

Trabajo científico – Física, Química y Físico-químicas de los Suelos

MODELADO Y CARTOGRAFIA DEL ALMACENAMIENTO DE CARBONO EN LOS
SUELOS DE LA REPÚBLICA ARGENTINA

MODELLING AND MAPPING OF SOIL CARBON STORAGE IN ARGENTINA

Mapa de C de los suelos argentinos

Juan José Gaitán^{1,2,*} (<https://orcid.org/0000-0003-2889-1418>), Pablo Luis Peri^{2,3}
(<https://orcid.org/0000-0002-5398-4408>), María Paula Barral^{4,5} (<https://orcid.org/0000-0001-7834-491X>), María Florencia Accame⁶ (<https://orcid.org/0009-0003-9871-8140>), Francisco
Guillermo Alaggia⁸ (<https://orcid.org/0009-0007-9570-3380>), Silvia, Albarracín⁹, Deivid Joan
Álvarez-Cortés^{2,10} (<https://orcid.org/0009-0005-3758-4243>), Claudio Álvarez¹¹
(<https://orcid.org/0009-0002-6743-5482>), Silvina Bacigaluppo¹² (<https://orcid.org/0000-0003-0567-0567>), Ezequiel Balducci¹³ (<https://orcid.org/0009-0005-7723-7940>), Natalia Banegas¹⁴
(<https://orcid.org/0000-0002-2080-2225>), Sebastián Barbaro⁵ (<https://orcid.org/0009-0004-0695-6705>), Santiago Behr¹⁵ (<https://orcid.org/0009-0007-3087-0604>), Marcelo Javier
Beltrán¹⁶, María Victoria Benedetto¹³ (<https://orcid.org/0009-0001-1580-5456>), Gonzalo
Berhongaray^{17,18} (<https://orcid.org/0000-0002-3662-8583>), Carlos Buduba¹⁹
(<https://orcid.org/0009-0006-0314-5119>), Enzo Caballero²⁰, Patricia Carfagno¹⁶
(<https://orcid.org/0009-0004-6763-3045>), Cecilia Caruso¹² (<https://orcid.org/0000-0002-9202-0951>), Erica Casasola²¹ (<https://orcid.org/0009-0000-5897-9272>), Flora Céspedes²², Jorge
Chalco Vera^{2,14} (<https://orcid.org/0000-0001-5657-2188>), Juan Cruz Colazo²³
(<https://orcid.org/0000-0002-4946-9147>), Silvia Correa²⁴ (<https://orcid.org/0009-0002-6806->

0301), Juan Pablo Diez²⁵ (<https://orcid.org/0009-0000-4889-6916>), Juan Martín Enrico¹² (<https://orcid.org/0000-0002-8078-5738>), Andrea Soledad Enríquez²⁶, Anabella Fantozzi²⁶ (<https://orcid.org/0000-0001-5795-2035>), Pedro David Fernández^{14,27} (<https://orcid.org/0000-0002-5123-4080>), Carolina Fernández López²⁸ (<https://orcid.org/0000-0001-8936-502X>), Joaquín Flores²⁸ (<https://orcid.org/0009-0000-4861-4739>), Carolina Frías²⁹ (<https://orcid.org/0009-0006-7340-0197>), Federico Fritz^{18,30}, Natalia Furlan³¹, Guillermo García Martínez¹⁹, Gabriel Gatica⁴ (<https://orcid.org/0000-0003-2883-2565>), Ana Paula Giannini³² (<https://orcid.org/0000-0003-3189-1478>), Silvia Yanina Goytía²⁰ (<https://orcid.org/0009-0002-3204-4924>), Javier Gyenge⁴ (<https://orcid.org/0000-0003-3895-5112>), Alicia Irizar³² (<https://orcid.org/0009-0007-5729-8783>), Rosario Iturralde³³ (<https://orcid.org/0000-0003-2456-812X>), Nanci Kloster³⁴ (<https://orcid.org/0000-0002-3263-3983>), Ditmar Bernardo Kurtz²⁸ (<https://orcid.org/0000-0001-8388-2800>), Ludmila La Manna³⁵ (<https://orcid.org/0000-0002-6672-690X>), Pablo Laclau³¹ (<https://orcid.org/0000-0002-9343-534X>), Javier Lara¹⁴ (<https://orcid.org/0009-0006-6084-3036>), Roxana Ledesma²⁹ (<https://orcid.org/0000-0001-6033-1555>), Raúl Lertora²⁰ (<https://orcid.org/0009-0007-5163-8599>), Carlos Sebastián López Morillo³⁶ (<https://orcid.org/0009-0007-0618-2297>), Ástor López²⁰ (<https://orcid.org/0000-0002-6891-4779>), Dardo López⁸ (<https://orcid.org/0000-0001-9709-0070>), Ana Lupi¹⁶ (<https://orcid.org/0000-0002-7969-2534>), Andrés Madias^{8,37}, Natalia Mansilla³⁸ (<https://orcid.org/0009-0000-3412-2215>), María Julia Martinefsky³³ (<https://orcid.org/0009-0006-4711-5114>), Matías Mastrángelo^{2,39} (<https://orcid.org/0000-0002-3049-3534>), Pablo Andrés Meglioli⁴⁰ (<https://orcid.org/0000-0001-7296-3947>), Eduardo Moavro⁴¹, Ingrid Mónaco²² (<https://orcid.org/0009-0007-3591-5277>), Lucas Moretti⁹ (<https://orcid.org/0000-0002-5661-0305>), Alejandro Moyano²⁴ (<https://orcid.org/0009-0007-6364-2237>), Francisco Murray⁴² (<https://orcid.org/0000-0002-3485-7585>), Marcelo Nosetto² (<https://orcid.org/0000-0002-9428-490X>), Gabriel Oliva⁴³ (<https://orcid.org/0000-0002-7839-8851>), Walter Opazo¹⁹ (<https://orcid.org/0000-0003-3493-3848>), Paula Paredes⁴³ (<https://orcid.org/0000-0001-8656-7443>), Guillermo Peralta⁴³ (<https://orcid.org/0000-0001-9671-2149>), Silvina Restovich³² (<https://orcid.org/0000-0001-7208-7326>), Tania Rey

