre los límites de los horizontes, y que la determinación carbono orgánico hubiera sido realizada mediante metodologías basadas en Walkley-Black.

Los factores ambientales incluidos como variables predictivas en los modelos fueron: variables climáticas (precipitación y temperatura), variables topográficas derivadas de un modelo digital de elevación (MDE) y atributos funcionales de los ecosistemas relacionados con la dinámica estacional de la producción primaria obtenidos a partir de imágenes del satélite MODIS-Terra. También se incluye la variable usos del suelo, según la clasificación de la Junta de Andalucía y la actualización de 2007 (Tabla 1). La información ambiental fue estandarizada cartográficamente al Sistema de Referencia de Coordenadas ETRS89, proyección UTM Huso 30N (EPSG: 25830), la misma que la utilizada en la localización de los perfiles. Con fines comparativos (e.g., Global - local), las covariables del COS fueron armonizadas espacialmente con el sistema SoilGrids250m (Hengl et al. 2017) en una grilla regular de 250m de resolución espacial (compatible con el producto MODIS MOD13Q1).

El cálculo de las variables topográficas (de acuerdo con Moore et al. 1991; Gallant y Dowling 2003; Wilson 2012) se llevó a cabo en SAGA GIS (Conrad et al. 2015), y fueron: 1. *Analytical Hillshading*, 2. *Slope*, 3. *Aspect*, 4. *Cross-Section Curvature*, 5. *Longitudinal Curvature*, 6. *Convergence Index*, 7. *Closed Depressions*, 8. *Catchment Area*, 9. *Topographic Wetness Index*, 10. *Ls Factor*, 11. *Channel Network Base Level*, 12. *Vertical Distance to Channel Network*, 13. *Valley Depth*, 14. *Relative Slope Position*, 15. *Multiresolution Valley Bottom Flatness index*, y 16. *Multiresolution Ridge Top Flatness index*. Para los atributos funcionales de los ecosistemas, se analizó la serie temporal 2003-2015 del índice de vegetación mejorado (*Enhanced Vegetation Index* –EVI–; Huete et al. 2002) obtenido del producto MOD13Q1 del satélite MODIS-Terra. Se calcularon dos descriptores integradores del funcionamiento ecosistémico en la Península Ibérica: la media anual de EVI, como estimador de la producción primaria anual, y el coeficiente de variación estacional, como indicador de la estacionalidad de la vegetación (Alcaraz-Se-gura et al. 2009).

### Estandarización a profundidades específicas

La base de datos patrimonial fue depurada de errores en la designación y profundidades de los horizontes edáficos empleando rutinas de pedología cuantitativa (Beaudette et al. 2013). Posteriormente mediante funciones de suavizado de áreas equivalentes (Bishop et al. 1999; Malone et al. 2009) se estandarizaron los valores de COS en 6 profundidades específicas (0-5, 5-15, 15-30, 30-60, 60-100 y 100-200 cm), siguiendo la discretización vertical señalada en las especificaciones de GlobalSoilMap para el mapa global de suelos (Arrouays et al. 2014). Se utilizó el método de funciones de suavizado de áreas equivalentes, o 'equal-area (mass preservative) splines', el cual asume que la variación de las propiedades de un perfil de suelo es continua (Malone et al. 2009).

### Modelos de variabilidad espacial

Para seleccionar las covariables con mayor poder predictivo del COS, se usaron regresiones lineales múltiples mediante el coeficiente de Pearson de la matriz de correlación, y se empleó el factor de inflación de la varianza (VIF) para identificar la redundancia estadística de los modelos (Heiberger y Holland 2004). Después de probar todas las combinaciones posibles e interacciones entre predictores, fueron seleccionadas aquellas variables que mejor explicaron la variabilidad del COS (e.g., menor VIF y mayor  $R^2$ ).

A continuación, para obtener mapas digitales del COS, el algoritmo de predicción tomó forma de un ensamble de árboles de regresión tipo *random forest* (Breiman 2001), considerando la estructura espacial de sus residuales para mejorar la capacidad predictiva, siguiendo a Hengl et al. (2004). *Random forest* es uno de los algoritmos predictivos más eficientes en los campos de aprendizaje supervisado (Fernández-Delgado et al. 2014). Para facilitar la interpretación de los resultados, se utilizaron exclusivamente las covariables previamente seleccionadas mediante la regresión lineal múltiple. Los modelos fueron sometidos a una estrategia de validación cruzada dejando conjuntos del diez por ciento de datos fuera de cada iteración, como sugiere Kohavi (1995). Para conocer la eficiencia de los modelos, se calcularon la raíz cuadrada del error cuadrático medio (*Root Mean Square Error* –RMSE–) y la varianza explicada ( $R^2$ ). Para estimar la incertidumbre de las predicciones de COS, se empleó la técnica descrita por Meinshausen (2006), que permite estimar la distribución condicional completa (la respuesta) de los datos a las covariables disponibles en el bosque de árboles de regresión generado. La incertidumbre se representó como la desviación estándar de esta distribución calculada para cada valor estimado (por pixel).

**Tabla 1.** Origen y características de la información ambiental utilizada como covariables para la generación del modelo del carbono orgánico del suelo (COS).

**Table 1.** Origin and characteristics of the environmental information used as input covariables in soil organic carbon (SOC) modelling.

Variables <sup>(1)</sup>	Fuente	Resolución	Descripción
MDE	IGN	200m	Variación de la altitud, utilizado para cálculo de variables topográficas
PP	REDIAM Junta de Andalucía	100m	Media anual precipitaciones (mm), periodo 1971-2000
TP	REDIAM Junta de Andalucía	100m	Media anual temperatura (°C), periodo 1971-2000
EVI	MODIS-Terra (MOD13Q1)	230m	Media anual índice de vegetación, periodo 2003-2015
CV_EVI	MODIS-Terra (MOD13Q1)	230m	Coefficiente variación estacional del índice de vegetación, periodo 2003-2015
USOS DEL SUELO	REDIAM Junta de Andalucía	1:25.000	Mapa de usos y coberturas vegetales del suelo de Andalucía (MUCVA).

<sup>(1)</sup> MDE: Modelo digital de elevaciones. PP: Precipitación media anual. TP: Temperatura media anual. EVI: Media anual del índice de vegetación *Enhanced Vegetation Index* (EVI). CV\_EVI: Coeficiente de variación estacional del EVI.