Montoya²⁸ (<https://orcid.org/0000-0002-6617-7111>), Julieta Rojas²⁰ (<https://orcid.org/0000-0003-3004-0735>), María Florencia Roldán²⁰ (<https://orcid.org/0009-0009-1324-2272>), Fernando Salvagiotti¹² (<https://orcid.org/0000-0002-6043-9803>), María Cristina Sánchez²⁹ (<https://orcid.org/0000-0003-2150-8471>), Martín Sandoval⁴⁵ (<https://orcid.org/0000-0001-8672-4154>), Florencia Soledad Saracco²⁹, Mario Eugenio Sello²⁵ (<https://orcid.org/0009-0002-5226-6436>), Ximena Sirimarco^{4,5} (<https://orcid.org/0000-0002-2815-1527>), Luciana Sleiman¹⁴, Cristina Ugarte¹⁹ (<https://orcid.org/0009-0009-3826-8524>), Sebastián Valiente⁴⁶ (<https://orcid.org/0009-0004-0480-2999>), Santiago Varela²⁵ (<https://orcid.org/0000-0003-3088-0419>), Virginia Velasco⁴⁶ (<https://orcid.org/0009-0000-0652-2529>), Augusto Viana¹⁴, Pablo Eugenio Villagra⁴⁰ (<https://orcid.org/0000-0002-1062-2001>), Sebastián Villarino^{2,39} (<https://orcid.org/0000-0003-1850-447X>), Alejandra Von Wallis⁴⁸ (<https://orcid.org/0000-0002-6417-6828>), Leslie Vorraber³¹ (<https://orcid.org/0009-0006-1957-9341>), Marcelo Germán Wilson⁴⁹ (<https://orcid.org/0000-0002-1214-1041>), Úrsula Ingrid Wolf Celoné¹⁰ (<https://orcid.org/0009-0008-3963-0364>), Diego Ybarra²⁸

¹ Universidad Nacional de Luján, Luján Buenos Aires, Argentina

² Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET), Argentina.

³ Instituto Nacional de Tecnología Agropecuaria (INTA), Estación Experimental Agropecuaria (EEA) Santa Cruz, Santa Cruz, Argentina.

⁴ Instituto de Innovación para la Producción Agropecuaria y el Desarrollo Sostenible (IPADS), INTA-EEA Balcarce-CONICET, Buenos Aires, Argentina.

⁵ Universidad FASTA, Mar del Plata, Buenos Aires. Argentina.

⁶ Asociación Argentina de Productores en Siembra Directa (AAPRESID), Argentina

⁸ INTA, Estación Forestal Villa Dolores, Córdoba, Argentina.

⁹ INTA, EEA Cerro Azul, Misiones, Argentina.

¹⁰ INTA, EEA Quimilí, Santiago del Estero, Argentina.

¹¹ INTA, EEA El Colorado, Formosa, Argentina.

¹² INTA, EEA Oliveros, Santa Fe, Argentina.

- ¹³ INTA, EEA Yuto, Jujuy, Argentina.
- ¹⁴ INTA, Instituto de Investigación Animal del Chaco Semiárido, Tucumán, Argentina.
- ¹⁵ INTA, EEA Chubut, Chubut, Argentina.
- ¹⁶ INTA, Instituto de Suelos, Buenos Aires, Argentina.
- ¹⁷ Instituto de Ciencias Agropecuarias del Litoral (CONICET - Universidad Nacional del Litoral), Santa Fe, Argentina.
- ¹⁸ Consorcios Regionales de Experimentación Agrícola (CREA), Santa Fe, Argentina
- ¹⁹ INTA, Estación Agroforestal Esquel, Chubut, Argentina.
- ²⁰ INTA, EEA Sáenz Peña, Chaco, Argentina.
- ²¹ INTA, Agencia de Extensión Rural (AER) Casilda, Santa Fe, Argentina.
- ²² INTA, EEA Colonia Benítez, Chaco, Argentina.
- ²³ INTA, EEA San Luis, San Luis, Argentina.
- ²⁴ INTA, AER Fernández, Santiago del Estero, Argentina.
- ²⁵ INTA, EEA Bariloche, Río Negro, Argentina.
- ²⁶ Instituto de Investigaciones Forestales y Agropecuarias Bariloche (INTA-CONICET), Río Negro, Argentina.
- ²⁷ Geography Department, Humboldt-University, Berlin, Alemania.
- ²⁸ INTA, EEA Corrientes, Corrientes, Argentina.
- ²⁹ INTA, EEA Santiago del Estero, Santiago del Estero, Argentina.
- ³⁰ Facultad de Agronomía, Universidad de Buenos Aires, C.A. Buenos Aires, Argentina.
- ³¹ INTA, AER San Martín de los Andes, Neuquén, Argentina.
- ³² INTA, EEA Pergamino, Buenos Aires, Argentina.
- ³³ INTA, AER Olavarría, Buenos Aires, Argentina.
- ³⁴ INTA, EEA Anguil, La Pampa, Argentina.
- ³⁵ Centro de Estudios Ambientales Integrados (CEAI) – Universidad Nacional de la Patagonia San Juan Bosco - CONICET, Chubut, Argentina.
- ³⁶ INTA, EEA Salta, Salta, Argentina.
- ³⁷ Facultad de Ciencias Agrarias, Universidad Nacional de Rosario, Santa Fe, Argentina.

- ³⁸ Departamento de Estudio de Suelos y Conservación, Dirección de Suelo y Agua Rural, Subsecretaría de Agricultura, Ministerio de Producción, Industria y Empleo de la Provincia de Chaco, Chaco, Argentina.
- ³⁹ Facultad de Ciencias Agrarias, Universidad Nacional de Mar del Plata, Buenos Aires, Argentina.
- ⁴⁰ Instituto Argentino de Nivología, Glaciología y Ciencias Ambientales, CONICET-Facultad de Ciencias Agrarias, Universidad Nacional de Cuyo, Mendoza, Argentina.
- ⁴¹ Secretaría de Agricultura, Ganadería y Pesca (SAGyP), Ministerio de Economía, C.A. Buenos Aires, Argentina.
- ⁴² INTA, AER San Luis, San Luis, Argentina.
- ⁴³ INTA, EEA Santa Cruz, Santa Cruz, Argentina.
- ⁴⁴ Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO) - Global Soil Partnership, Roma, Italia
- ⁴⁵ Laboratorio de Investigación de Sistemas Ecológicos y Ambientales (LISEA), Facultad de Ciencias Agrarias y Forestales, Universidad Nacional de La Plata, Buenos Aires, Argentina.
- ⁴⁶ INTA, AER Bandera, Santiago del Estero, Argentina.
- ⁴⁷ INTA, AER Ing. Jacobacci, Río Negro, Argentina.
- ⁴⁸ INTA, EEA Montecarlo, Misiones, Argentina.
- ⁴⁹ INTA, EEA Paraná, Entre Ríos, Argentina.

* Autor de contacto: jgaitan@unlu.edu.ar

RESUMEN

La estimación de las reservas de carbono orgánico del suelo (COS) es muy relevante considerando que el COS es uno de los principales impulsores de la mitigación del cambio climático y la productividad del suelo. Este trabajo actualiza el mapa de almacenamiento de COS de Argentina para la capa 0-30 cm, utilizando un enfoque de Mapeo Digital de Suelos

con el algoritmo Random Forest. Se analizaron 5.377 sitios muestreados entre 2015 y 2022 y se emplearon 38 variables predictoras climáticas, topográficas, edáficas y de vegetación. El almacenamiento total de COS se estimó en 13,19 PgC, con un rango de incertidumbre de 12,64-13,74 PgC. La reserva media nacional fue de 51,35 Mg ha⁻¹, con los valores más altos en humedales y tierras forestales. Sin embargo, al considerar la reserva total, los Pastizales acumularon el 61% del COS total del país, las Tierras forestales el 23%, las Tierras de cultivos el 13% y los Humedales el 3%. El modelo mostró un desempeño sólido ($R^2 = 0,73$) y confirmó que la temperatura es el principal factor de control del COS, seguida por la vegetación y las propiedades edáficas. Este mapa proporciona una línea de base para evaluar cambios en el almacenamiento de COS, lo que resulta clave para políticas de mitigación del cambio climático y manejo sustentable del suelo. Su actualización periódica permitirá reportar avances (o retrocesos) en compromisos internacionales y contribuir a los Objetivos de Desarrollo Sostenible. Para ello resulta necesario generar nuevos datos a través de redes de sitios de monitoreo permanentes y a largo plazo.

PALABRAS CLAVE: mapeo digital de suelos, random forest, servicios ecosistémicos, modelos espaciales.

ABSTRACT

The assessment of soil organic carbon stocks (SOC) is highly relevant considering that SOC *is one of the main drivers of* climate change mitigation and soil productivity. This study updates the SOC storage map of Argentina for the 0-30 cm layer using a Digital Soil Mapping approach with the Random Forest algorithm. A total of 5,377 sites sampled between 2015 and 2022 were analyzed, employing 38 predictive variables related to climate, topography, soil properties, and vegetation. The total SOC storage was estimated at 13.19 PgC, with an uncertainty range of 12.64-13.74 PgC. The mean SOC stock of Argentina was 51.35 Mg ha⁻¹, with the highest values found in wetlands and forest lands. However, in terms of total SOC storage, grasslands account for 61% of the national SOC stock, followed by forest lands (23%), croplands (13%), and wetlands (3%). The model demonstrated solid

performance ($R^2 = 0.73$) and confirmed that temperature is the main controlling factor of SOC, followed by vegetation and soil properties. This map provides a baseline for assessing changes in SOC storage, which is essential for climate change mitigation policies and sustainable soil management. Its periodic updating will enable progress (or setbacks) tracking in international agreements and contribute to the fulfilment of Sustainable Development Goals. This requires generating new data through networks of permanent, long-term monitoring sites.

KEYWORDS: digital soil mapping, random forest, ecosystem services, spatial models.

INTRODUCCIÓN

El suelo desempeña un rol fundamental en el ciclo global del carbono (C) almacenando aproximadamente 1.500 Pg C en el primer metro de profundidad (IPCC, 2000; FAO, 2001; Lorenz y Lal, 2018). Este reservorio duplica al de la atmósfera (750 Pg C) y es casi tres veces el reservorio en la vegetación (610 Pg C) (Lal, 2004; Smith, 2004, 2008). En paralelo, las actividades antrópicas inyectan anualmente a la atmósfera la suma de ~11 Pg de C (Le Quéré et al., 2016). Por lo tanto, pequeños cambios porcentuales en el depósito de carbono orgánico del suelo (COS) pueden afectar considerablemente el ciclo global del C, influyendo en el contenido de dióxido de carbono en la atmósfera. De esta manera, los cambios en el COS afectan la dinámica del cambio climático global (Stockmann et al., 2013), a través de emisiones y secuestro que aceleran o mitigan el proceso de calentamiento. El almacenamiento de COS es una función ecosistémica clave que contribuye a la regulación del clima y a la fertilidad y productividad del suelo. Esto se debe a su influencia en diversas propiedades físicas, químicas y biológicas, que promueven procesos tales como el ciclo biogeoquímico de varios nutrientes (McGill y Cole, 1981) y la formación y estabilización de los agregados del suelo (Tisdall y Oades, 1982). Por lo tanto, el COS se ha propuesto como un indicador principal para monitorear los procesos de degradación de las tierras. A nivel global, la Convención de las Naciones Unidas de Lucha contra la Desertificación (UNCCD), como organismo custodio del indicador 15.3.1 de Objetivos de Desarrollo Sostenible (ODS),

ha adoptado el mapeo de las reservas de COS como uno de los indicadores para estimar el área de tierras degradadas y para monitorear la meta de alcanzar la neutralidad en la degradación de las tierras hacia el año 2030 (IUCN, 2015).