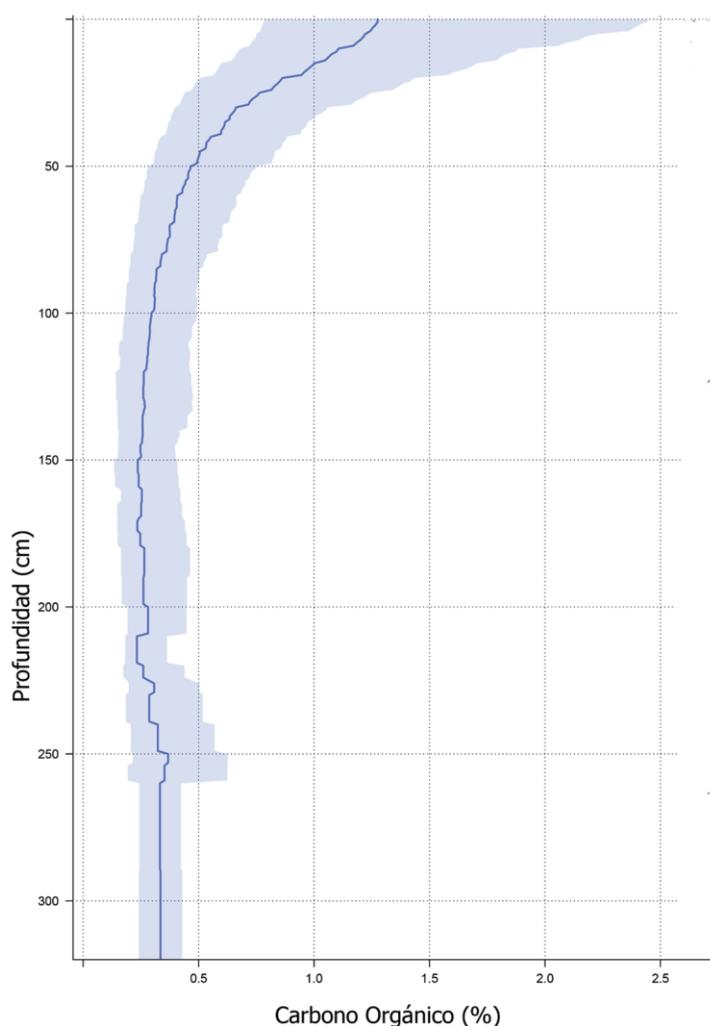
## Resultados

Tras la depuración de errores se mantuvieron para el análisis 3953 datos de COS distribuidos en 807 perfiles (Fig. 1), siendo el error más frecuente detectado la falta de consistencia en los límites de profundidad de los horizontes. Los valores de carbono estandarizados a las profundidades consideradas mostraron que la variabilidad y contenido de COS entre perfiles disminuye a medida que incrementa la profundidad (Fig. 2), con valores medios entre 6.25% en el horizonte superficial (0-5 cm) y 0.46% en el horizonte más profundo (>100 cm).

La relación del COS con las covariables consideradas cambia con la profundidad (Tabla 2). En los horizontes superficiales (0-30 cm), la precipitación y el índice de verdor de la vegetación (media de EVI), seguidas por el *Multiresolution Valley Bottom Flatness index* (vinculado a las dimensiones espaciales de los valles y zonas de acumulación), resultan las variables mejor correlacionadas con el COS. En los horizontes profundos (>30cm), la precipitación y las variables topográficas son las que más covarían con el COS.

Las regresiones lineales múltiples mostraron la mayor varianza explicada de COS en superficie, mientras que desciende considerablemente en profundidad. La Tabla 3 muestra los resultados de los modelos elaborados, incluyendo la mejor combinación de variables obtenida en los modelos lineales, y la varianza explicada. Los modelos basados en la técnica *random forest* presentan valores altos de varianza explicada a cualquier profundidad, entre el 57 y 63%. En pruebas realizadas con todas las covariables disponibles (20) encontramos que la varianza explicada incluso disminuye, en promedio al 58% (considerando todas las profundidades). La aproximación utilizada para la selección de variables reduce la complejidad del modelo (incrementa su interpretabilidad) sin sacrificar varianza explicada. La incorporación de la variable usos del suelo en los modelos no mejora apreciablemente su capacidad predictora, manteniéndose prácticamente la varianza explicada, entre el 61 y 65%, y el RMSE, alrededor del 2.15.

Las predicciones de COS de Andalucía a diferentes profundidades muestran valores máximos de 8% de COS en superficie, con un reconocible e interpretable patrón espacial (Fig. 3). En general se aprecia una disminución de Oeste a Este siguiendo el mismo patrón que la distribución de la precipitación, así como un marcado patrón geográfico basado en la orografía regional (grandes sistemas montañosos y valles). Este patrón espacial es claro a cualquiera de las profundidades consideradas, aunque se difumina al incrementar la profundidad.



**Figura 2.** Distribución vertical promedio del carbono orgánico en el suelo (COS) en Andalucía. Se representa el perfil medio de los suelos incluidos en la base de datos. La línea marca la mediana, y el área delimita los percentiles 25 y 75.

**Figure 2.** Vertical distribution of the average soil organic carbon (SOC) in Andalusia. Average profile of the soils database. The line shows the median and the grey area the 25th and 75th percentiles.

**Tabla 2.** Valores del coeficiente de correlación de Pearson obtenidos en la matriz de correlación entre covariables y COS en Andalucía, para cada profundidad del suelo considerada. En negrita los valores significativos (al 95%), y sombreados las tres variables con mayor significación para cada profundidad.

**Table 2.** Pearson correlation coefficients of the covariables-COS correlation matrix, at each soil depth in Andalucía. Significant values (for a 95% confidence interval) in bold, and the three most significant variables for each soil depth, shaded.