Los patrones espaciales de cambios de COS están controlados por diferentes factores o procesos ambientales. El clima (principalmente las precipitaciones y la temperatura) influye en el almacenamiento de COS a través del control que ejerce sobre procesos como la meteorización de los materiales originarios del suelo y la mineralización/humificación de la materia orgánica (Gaitán et al., 2019). La topografía influye en la insolación y microclima, y determina el flujo de agua, solutos y sedimentos a través del paisaje (Zhu et al, 2019); redistribuyendo el COS a través de procesos como la erosión hídrica (Polyakov y Lal, 2004; Müller y Chaplot, 2015; Holz y Augustín, 2021). Las propiedades del suelo también influyen en el contenido y patrón espacial del COS, por ejemplo el contenido de arcillas, la cual forma complejos estables con la materia orgánica y, de esta manera, protege al COS de la mineralización, aumentando su tiempo de permanencia y su acumulación en el suelo (Paul, 1984; Schimel et al., 1985). Finalmente, un proceso clave interrelacionado con el COS, y asociado en parte a los factores y procesos ambientales anteriores, es la productividad primaria neta de la vegetación (PPN). La PPN representa la entrada principal de C al suelo a través de material vegetal en descomposición en superficie o muerte de raíces y, por lo tanto, es esencial para la acumulación de COS (Gaitán et al., 2019).

Los cambios en el uso y cobertura del suelo, especialmente la conversión de ecosistemas naturales en agroecosistemas, amenazan la salud de los suelos a nivel global (Olsson et al., 2023). El uso agrícola de los suelos modifica las propiedades físicas, químicas y biológicas, pudiendo llevar a la degradación de estos, especialmente cuando se reduce el contenido de COS. Debido a las labranzas y otras perturbaciones, que desintegran los agregados y alteran las condiciones de aireación, humedad y temperatura del suelo, se acelera la descomposición microbiana y la oxidación de COS a CO₂, lo que determina un aumento en su concentración en la atmósfera y contribuye al calentamiento global (Batlle-Aguilar et al., 2011; Wiesmeier et al., 2012). Además, esta reducción de COS afecta negativamente la

productividad de la tierra, incrementando los problemas relacionados con la seguridad alimentaria (Lal, 2004; Romero et al., 2024). Por el contrario, el incremento de COS aumenta la calidad y fertilidad del suelo al mejorar su estructura y la capacidad de retención de humedad y nutrientes, así como al reducir el riesgo de degradación por erosión, entre otras funciones (Brady y Weil, 2002, p. 219–271). Al mismo tiempo, se contribuye a la mitigación del cambio climático al fijar CO₂ atmosférico y almacenarlo en el suelo, con lo que se generan retroalimentaciones positivas entre seguridad alimentaria y cambio climático (Smith y Powlson, 2003).

Debido a esto, a nivel mundial existe un interés creciente por estimar y mapear las reservas de COS y sus variaciones temporales con mayor precisión, utilizando resoluciones espaciales más finas y abarcando extensiones geográficas más amplias (Feeney et al., 2022). Sin embargo, la estimación espacialmente explícita del contenido de COS es un desafío complejo, dado que su variabilidad espacio-temporal depende de la interacción dinámica de múltiples factores formadores del suelo, tales 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; Hauvelink et al., 2021). El desarrollo de tecnologías de mapeo digital de suelos (MDS) y sus aplicaciones ha facilitado la generación de mapas digitales continuos derivados de modelos predictivos (McBratney et al., 2003), así como la estimación de sus incertidumbres asociadas (Viscarra-Rossel et al., 2015). Estos mapas se fundamentan en el análisis de las relaciones entre los valores de COS y las variables de la ecuación de los factores formadores del suelo (Jenny, 1941).

En los últimos años, múltiples estudios han utilizado MDS para mapear las reservas de COS, utilizando diversas metodologías que incluyen modelos lineales como regresión simple o múltiple, geoestadística o diversas técnicas de aprendizaje automático (Lamichhane et al., 2019). Estas últimas se basan en el reconocimiento de patrones en una muestra de datos y la generación de un algoritmo capaz de extraer inferencias de nuevos conjuntos de datos para los que no ha sido entrenado previamente. En una revisión de técnicas de MDS aplicadas al mapeo de COS, Lamichhane et al. (2019) hallaron que las técnicas de

inteligencia artificial se han mostrado más eficientes para modelar el COS que los modelos lineales o la geoestadística, y que los ensambles de árboles de regresión tipo Random Forest (RF) (Breiman, 2001) son las técnicas de inteligencia artificial que generan mejores predicciones. Un aspecto importante es la incertidumbre de los valores predichos de COS, que refleja la variabilidad que no puede ser explicada con los datos y covariables utilizados. La magnitud de esta incertidumbre depende de los errores y de las inconsistencias en las bases de datos de COS y de las covariables utilizadas, así como también de la complejidad de las relaciones entre el suelo y su ambiente de formación (O'Rourke et al., 2015). Cuantificar la incertidumbre en los modelos es crucial, dado que esto afecta nuestra capacidad de detectar cambios significativos en las reservas de C inducidos por cambios en el clima, en la productividad de la vegetación y/o en las prácticas de manejo (Folberth et al., 2016).

Conocer la distribución espacial de las reservas de COS en Argentina y comprender los principales factores que la regulan es importante dado que permitiría diseñar estrategias para su conservación y la planificación de acciones para mitigar el cambio climático. Por ejemplo, un mapa actual de COS a nivel nacional proporcionará una línea de base en la que se pueden basar los esquemas de comercio de bonos de C y ayudará a identificar y priorizar las potenciales localizaciones para proyectos de secuestro de C basados en el suelo (Lamichhane et al., 2019). Además, este mapa podría aportar al modelado de mecanismos que inciden en la producción de cultivos y en los procesos de degradación de la tierra (Sleutel et al., 2006; Minasny et al., 2013; Nijbroek et al., 2018). Hasta la fecha, el mapa más completo de las reservas de C en los suelos de Argentina fue realizado por Olmedo et al. (2018) e incorporado al mapa global de FAO e ITPS (2018). Si bien se trata de un intento sólido de crear una línea de base reconocida para el país, este mapa presenta algunas limitaciones: i) su utilidad se ve restringida como mapa de línea de base, debido a que las 5.073 muestras de suelo utilizadas para la modelización fueron recolectadas en un periodo amplio de tiempo, entre 1950 y 2010, ii) las muestras fueron tomadas a profundidades

variables (por horizonte), iii) debido a la falta de datos de densidad aparente, la reserva de COS de 0 a 30 cm fue estimada a través de modelos.

Con la finalidad de generar una línea de base actual de las reservas de COS para el territorio de la República Argentina, el presente estudio tiene como objetivos: i) actualizar el mapa de almacenamiento de COS (0–30 cm, Mg ha^{-1}), ii) estimar la incertidumbre asociada a los modelos predictivos generados, iii) obtener estadísticas de almacenamiento de COS para los principales tipos de uso/cobertura del suelo del país y iv) evaluar la importancia de los principales factores que influyen en el almacenamiento de COS.

MATERIALES Y MÉTODOS

Área de estudio

El territorio de la República Argentina abarca una superficie de 2,79 millones de km^2 y es el octavo país del mundo en extensión. La geografía es muy diversa, predominando llanuras en el centro, norte y este, montañas y serranías en el oeste y mesetas en el sur. El país se encuentra atravesado, en su extremo occidental, de norte a sur por la cordillera de los Andes. Dos tercios del país presentan condiciones áridas o semiáridas a partir de una marcada diagonal que se extiende desde el noroeste hacia el centro-este y sur del país. Los climas húmedos (subtropicales, templados y fríos) se localizan en el noreste, centro-este y sur-oeste. Las precipitaciones medias anuales varían desde menos de 100 mm en la mencionada diagonal árida, hasta alrededor de 2.000 mm en el noreste y en la cordillera patagónica. Para la presente estimación de la reserva de COS a nivel nacional no se tuvieron en cuenta superficies relacionadas a cuerpos de agua permanentes, asentamientos y hielo/nieve del mapa de uso/cobertura del suelo de Argentina (Año 2020, Nivel II; Volante et al., 2024). También se excluyó superficie relacionada a roca desnuda y otras áreas sin vegetación del mapa de cobertura verde de montaña (Gaitán et al., 2022). Por lo tanto, la superficie total sobre la que se modeló y cartografió la reserva de COS fue de 2,57 millones de km^2 (92,1% del total del país).

Base de datos de COS

Se utilizaron datos de almacenamiento de COS de 5.377 sitios distribuidos en el territorio nacional (Figura 1). Las muestras de suelo fueron colectadas entre los años 2015 y 2022 en el marco de varios proyectos e iniciativas (Tabla 1). El número de sitios muestreados para los principales tipos de uso/cobertura del suelo del país (Volante et al., 2024), y para los cuales se generarán las estadísticas de almacenamiento de COS, fue como sigue: Tierras forestales 1561 (Tierras forestales nativas 1195, Otras tierras forestales nativas 270 y Plantaciones forestales 96); Tierras de cultivos 1718; Pastizales 2025 (Pastizales cerrados 1525 y Estepas arbustivo-graminosas 500) y Humedales 73. La densidad promedio de datos de suelos fue de 1,47 sitios por cada 1.000 km².




Figura 1. Diagrama de flujo metodológico que muestra la secuencia de pasos aplicados para la predicción de las reservas de carbono orgánico del suelo (COS) en Argentina. Se

utilizaron datos de COS de 5.377 sitios medidos a campo, 38 covariables ambientales y el algoritmo Random Forest para modelar y mapear la reserva de COS: percentil 5 (p5), valores medios (media) y percentil 95 (p95).

Figure 1. Methodological flowchart showing the sequence of steps applied for the prediction of soil organic carbon (SOC) stocks in Argentina. SOC data from 5,377 field-measured sites, 38 environmental covariates, and the Random Forest algorithm were used to model and map the SOC stock: 5th percentile (p5), mean values (mean), and 95th percentile (p95).

Tabla 1. Fuentes de los 5.377 sitios utilizados para modelar y mapear el almacenamiento de carbono orgánico del suelo en Argentina.

Table 1. Sources of the 5,377 sites used to model and map soil organic carbon storage in Argentina.

Fuente	N.º sitios	Profundidad de muestreo	Densidad aparente	Referencia
Observatorio Nacional de Suelos Agropecuarios (ONSA)	1000	0-20	No	Inédito
PEi040 INTA: Monitoreo de la degradación de tierras	200	0-30	Sí	Inédito
Convenio INTA-TNC: pasturas chaqueñas	231	0-30	Sí	Gaitán <i>et al.</i> , 2021
Red MARAS	131	0-10	No	Oliva <i>et al.</i> , 2020
Red PEBANPA	108	0-30	Sí	Peri <i>et al.</i> , 2016
Consultoría MAYS-INTA: C en bosques nativos	1912	0-30	Sí	Peri <i>et al.</i> , 2021
Consultoría MAYS-INTA: C en bosques implantados	517	0-30	Sí	Peri <i>et al.</i> , 2022
PDi062 INTA: Secuestro de C en el	249	0-30	Sí	Inédito.

suelo

SISINTA	269	0-30	No	http://sisinta.inta.gob.ar/
Aapresid	619	0-20	No	Inédito
Proyecto Suelos de la Región Chaco Santiagueño CREA	141	0-30	Sí	Inédito

Del total de sitios, el 67,5% fueron muestreados hasta los 30 cm de profundidad. Los sitios de muestreo fueron ubicados en áreas representativas de la cobertura del suelo de cada Ecorregión, evitando áreas poco representativas del paisaje como microdepresiones, afloramientos rocosos, etc. En cada sitio, se estableció una parcela de muestreo de entre 400 y 1000 m² en cuyo punto central se tomaron las coordenadas geográficas mediante GPS. Dentro de la parcela de muestreo se tomó una muestra compuesta de suelo (entre 3 y 10 submuestras) con barreno en dos profundidades: 0-10 y 10-30 cm. Las muestras fueron secadas a temperatura ambiente y tamizadas por malla de 2 mm. Las piedras y restos vegetales de la fracción > 2mm retenida en el tamiz fueron retirados, mientras que los agregados de suelo retenidos fueron molidos hasta que toda la fracción atravesó el tamiz. La concentración de COS de las muestras fue determinada en laboratorio por el método de combustión húmeda, siguiendo el protocolo de Walkley y Black (1934) según Norma IRAM-SAGPyA 29571-2.