	AH	SL	AS	CSC	LC	CI	TWI	LsF	CNBL	VD	RSP	MRVBF	MRRTF	EVI	CV_EVI	PP	TP
0-5	0.01	-0.04	0.18	<b>-0.14</b>	-0.07	<b>-0.19</b>	-0.06	-0.04	<b>0.22</b>	0.15	-0.04	0.15	<b>0.66</b>	<b>0.50</b>	-0.03	<b>0.7</b>	0.02
5-15	0.08	0.15	<b>0.25</b>	0.01	-0.11	-0.1	-0.11	-0.18	0.19	0.19	-0.04	0.18	<b>0.43</b>	<b>0.52</b>	-0.2	<b>0.53</b>	-0.05
15-30	0.08	-0.01	0.21	<b>-0.24</b>	0.06	-0.15	-0.05	-0.09	0.2	<b>0.22</b>	-0.03	<b>0.22</b>	<b>0.41</b>	<b>0.21</b>	-0.03	<b>0.41</b>	-0.06
30-60	0.15	-0.06	0.17	0.001	-0.03	-0.18	-0.01	-0.05	0.16	<b>0.27</b>	-0.03	<b>0.22</b>	<b>0.25</b>	0.16	0.02	<b>0.28</b>	-0.12
60-100	<b>0.22</b>	<b>-0.19</b>	<b>0.32</b>	0.08	<b>0.23</b>	0.15	-0.03	-0.12	<b>0.27</b>	<b>0.43</b>	-0.05	<b>0.38</b>	<b>0.45</b>	0.09	-0.02	<b>0.48</b>	-0.2
100-200	-0.08	-0.07	<b>-0.18</b>	0.08	-0.06	0.17	<b>0.24</b>	<b>0.13</b>	-0.2	-0.08	<b>0.15</b>	-0.04	0.05	-0.05	<b>0.11</b>	-0.01	0.06

AH: Analytical hillshading. SL: Slope AS: Aspect. CSC: Cross-Section Curvature. LC: Longitudinal Curvature. CI: Convergence index. TWI: Topographic wetness index. LsF: Ls Factor. CNBL: Channel network base level. VD: Valley depth. RSP: Relative slope position. MRVB: Multiresolution valley bottom flatness index. MRRTF: Multiresolution ridge top flatness index. EVI: Media anual del Enhanced Vegetation Index. CV\_EVI: Coeficiente de variación estacional del EVI. PP: Precipitación. TP: Temperatura

**Tabla 3.** Varianza explicada y raíz cuadrada del error cuadrático medio (RMSE) de los modelos de estimación del carbono orgánico del suelo (COS) para cada profundidad, usados para la elaboración de los mapas de densidad de carbono en Andalucía.

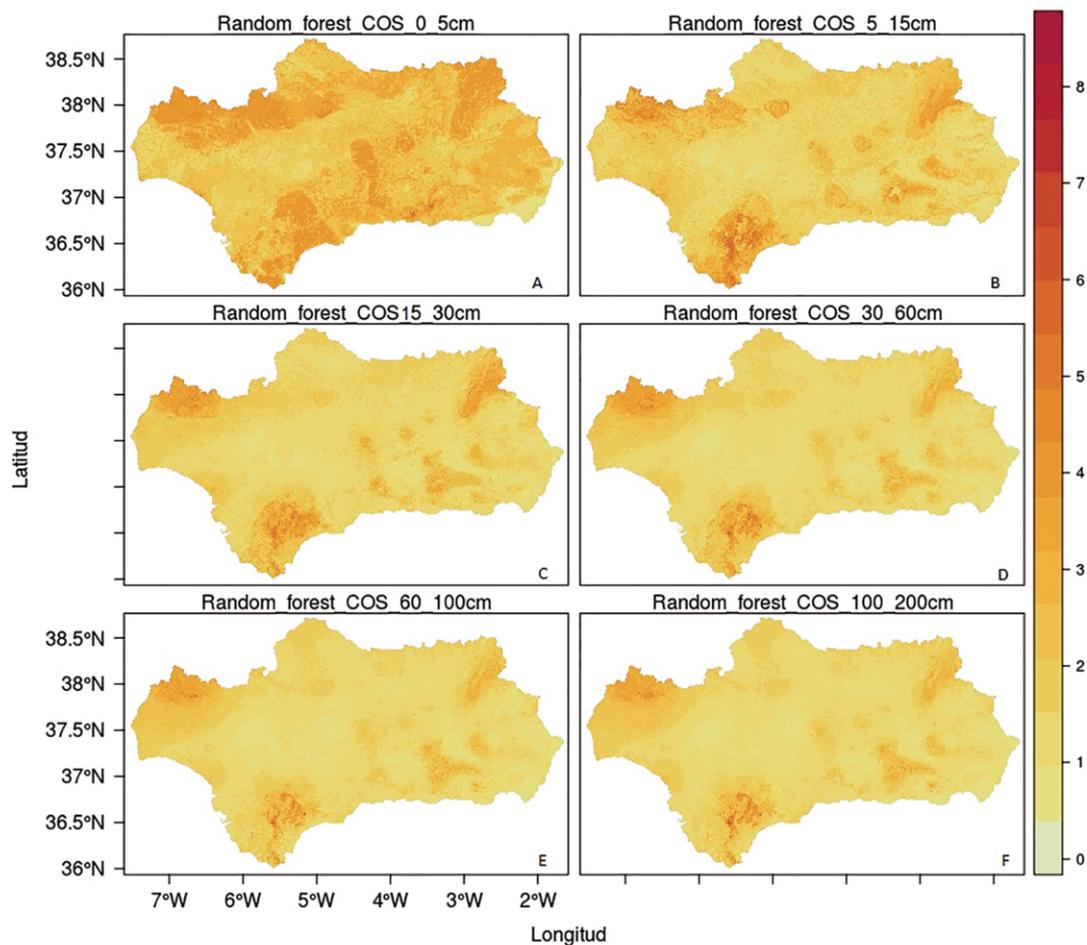
**Table 3.** Explained variance and RMSE of the COS models at each soil depth which were used to model the carbon density in Andalucía.