Se tomaron muestras para determinar la densidad aparente del suelo con el método del cilindro (Blake y Hartge, 1986) en las profundidades 0-10 y 10-30 cm. El almacenamiento de COS (Mg ha⁻¹) fue calculado con la Ecuación 1:

Ecuación 1:

$$COS\ 0 - 30\ [Mg.\ ha - 1] = \%COS\ 0 - 30cm * DAP\ 0 - 30cm * 0,3 * (1 - FG) * 0,1$$

donde, %COS 0-30 cm es el porcentaje de COS (kg.100 kg⁻¹) de 0 a 30 cm (%COS 0-30 cm = %COS 0-10 cm × 1/3 + %COS 10-30 cm × 2/3); DAP 0-30 cm es la densidad aparente del

suelo (kg.m^{-3}) de 0 a 30 cm ($\text{DAP 0-30 cm} = \text{DAP 0-10 cm} \times 1/3 + \text{DAP 10-30 cm} \times 2/3$); 0,3 es la profundidad de muestreo (m); FG es la fracción de fragmentos gruesos en el suelo y 0,1 es un factor para expresar el resultado en Mg ha^{-1} .

Para los 1.000 sitios del Observatorio Nacional de Suelos Agropecuarios (ONSA) y los 619 de Aapresid (Asociación Argentina de Productores en Siembra Directa), cuya profundidad de muestreo fue 0-20 cm, el %COS 0-30 cm fue estimado mediante la Ecuación 2 ajustada con 375 sitios para los cuales se contó con los datos de %COS 0-20 cm y %COS 0-30 cm.

Ecuación 2

$$\%COS\ 0 - 30\ cm = 0,8234 * \%COS\ 0 - 20cm + 0,0098 \quad (R^2 = 0,97)$$

La DAP para los 1.000 sitios del ONSA, los 619 de Aapresid y los 269 sitios de Sistema de Información de Suelos del INTA (SISINTA) fue estimada mediante la Ecuación 3 ajustada con 345 sitios para los cuales se contó con datos de DAP y %COS 0-30 cm. Los datos de porcentaje de arcilla y arena, a 0-30 cm de profundidad de suelo fueron extraídos de los mapas de Schulz et al. (2022).

Ecuación 3:

$$\text{DAP } 0 - 30\text{cm} [\text{kg.m}^{-3}] = 8,95 * \% \text{Arcilla } 0 - 30\text{cm} + 5,57 * \% \text{Arena } 0 - 30\text{cm} - 86,7 * \% \text{COS } 0 - 30\text{cm} + 1077,7 \quad (R^2 = 0,34)$$

Todos los sitios utilizados en las modelizaciones de las Ecuaciones 2 y 3, tanto para calibrar como para predecir, pertenecen a la categoría Tierras de cultivos de la llanura chaco-pampeana y a suelos del orden Molisoles.

Para los 131 sitios de la red MARAS (Monitoreo Ambiental de Regiones Áridas y Semiáridas) que solo contaron con datos de %COS 0-10 cm, el almacenamiento de COS (Mg ha^{-1} , 0-30 cm) se estimó a partir de la Ecuación 4 ajustada con 121 sitios de la red

PEBANPA (Parcelas de Ecología y Biodiversidad de ambientes naturales en Patagonia Austral) para los cuales se contó con los datos de %COS 0-10 cm y COS Mg ha⁻¹ 0-30 cm:

Ecuación 4:

$$COS\ 0 - 30cm\ [Mg.\ ha - 1] = 33,46\ x\ * \%COS\ 0 - 10cm + 6,33 \quad (R^2 = 0,98)$$

Variables ambientales predictoras

Se seleccionó un conjunto de 38 variables climáticas, topográficas, edáficas y de vegetación potencialmente predictoras del almacenamiento de COS (McBratney et al., 2003) (Tabla 2).

Todos los mapas de las covariables fueron obtenidos, calculados o cargados en la plataforma Google Earth Engine (GEE) para el modelado posterior. La resolución original de cada covariable fue escalada a una resolución común de 250 m utilizando el método resample ("bilinear"). Este método estima el valor de cada nuevo píxel como un promedio ponderado de los cuatro píxeles más cercanos en la imagen original, lo que permite suavizar las transiciones y minimizar errores asociados a cambios bruscos en los valores.

Variables climáticas: entre las variables climáticas consideradas, se obtuvieron datos de precipitación media anual y de temperatura máxima, mínima y media anual (1970-2000) de la base de datos global Worldclim. Además, se incluyeron 17 variables bioclimáticas derivadas de los mapas mensuales de temperatura y precipitación (Hijmans et al., 2005), y datos de temperatura media (2001-2021) del día y de la noche obtenidos del producto MOD11A1.V6 del sensor Moderate Resolution Imaging Spectroradiometer (MODIS).

Variables topográficas: para analizar la influencia de variables topográficas, se seleccionó un conjunto de 7 mapas morfométricos generados usando el algoritmo Terrain Analysis en GEE (Tabla 2) (TAGEE, Safanelli et al., 2020). Este algoritmo utiliza el modelo digital de elevación derivado de imágenes de radar de la Shuttle Radar Topography Mission (SRTM, Farr et al., 2007).

Variables edáficas: teniendo a la arcilla y la erosión de suelos como componentes claves que influyen en el almacenamiento y patrón espacial del COS, en este estudio se utilizaron mapas nacionales de contenido de arcilla del suelo (0-30 cm de profundidad; Schulz et al., 2022) y de pérdida de suelo por erosión hídrica derivado de la ecuación universal de pérdida de suelo (USLE, por sus siglas en inglés) (Gaitán et al., 2017).

Variables de la vegetación: los índices de vegetación derivados de imágenes satelitales son ampliamente utilizados por su relación con características de la vegetación (Jackson y Huete, 1991). En este estudio, se utilizaron los índices NDVI, EVI y SAVI y la reflectancia de las bandas azul, rojo e infrarrojo cercano (Tabla 2) obtenidos del producto MOD13Q1 del sensor MODIS. Para calcular estos índices se utilizaron los datos de reflectancia media de las bandas en el período 2015-2021 previamente enmascarados para eliminar los datos con mala calidad (SummaryQA igual o mayor a 2).

Modelización

Se utilizó el algoritmo Random Forest (RF; Breiman, 2001) para predecir y mapear el almacenamiento de COS (Mg ha^{-1} , 0-30 cm) en los suelos de Argentina. Este algoritmo de aprendizaje automático construye un conjunto de árboles de regresión. Cada uno de estos árboles predice el resultado en cada pixel y la predicción final resulta del promedio de estos valores (Breiman, 2001). Cada árbol se construye a partir de una muestra seleccionada al azar del conjunto de datos originales, esto permite una estimación robusta del error con el conjunto de muestras restantes, las llamadas muestras *Out-Of-Bag*. Los valores de estas muestras excluidas se predicen a partir de las muestras seleccionadas y, al contrastar los valores previstos con los observados, se pueden calcular diferentes métricas para evaluar el rendimiento de los modelos. En cada árbol se utiliza un subconjunto de covariables predictoras, lo que permite estimar la importancia de las covariables, la cual está dada por la disminución en la precisión de la predicción antes y después de permutar una variable. Se utilizó el algoritmo Random-Forest-Recursive Feature Elimination (RF-RFE) (Gregorutti et al., 2017) para evitar la inclusión de covariables de baja correlación con el almacenamiento

de COS o el uso de covariables correlacionadas entre sí que afectan el desempeño del modelo. Este algoritmo permite seleccionar el subconjunto de covariables que tienen mayor importancia para predecir el almacenamiento de COS mediante un proceso de selección que, iterativamente, elimina los predictores con poder explicativo más débil del conjunto inicial de 38 covariables. El desempeño del modelo fue evaluado mediante un proceso de validación cruzada con 10 corridas. Para ello, el conjunto original de datos de COS fue dividido al azar en 10 conjuntos dentro de los cuales el 70% de los datos fue usado para calibrar el modelo y el 30% para validarlo. En cada paso del algoritmo RF-RFE, se calculó la media del Error Absoluto Medio (MAE) en las 10 corridas y se lo relacionó de manera gráfica con el número de covariables remanentes (APÉNDICE I). Basado en este análisis, se seleccionaron 10 covariables para modelar y mapear el almacenamiento de COS (Tabla 2). El desempeño del modelo fue evaluado en las 10 corridas de la validación cruzada mediante la media de cuatro índices: coeficiente de determinación (R^2), error cuadrático medio (RMSE), error absoluto medio (MAE) y error absoluto medio relativo a la media de las muestras (MAErel). Además, se obtuvieron los percentiles 5 (p5) y 95 (p95) de la predicción, dando como resultado mapas con los valores mínimos y máximos del valor de COS estimado en cada pixel. La incertidumbre fue estimada como la diferencia entre los percentiles p5 y p95 (90 % de intervalo de predicción) tal como fue propuesto por Heuvelink et al. (2021). Se analizó la relación entre el almacenamiento de COS y las 10 covariables identificadas como las más importantes mediante análisis de regresión simple.

Comparación del mapa actual

El mapa generado, se comparó con el mapa generado por Olmedo et al. (2018), utilizando álgebra de rasters (resta mapa actual – mapa Olmedo et al., 2018).

Almacenamiento de COS por tipos de uso/cobertura del suelo

A partir del mapa de almacenamiento de COS y del mapa de uso/cobertura del suelo Nivel I para el año 2020 (Volante et al., 2024) se obtuvieron estadísticas sobre el contenido de COS

por unidad de superficie (Mg ha⁻¹) y total (Pg C) para las categorías establecidas por el IPCC (Panel Intergubernamental sobre Cambio Climático): tierras forestales, tierras de cultivos, pastizales y humedales. La categoría tierras forestales fue desglosada en tres categorías (tierras forestales nativas, otras tierras forestales nativas y plantaciones forestales) según la cartografía a Nivel II de Volante et al. (2024), mientras que la categoría pastizales fue desglosada en dos categorías (pastizales cerrados y estepas arbustivo-graminosas). Las categorías asentamientos y otras tierras fueron consideradas sin suelo y, por lo tanto, eliminadas del mapa de COS.

Tabla 2. Covariables ambientales utilizadas como predictoras para modelar el almacenamiento de carbono orgánico del suelo en los suelos de Argentina. En negrita se muestran las 10 covariables seleccionadas para el modelo final luego de aplicar el algoritmo Random-Forest-Recursive Feature Elimination.

Table 2. Environmental covariates used as predictors to model soil organic carbon storage in Argentine soils. The 10 covariates selected for the final model after applying the Random-Forest-Recursive Feature Elimination algorithm are shown in bold.

Tipo de variable	Variable	Descripción	Unidad	Resolución Temporal	Resolución espacial original (m)	Referencia
Clima	Prec	Precipitación media anual	mm	Media 1970-2000	1000	Hijmans <i>et al.</i>, 2005
	Tmin	Temperatura mínima anual	°C	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Tavg	Temperatura media anual	°C	Media 1970-2000	1000	Hijmans <i>et al.</i>, 2005
	Tmax	Temperatura máxima anual	°C	Media 1970-2000	1000	Hijmans <i>et al.</i>, 2005
	Bio02	Rango diurno medio (T máx.-T mín.)	°C	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio03	Isotermalidad (Bio02/Bio07)	°C	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio04	Estacionalidad de la temperatura (Desvío estándar * 100)	°C	Media 1970-2000	1000	Hijmans <i>et al.</i>, 2005
	Bio05	Temperatura máxima del mes más cálido	°C	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio06	Temperatura mínima del mes más frío	°C	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio07	Rango anual de temperatura (Bio05-Bio06)	°C	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005