Profundidad (cm)	Variables incluidas <sup>(1)</sup>	Modelo <sup>(2)</sup>	Varianza explicada (%)	RMSE
0-5	CSC, CD, EVI, PP	LM	50.0	7.76
	CSC, CD, EVI, PP	RF	62.0±0.44	2.15± 0.01
	CSC, CD, EVI, PP, US	RF	62.0±0.48	2.15± 0.02
5-15	AS, MRRTF, EVI, PP	LM	27.0	4.66
	AS, MRRTF, EVI, PP	RF	63.0±0.46	2.16± 0.21
	AS, MRRTF, EVI, PP, US	RF	62.5±0.41	2.15± 0.01
15-30	CSC, CNBL, PP	LM	16.0	2.47
	CSC, CNBL, PP	RF	62.6±0.69	2.16±0.02
	CSC, CNBL, PP, US	RF	63.0±0.57	2.14± 0.11
30-60	VD, PP	LM	12.0	2.08
	VD, PP	RF	62.6±0.53	2.13±0.02
	VD, PP, US	RF	61.0±0.55	2.15± 0.03
60-100	AS, MRRTF, PP	LM	28	1.1
	AS, MRRTF, PP	RF	57.4±0.48	2.28±0.01
	AS, MRRTF, PP, US	RF	61.0±0.47	2.17± 0.01
100-200	LsF, CNBL, VDCN, RSP, CV_EVI, TP	LM	0.05	0.27
	LsF, CNBL, VDCN, RSP, CV_EVI, TP	RF	62.0± 0.64	2.15±0.02
	LsF, CNBL, VDCN, RSP, CV_EVI, TP, US	RF	62.0±0.40	2.14± 0.14

<sup>(1)</sup> Seleccionadas a partir de los modelos lineales con el criterio de mayor varianza explicada, menor RMSE y menor VIF (Variance Inflation Factor).

AS: Aspect. CD: Closed depressions. CSC: Cross-Section curvature. LsF: Ls Factor. CNBL: Channel network base level. VD: Valley depth. RSP: Relative slope position. MRRTF: Multiresolution valley bottom flatness index. EVI: Media anual de Enhanced Vegetation Index (EVI). CV\_EVI: Coeficiente de variación estacional del EVI. PP: Precipitación TP: Temperatura, US: Usos del suelo.

<sup>(2)</sup> LM: modelo regresión lineal. RF: modelo arboles aleatorios (random forest)



**Figura 3.** Mapas de distribución del carbono orgánico en los suelos de Andalucía, por profundidades. Valores expresados en %. Varianza explicada entre el 57% y 63%. Estos mapas son el resultado de técnicas de random forest-regression kriging empleando como factores predictivos las covariables seleccionadas en los modelos lineales.

**Figure 3.** Maps of organic carbon distribution in Andalusia, at different soil depths. Values expressed as %. Explained variance between 57% and 63%. These maps are derived from random forest-regression kriging method using as predictive factors the variables selected by the linear model.

La incertidumbre asociada a los valores de COS pueden alcanzar 8%, incrementándose a medida que lo hace el porcentaje de COS (Fig. 4). El patrón espacial de la incertidumbre es disperso y menos variable en la superficie. Con la profundidad, este patrón permite la identificación de áreas específicas (e.g., Sureste y Noroeste) donde la incertidumbre es claramente mayor en áreas que concentran los mayores reservorios de COS.

## Discusión

### Controles ambientales de la variabilidad

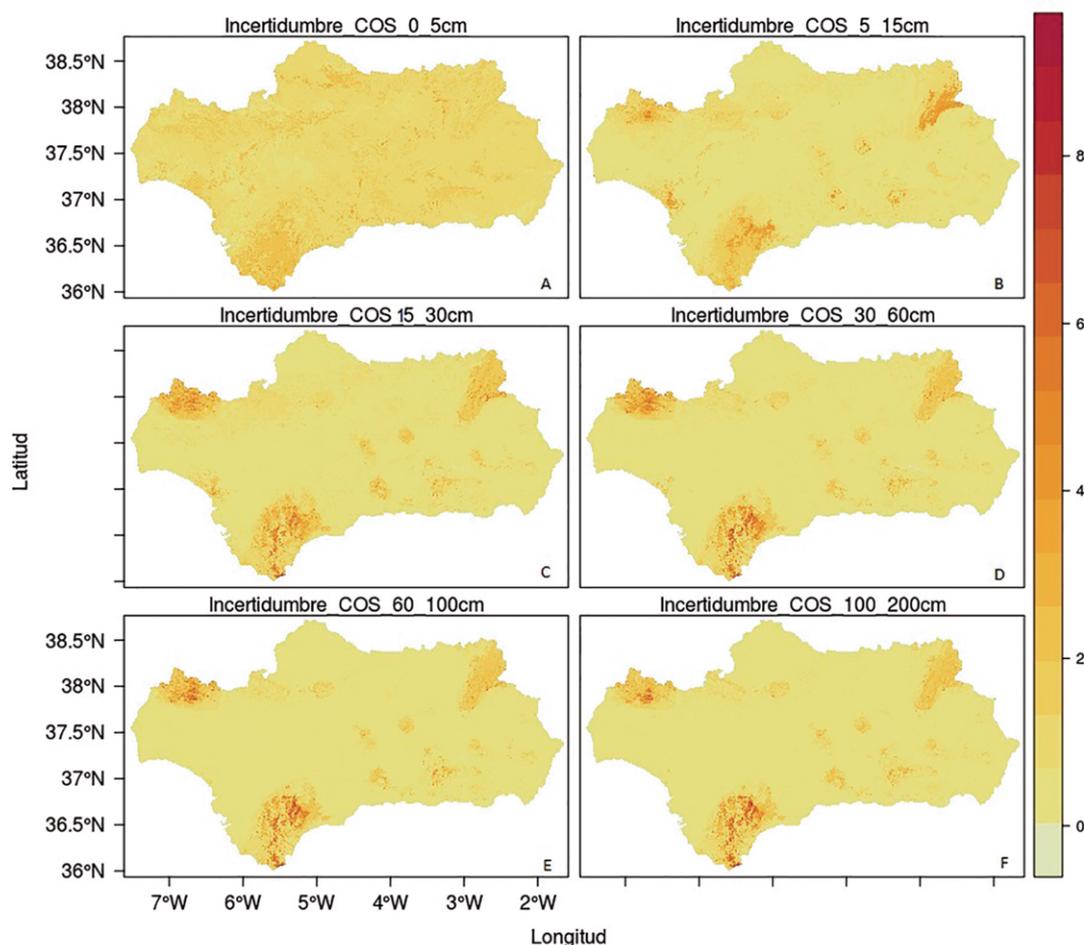
Los resultados muestran (Tabla 3) que los controles de variación espacial del COS cambian en función de la profundidad del horizonte, lo que indica que los factores de control y los mecanismos implicados en la estabilización y dinámica del COS difieren en la superficie y en profundidad. Esto apoya la idea de que el estudio de la variabilidad del COS a lo largo del perfil completo de suelo es necesario para mejorar las estimaciones y conocer su comportamiento (Willaarts et al. 2016).

La precipitación fue en general el control más importante del COS, de manera positiva, aunque esta relación se debilitó a medida que la profundidad aumentaba. En superficie, los mapas muestran un patrón espacial asociado al gradiente de precipitación regional: tendencia general a disminuir el COS de Oeste a Este, y a variar irregularmente bajo el efecto local de la orografía. Patrones similares han sido descritos previamente por Wiesmeier et al. (2014) en el sureste de Alemania; por Rial et al. (2015) en Galicia, Willaarts et al. (2016) en el sur de España, o Calvo de Anta et al. 2015 en el norte y nordeste de España.

Este incremento del COS con la lluvia, y por tanto con disponibilidad de agua en el suelo (Koster 2004), se justifica por una posible mayor intensidad de los procesos biológicos y mayor aporte de biomasa, tanto en superficie como por debajo de ella en el suelo. Mientras que en la superficie el aporte principal de COS se debe a la biomasa aérea, en el subsuelo el reservorio de COS también es importantes a través de las raíces (Jobbágy y Jackson 2000; Rumpel y Kögel-Knabner 2011; Albaladejo et al. 2013).

Respecto a la temperatura, aunque ha sido señalada como un control importante de la variabilidad del COS (Blanco 2015), los resultados muestran que en Andalucía el principal control de COS es la precipitación. Esto puede explicarse por la predominancia en Andalucía de un clima Mediterráneo cuyas características térmicas se sitúan mayoritariamente en un intervalo idóneo para la actividad biológica, excepto en zonas montañosas altas concretas donde puede ser limitante. De esta forma la topografía, en concreto la presencia de valles o zonas de acumulación que resulta ser importante en la disponibilidad de agua, también ejerce un control principal para la acumulación de materia orgánica. Este efecto también ha sido descrito para ecosistemas con importantes limitaciones en la disponibilidad de agua (Austin et al. 2004) y para procesos concretos implicados en el balance de carbono en el suelo como la respiración (Oyonarte et al. 2012).

También se ha observado una alta correlación del COS en los horizontes superficiales con la media anual del índice de vegetación EVI, un indicador de la productividad primaria anual también vinculado con la biomasa aérea (Zhang et al. 2012). La dinámica de este indicador no sólo refleja la variabilidad climática, sino también se relaciona directamente con el tipo de manejo, uso o cobertura



**Figura 4.** Mapas de distribución de la incertidumbre asociada a la estimación del carbono orgánico en los suelos de Andalucía, por profundidades. Valores expresados en %. Estos mapas son el resultado de *quantile regression forests*, que permiten la estimación de la distribución condicional completa del COS como respuesta a los mejores predictores seleccionados con los métodos lineales, por pixel. Estos mapas muestran la incertidumbre, representada por el rango de los intervalos de confianza a 95% de dicha distribución.

**Figure 4.** Maps of uncertainty distribution associated with organic carbon estimation in Andalusia, at different soil depths. Values expressed as %. These maps are derived from *quantile regression forest* method, which estimates the COS conditional distribution by pixel as result of the selection of the best predictive factors of the linear models. These maps show the uncertainty for a 95% confidence interval.

del suelo, factor que ha sido señalado como el principal control en la dinámica temporal del COS (Albadalejo et al. 2013; Doblas-Miranda et al. 2013; Calvo de Anta et al. 2015).

Los análisis realizados establecen que no se incrementa la varianza explicada de los modelos que introducen el uso del suelo respecto a los que utilizan exclusivamente el EVI (Tabla 3), lo que sugiere que existe redundancia en la variabilidad explicada por estos predictores. De esta forma parece aconsejable incorporar a la modelización variables capaces de describir esta dinámica, y dado que el EVI es sensible a cambios en las coberturas vegetales y los cambios de uso y manejo del terreno (Alcaraz-Segura et al. 2009, 2013) y pueden ser calculados con una alta resolución temporal, resultan la herramienta idónea para conseguir este objetivo. De manera consistente con nuestros resultados, otros trabajos han encontrado que los índices de vegetación son un buen predictor de los reservorios del COS (Zhang et al. 2012; Yang et al. 2016), y la evaluación de su captura potencial de carbono en el suelo (Burghaimer et al. 2006).

Esto indica la posibilidad de evaluar el uso de atributos funcionales de los ecosistemas, junto a los estructurales que mayoritariamente se utilizan, derivados de teledetección como descriptores de la dinámica de la vegetación con resultados prometedores para anticipar los cambios en la distribución de especies (Alcaraz-Segura et al. 2017) y mejorar los pronósticos del tiempo (Müller et al. 2014) para el seguimiento de la dinámica y los cambios en el COS. La incorporación de este tipo de variables (dinámica y de fácil acceso) a los modelos resultaría útil para el monitoreo y manejo sustentable de los reservorios de carbono a escalas temporales de corto a medio plazo.

Sin embargo, la variabilidad del COS depende de una compleja red de factores y, aunque encontramos que la precipitación y el veredor de la vegetación son los principales controles de COS en los horizontes superficiales, también encontramos una fuerte influencia de las variables topográficas que incrementa con la profundidad de análisis (Tabla 3). Es por esto que la topografía es comúnmente usada para mapear cambios en el COS (Minasny et al. 2013). La topografía controla dos procesos principales relacionados al COS que definen en gran medida las características estructurales de la vegetación, la distribución de agua en el paisaje y el potencial de radiación solar (Moore et al. 1991). La utilización de variables topográficas obtenidas a partir de MDE facilita la posibilidad de obtener modelos de COS en áreas con baja disponibilidad de datos, sin embargo resultan limitadas para predecir la dinámica del carbono a corto plazo, dado que la topografía es una covariable estática a escala de manejo. La integración de las variables topográficas estables junto a las dinámicas (e.g. clima o EVI), supera esta limitación abriendo la posibilidad de monitorear los cambios en los reservorios de carbono de manera operativa, ya que ambos grupos de covariables son de cobertura global y de libre acceso.

#### Modelos de variabilidad espacial del COS

El mayor porcentaje de carbono fue encontrado en los horizontes superficiales (0-5 cm), dado que son los que reciben directamente el aporte de restos orgánicos, donde existe una mayor densidad de raíces y una mayor actividad microbiana (Acosta-Mireles et al. 2009). Los valores de porcentaje de carbono orgánico y varianza explicada son comparables a los descritos en la bibliografía

a nivel español (Rodríguez-Lado y Martínez-Cortizas 2015; Rodríguez Martín et al. 2016). Nuestros resultados muestran que el uso de modelos predictivos informados con una apropiada y previa selección de variables facilita la estimación de los contenidos de COS en los reservorios, incrementando la interpretabilidad de las predicciones generadas. En promedio, 60% de la variabilidad espacial del contenido de COS en Andalucía fue explicado bajo este esquema, lo que se considera un alto porcentaje respecto a la variación observada considerando que la variación espacial de las propiedades del suelo se produce a escala de metros o decenas de metros, muy por debajo de la escala de trabajo (Heuvelink y Webster 2001). Otra causa de la varianza no explicada es la densidad de muestreo y su distribución no homogénea (Heng et al. 2014), difícil de evitar cuando se utilizan bases de datos patrimoniales.

El protocolo estadístico desarrollado en este trabajo permite establecer de forma espacialmente explícita la incertidumbre asociada a cada predicción. En los suelos de Andalucía la incertidumbre no se distribuye espacialmente de forma homogénea y se concentra en las zonas con valores más altos de COS, de manera consistente con trabajos previos (Heng et al. 2014; Mulder et al. 2016). La incertidumbre incrementa sus valores máximos con la profundidad de análisis, probablemente porque no hay muchas covariables para representar el suelo en horizontes sub-superficiales (Hengl et al. 2017). Los valores de incertidumbre obtenidos (hasta el 8%) son difíciles de discutir y comparar ya que no existen otros mapas de incertidumbre de la distribución del COS en los suelos españoles.

Se considera que los productos obtenidos (e.g., mapas de COS e incertidumbres asociadas) resultan imprescindibles para aumentar la interoperabilidad y desarrollar estrategias eficientes en el control del cambio climático mediante el manejo del stock de carbono en los ecosistemas terrestres (Vargas et al. 2017).

## Conclusiones

Mediante la utilización del esquema metodológico propuesto es posible generar mapas interpretables y modelos predictivos que permiten (1) alcanzar una alta varianza explicada del contenido de COS, (2) conocer las variables que controlan la distribución del carbono, (3) estimar la distribución horizontal y vertical del COS en zonas sin costosa información ambiental, y (4) estimar el nivel de incertidumbre que afecta estas distribuciones. Los resultados obtenidos mejoran el detalle de la distribución espacial y la precisión de la información disponible sobre porcentaje de COS en el territorio andaluz.

La precipitación, indicadores subrogados de la productividad primaria media (EVI), y el relieve permitieron crear un modelo que explicó hasta un 60 por ciento de la distribución del COS en los 200 cm estudiados. La topografía, como variable estable, resulta ser un factor determinante en la variabilidad espacial del COS. Variables dinámicas como la precipitación promedio o el EVI medio anual también resultaron determinantes. Sin embargo, el EVI medio anual resulta de especial interés para la modelación ya que, al capturar diferencias espaciales en la biomasa de la vegetación (vinculadas a la cobertura vegetal), tener una capacidad predictora similar a los usos del suelo, y ser fácilmente actualizable mediante teledetección, podría facilitar el monitoreo de los cambios potenciales de COS de forma dinámica.

Los resultados abren la posibilidad de gestión activa del carbono orgánico de los suelos en el territorio andaluz. Los productos derivados de esta investigación (e.g., mapas de COS e incertidumbres asociadas) pueden resultar útiles para la toma de decisiones sobre los usos de la tierra e identificación de áreas prioritarias para la gestión y manejo de los stocks de carbono.

## Agradecimientos

Los autores agradecen la colaboración de la Consejería de Medio Ambiente y Ordenación del Territorio de la Junta de Andalucía, facilitando el uso de la base de datos de suelos de Andalucía.

Este estudio recibió financiación de MINECO (Ayuda JC2015-00316 y proyecto CGL2014-61610-EXP) y de la Junta de Andalucía con apoyo de los Fondos FEDER (proyecto GLOCHARID), y el programa Horizon 2020 de la Unión Europea (proyecto ECOPOTENTIAL, acuerdo 641762). MG agradece el apoyo brindado por el Consejo Nacional de Ciencia y Tecnología (CONACyT) de México. DAS, CO y RV agradecen a RD por facilitar discusiones iniciales para desarrollar este trabajo.

## Referencias

- Acosta-Mireles, M., Carrillo-Anzures, F., Díaz Lavariaga, M. 2009. Determinación del carbono total en bosques mixtos de *Pinus patula* Schl. et Cham. *Terra Latinoamericana* 27(2): 105-114
- Albaladejo, J., Ortiz, R., García-Franco, N., Navarro, A., Almagro, M., Pintado, J., Martínez-Mena, M. 2013. Land use and climate change impacts on soil organic carbon stocks in semi-arid Spain. *Journal of Soils and Sediments* 13(2): 265-277.
- Alcaraz-Segura, D., Cabello, J., Paruelo, J.M. 2009. Baseline characterization of major Iberian vegetation types based on the NDVI dynamics. *Plant Ecology* 202(1): 13-29.
- Alcaraz-Segura, D., Paruelo, J., Epstein, H., Cabello, J. 2013. Environmental and Human Controls of Ecosystem Functional Diversity in Temperate South America. *Remote Sensing* 5, 127-154.
- Alcaraz-Segura, D., Lomba, A., Sousa-Silva, R., Nieto-Lugilde, D., Alves, P., Georges, D., Vicente, J., Honrado, J. 2017. Potential of satellite-derived ecosystem functional attributes to anticipate range shifts. *International Journal of Applied Earth Observation and Geoinformation* 57: 86-92.
- Arrouays, D., Grundy, M.G., Hartemink, A.E., Hempel, J.H., Heuvelink, G.B.M., Hong, S.Y.M., et al. 2014. Chapter Three – GlobalSoilMap: Towards a Fine Resolution Global Grid of Soil Properties. En: Sparks D.L. (ed) *Soil Carbon. Advances in Agronomy* 125:93-134.
- Austin, A.T., Yahdjian, L., Stark, J.M., Belnap, J., Porporato, A., Norton, J., Ravetta, D.A., Schaeffer, S.M. 2004. Water pulses and biogeochemical cycles in arid and semiarid ecosystems. *Oecologia* 141(2): 221-235.
- Batjes, N.H. 2016. Harmonized soil property values for broad-scale modeling (WISE30sec) with estimates of global soil carbon stocks. *Geoderma* 269: 61-68.
- Beaudette, D.E., Roudier, P., O'Geen, A.T. 2013. Algorithms for quantitative pedology: A toolkit for soil scientists. *Computers and Geosciences* 52:258-268.
- Bermejo, D., Cáceres, F., Moreira, J.M., Montes, J.E., Sánchez, S., Laguna, D., et al. 2011. *Medio siglo de cambios en la evolución de usos del suelo en Andalucía 1956- 2007*. Consejería de Medio Ambiente. Junta de Andalucía. España
- Bert M., Ogunlade D., Coninck H., Loos M., M.L. (Eds.). 2005. *La captación y el almacenamiento de dióxido de carbono. Resumen para responsables de políticas y resumen técnico*. Grupo Intergubernamental de Expertos, Convención Marco de las Naciones Unidas para el Cambio Climático. 66pp. ISBN 92-9169-319-7
- Bishop, T.F.A., McBratney, A.B., Laslett, G.M. 1999. Modelling soil attribute depth functions with equal-area quadratic smoothing splines. *Geoderma* 91(1-2): 27-45.
- Blanco, A. 2015. *Estudio de la Distribución Espacial y Cartografía Digital de Algunas Propiedades Físicas, Químicas e Hidrodinámicas de Suelos de la Cuenca del Segura*. Tesis Doctoral. Universidad de Murcia, Murcia, España. 270pp. Disponible en: <http://www.tdx.cat/handle/10803/334699>
- Breiman, L., 2001. Random forests. *Machine Learning* 45: 5-32.
- Burgheimer, J., Wilske, B., Maseyk, K., Karnieli, A., Zaady, E., Yakir, D., Kesselmeier J. 2006. Relationships between Normalized Difference Vegetation Index (NDVI) and carbon fluxes of biologic soil crusts assessed by ground measurements. *Journal of Arid Environments* 64:651-669.
- Calvo de Anta, R., Luís Calvo, E., Casás Sabarís F., Galiñanes Costa, J.M., Matilla Mosquera, N., Macías Vázquez, F., Camps Arbestain, M., Vázquez García, N. 2015. Soil organic carbon in northern Spain (Galicia, Asturias, Cantabria and País Vasco). *Spanish Journal of Soil Science* 5 (1): 41-53.
- Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., et al. 2015. System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. *Geoscientific Model Development* 8(7):1991-2007. doi: 10.5194/gmd-8-1991-2015.

- Cruz-Cárdenas, G., López-Mata, L., Ortiz-Solorio, C., Villaseñor, J., Ortiz, E., Silva, J.T., Estrada-Godoy, F. 2014. *Geoderma* 213: 29-35
- De la Rosa, D. 1984. *Catálogo de suelos de Andalucía*. Monografías de Medio Ambiente. 3. Servicio de Publicaciones. Junta de Andalucía. Sevilla. España.
- Doblas-Miranda, E., Rovira, P., Brotons, L., Martínez-Vilalta, J., Retana, J., Pla, M., Vayreda, J. 2013. Soil carbon stocks and their variability across the forests, shrublands and grass-lands of peninsular Spain. *Biogeosciences* 10: 8353–8361.
- Fernández-Delgado, M., Cernadas, E., Barro, S., Amorim, D. 2014. Do We Need Hundreds of Classifiers to Solve Real World Classification Problems? *Journal of Machine Learning Research* 5:3133–3181.
- Folberth, C., Skalský, R., Moltchanova, E., Balkovič, J., Azevedo, L.B., Obersteiner M., van der Velde, M. 2016. Uncertainty in soil data can outweigh climate impact signals in global crop yield simulations. *Nature Communications* 7: 11872.
- Gallant, J.C., Dowling, T.I. 2003. A multiresolution index of valley bottom flatness for mapping depositional areas: Multiresolution Valley Bottom Flatness. *Water Resources Research* 39(12): 1347
- Gessler, P.E., Moore, I.D., McKenzie, N.J., Ryan P.J. 1995. Soil-landscape modelling and spatial prediction of soil attributes. *International Journal of Geographical Information Systems* 9 (4): 421-432.
- Grimm, R., Behrens, T., Märker, M., Elsenbeer, H. 2008. Soil organic carbon concentrations and stocks on Barro Colorado Island — Digital soil mapping using Random Forests analysis. *Geoderma* 146 (1–2): 102-113.
- Hastie, T., Tibshirani, R., Friedman, J. 2008. *The elements of Statistical Learning. Data Mining, Inference, and Prediction*. Second Edition. Springer Series in Statistics. Springer-Verlag. New York. Estados Unidos.
- Heiberger, R.M., Holland, B. 2004. *Statistical analysis and data display: An intermediate course with examples in S-Plus, R, and SAS*. Springer. New York. Estados Unidos.
- Hengl, T., Heuvelink, G.B.M., Stein, A. 2004. A generic framework for spatial prediction of soil variables based on regression-kriging. *Geoderma* 120: 75–93.
- Hengl, T., Mendes de Jesus J.M., MacMillan, R.A., Batjes, N.H., Heuvelink, G.B.M., Ribeiro, E. et al. 2014. SoilGrids1km — Global Soil Information Based on Automated Mapping. *PLoS ONE* 9, e105992.
- Hengl, T., Mendes de Jesus, J., Heuvelink, G.B.M., Ruiperez Gonzalez, M., Kilibarda, M., Blagotić, A. et al. 2017. SoilGrids250m: Global gridded soil information based on machine learning (ed Bond-Lamberty B). *PLOS ONE* 12, e0169748.
- Heuvelink G.B.M., Webster R. 2001. Modelling soil variation: past, present, and future. *Geoderma* 100: 269–301.
- Huete, A., Didan, K., Miura, T., Rodríguez, E.P., Gao, X., Ferreira, L.G. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment* 83(1-2): 195-213
- James, G., Witten, D., Hastie, T., Tibshirani, R. 2013. *An Introduction to Statistical Learning with Application in R*. Springer. New York. Estados Unidos.
- Jenny, H. 1941. *Factors of Soil Formation*. McGraw-Hill, NY. Estados Unidos.
- Jobbágy, E.G., Jackson, R.B. 2000. The vertical distribution of soil organic carbon and its relation to climate and vegetation. *Ecological Applications* 10: 423–436.
- Kohavi, R. 1995. A study of cross-validation and bootstrap for accuracy estimation and model selection. *Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence* 2 (12): 1137–1143.
- Koster, R.D. 2004. Regions of Strong Coupling Between Soil Moisture and Precipitation. *Science* 305:1138–1140.
- Lal, R. Ed. 2001. Soil Carbon Sequestration and the Greenhouse Effect. SSSA Spec. Publ. Nº 57, *Soil Science Society of America*, Inc., Madison, WI, Estados Unidos.
- Lal, R. 2004. Soil Carbon Sequestration to mitigate climate change. *Geoderma* 123:1-22.
- Malone, B.P., McBratney, A.B., Minasny, B., Laslett, G.M. 2009. Mapping Continuous Depth Functions of Soil Carbon Storage and Available Water Capacity. *Geoderma* 154: 138–52
- McBratney, A.B., Mendonca Santos, M.L., Minasny, B. 2003. On digital soil mapping. *Geoderma*, 117:3-52
- Meinshausen, N. 2006. Quantile Regression Forests. *Journal of Machine Learning Research* 7: 983–999.
- Minasny, B., McBratney, A.B., Malone, B.P., Wheeler, I. 2013. Digital mapping of soil carbon. *Advances in Agronomy* 118:1–47.
- Moore, I.D., Grayson, R.B., Ladson, A.R. 1991. Digital terrain modelling: A review of hydrological, geomorphological, and biological applications. *Hydrological Processes* 5: 3–30.
- Mulder, V.L., Lacoste, M., Richer-de-Forges, A.C., Martin, M.P., Arrouays, D. 2016. National versus global modelling the 3D distribution of soil organic carbon in mainland France. *Geoderma* 263:16–34.
- Müller, O.V., Berbery, E.H., Alcaraz-Segura, D., Ek, M.B. 2014. Regional model simulations of the 2008 drought in southern South America using a consistent set of land surface properties. *Journal of Climate* 27(17): 6754-6778.
- Muñoz-Rojas, M., Jordan, J., Zavala, L.M., De la Rosa, D., Abd-Elmabod, S.K., Anaya-Romero, M. 2012. Organic carbon stocks in Mediterranean soil types under different land uses (Southern Spain). *Solid Earth* 3: 375–386.
- Oyonarte, C., Rey, A., Raimundo, J., Miralles, I., Escribano, P. 2012. The use of soil respiration as an ecological indicator in arid ecosystems of the SE of Spain: spatial variability and controlling factors. *Ecological Indicators* 14 (1): 40-49.
- O'Rourke, S.M., Angers, D.A., Holden, N.M., McBratney, A.B. 2015. Soil organic carbon across scales. *Global Change Biology* 21: 3561–3574.
- Rial, M., Martínez-Cortizas, A.M., Rodríguez-Lado, L. 2015. A Novel Approach to Map Soil Organic Carbon Content Using Spectroscopic and Environmental Data. *Procedia Environmental Sciences*, 27: 49–52.
- Richardson, H.J., David J.H., Dan R.D., Lauchlan H. F. 2017. A comparison of geographic datasets and field measurements to model soil carbon using random forests and stepwise regressions (British Columbia, Canada). *GIScience and Remote Sensing* 54 (4):573-591.
- Rodríguez-Martín, J.A., Fuentes, A., Gonzalo, J., Ramos-Miras, J.J., Grau, J.M., Boluda, R. 2016. Assessment of the soil organic carbon stock in Spain. *Geoderma* 264: 117–125.
- Rodríguez-Lado, L., Martínez-Cortizas, A. 2015. Modelling and mapping organic carbon content of top soils in an Atlantic area of southwestern Europe (Galicia, NW-Spain). *Geoderma* 245-246: 65-73.
- Rumpel, C., Kögel-Knabner, I. 2011. Deep soil organic matter—a key but poorly understood component of terrestrial C cycle. *Plant Soil* 338: 143–158.
- Scharlemann, J. Tanner, E., Hiederer, R., Kapos, V. 2014. Global soil carbon: understanding and managing the largest terrestrial carbon pool. *Carbon Management* 5(1): 81–91.
- Stockmann, U., Padarian, J., McBratney, A.B., Minasny, B. de Brogniez, D., Montanarella, L. et al. 2015. Global soil organic carbon assessment. *Global Food Security* 6: 9–16.
- Vargas, R., Alcaraz-Segura, D., Birdsey, R., Brunzell, N.A., Cruz-Gaistardo, C.O., de Jong, B., et al. 2017. Enhancing interoperability to facilitate implementation of REDD+: case study of Mexico. *Carbon Management* 8(1): 57-65.
- Viscarra-Rossel, R.A., Behrens, T. 2010. Using data mining to model and interpret soil diffuse reflectance spectra. *Geoderma* 158 (1-2): 46–54.
- Viscarra-Rossel, R.A., Chen, C., Grundy, M.J., Searle, R., Clifford, D., Campbell, I P. H. 2015. The Australian three-dimensional soil grid: Australia's contribution to the GlobalSoilMap project. *Soil Research* 53: 845-864.
- Webster, R., Oliver, M. 2007. *Geostatistics for environmental scientists*. Chichester: John Wiley and Sons. England.
- Wiesmeier, M., Berthold, F., Sporlein, P., Geuss, U., Hangen, E., Reischl, A., Schilling, B., Angst, G., von Lutzow, M., Kögel-Knabner, I. 2014. Estimation of total organic carbon storage and its driving factors in soils of Bavaria (southeast Germany). *Geoderma Regional* 1(C): 67–78.
- Willaarts, B.A. Oyonarte, C., Muñoz-Rojas, M., Ibáñez, J.J. Aguilera, P. 2016. Environmental Factors Controlling Soil Organic Carbon Stocks in Two Contrasting Mediterranean Climatic Areas of Southern Spain. *Land Degradation and Development* 27: 603–611.
- Wilson, J.P. 2012. Digital terrain modeling. *Geomorphology* 137:107–121.
- Yang, R.M, Zhang, G.L., Yang, F. Zhi, J.J., Yang, F., Liu, F. et al. 2016. Precise estimation of soil organic carbon stocks in the northeast Tibetan Plateau. *Scientific Reports* 6:21842.
- Zhang, W., Wang, K., Chen, H., He, Y., Zhang, J. 2012. Ancillary information improves kriging on soil organic carbon data for a typical karst peak cluster depression landscape. *Journal of the Science of Food and Agriculture* 92: 1094–1102.