	Bio08	Temperatura media del trimestre más húmedo	°C	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio09	Temperatura media del trimestre más seco	°C	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio10	Temperatura media del trimestre más cálido	°C	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio11	Temperatura media del trimestre más frío	°C	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio13	Precipitación del mes más húmedo	mm	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio14	Precipitación del mes más seco	mm	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio15	Estacionalidad de la precipitación	Coef. de Variación	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio16	Precipitación del trimestre más húmedo	mm	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio17	Precipitación del trimestre más seco	mm	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio18	Precipitación del trimestre más cálido	mm	Media 1970-2000	1000	Hijmans <i>et al.</i> , 2005
	Bio19	Precipitación del trimestre más frío	mm	Media 1970-2000	1000	Hijmans <i>et al.</i>, 2005
	LST_Día	Temperatura media diurna	mm	Media 2001-2021	1000	Wan <i>et al.</i>, 2015
	LST_Noche	Temperatura media nocturna	mm	Media 2001-2021	1000	Wan <i>et al.</i>, 2015
Topografía	Elevación	Altura sobre el nivel del mar	m	No determinada	30	Safanelli <i>et al.</i> , 2020
	Pendiente	Gradiente de la pendiente	Grados	No determinada	30	Safanelli <i>et al.</i> , 2020
	Aspecto	Dirección de la brújula	Grados	No determinada	30	Safanelli <i>et al.</i> , 2020
	Hillshade	Brillo del terreno iluminado	Sin unidades	No determinada	30	Safanelli <i>et al.</i> , 2020
	Northness	Grados de orientación al norte	Sin unidades	No determinada	30	Safanelli <i>et al.</i> , 2020
	Eastness	Grados de orientación al este	Sin unidades	No determinada	30	Safanelli <i>et al.</i> , 2020
	Shape Index	Clasificación Gaussiana de la forma del terreno	Sin unidades	No determinada	30	Safanelli <i>et al.</i> , 2020
Suelo	% Arcilla	Contenido de arcilla (0-30 cm)	%	No determinada	750	Schulz <i>et al.</i>, 2022
	Erosión Hídrica	Tasa de pérdida de suelo	t.ha ⁻¹ .año ⁻¹	No determinada	200	Gaitán <i>et al.</i> , 2017
Vegetación	NDVI	Índice de vegetación de diferencia normalizada	Sin unidades	Media 2015-2021	250	Rouse <i>et al.</i> , 1973
	EVI	Índice de vegetación mejorado	Sin unidades	Media 2015-2021	250	Huete <i>et al.</i> , 2002
	SAVI	Índice de vegetación ajustado por suelo	Sin unidades	Media 2015-2021	250	Huete, 1988
	Banda azul	Reflectancia de superficie banda azul	Sin unidades	Media 2015-2021	250	MODIS/061/MOD13Q1
	Banda roja	Reflectancia de superficie banda roja	Sin unidades	Media 2015-2021	250	MODIS/061/MOD13Q1
	Banda infrarrojo cercano	Reflectancia de superficie banda infrarrojo cercano	Sin unidades	Media 2015-2021	250	MODIS/061/MOD13Q1

RESULTADOS

En la Figura 2a se muestra el mapa de almacenamiento de COS (Mg ha⁻¹, 0-30 cm) en los suelos de la República Argentina. La reserva media de COS a nivel nacional fue

estimada en $51,35 \text{ Mg ha}^{-1}$. El análisis de incertidumbre de la predicción muestra que este valor medio puede encontrarse en el rango $49,24\text{-}53,50 \text{ Mg ha}^{-1}$ con un 90% de probabilidad ($p5 - p95$). El almacenamiento total de COS en los suelos de Argentina fue estimado en $13,19 \text{ PgC}$, pudiendo variar entre $12,64$ y $13,74 \text{ PgC}$ considerando la incertidumbre. El rango de variación de la incertidumbre ($p95$ menos $p5$) se halló entre $1,8\text{-}15,5 \text{ Mg ha}^{-1}$, con una media de $4,3 \text{ Mg ha}^{-1}$, que representa el 8,5% de la reserva media de COS. El patrón espacial de la incertidumbre muestra que los mayores valores tienden a ubicarse en las áreas con mayor reserva de COS (Figura 2b). Los parámetros que permiten evaluar el desempeño del modelo de RF para predecir los valores de COS fueron (promedio de 10 corridas): $R^2 = 0,73$; $\text{RMSE} = 29,2 \text{ (Mg ha}^{-1}\text{)}$; $\text{MAE} = 17,8 \text{ (Mg ha}^{-1}\text{)}$ y $\text{MAErel} = 0,24$. Los mapas de la estimación media y los percentiles 5 y 95 (Mg ha^{-1}) se pueden descargar en formato raster del siguiente link: <https://doi.org/10.5281/zenodo.15288600>.




Figura 2. Mapa de almacenamiento de carbono orgánico del suelo (COS) (Mg ha^{-1} , 0-30 cm) en los suelos de Argentina (a) y mapa de incertidumbre de la predicción (b).

Figure 2. Soil organic carbon (COS) storage map (Mg ha^{-1} , 0-30 cm) of Argentine soils (a) and prediction uncertainty map (b).

El almacenamiento total de COS estimado en el presente estudio fue un 16% menor al estimado por Olmedo et al. (2018) ($15,71 \text{ PgC}$). Sin embargo, debe considerarse que ambos estudios fueron modelados sobre superficies diferentes: el mapa de Olmedo et al (2018) solo excluye los cuerpos de agua y no así otras superficies sin suelo (asentamientos, hielo/nieve, roca desnuda). Por lo tanto, al realizar la comparación sobre la misma superficie hallamos que el almacenamiento total de COS del presente estudio fue un 5,7% menor respecto al del mencionado estudio previo. La Figura 3 muestra el patrón espacial de las diferencias entre ambas estimaciones: mapa actual – mapa Olmedo et al. (2018).




Figura 3. Diferencia en la reserva de carbono orgánico del suelo (Mg ha^{-1} , 0-30 cm) estimada en el estudio actual y el estudio de Olmedo et al. (2018).

Figure 3. Differences in soil organic carbon storage (Mg ha^{-1} , 0-30 cm) estimated in the current study and the study by Olmedo et al. (2018).

El algoritmo RF-RFE permitió seleccionar las 10 covariables más importantes para modelar y mapear el almacenamiento de COS. El clima, especialmente la temperatura, parece ejercer el principal control del COS a escala nacional, dado que, de las 10 variables, siete fueron climáticas (cinco de temperatura y dos de precipitación). Dos variables correspondieron a características de la vegetación extraídas de imágenes satelitales (índice SAVI y reflectancia en la banda azul), y una variable fue edáfica (% de arcilla) (Figura 4). En la Figura 4 se muestran las relaciones bivariadas entre el stock de COS y las 10 covariables

en los 5.377 sitios medidos a campo. Las variables asociadas con la temperatura (Figura 5) son las que, individualmente, explican una mayor proporción de la variabilidad del stock de COS, relacionándose en forma negativa. El contenido de arcilla se relacionó en forma positiva con el COS, aunque en los suelos del Orden Andisoles (bosque andinopatagónico) se observó un patrón diferente al resto de los Órdenes de suelo. El índice satelital de vegetación SAVI mostró una relación positiva con el COS, mientras que la reflectancia en la banda azul lo hizo en forma negativa. Las variables de precipitación mostraron la relación más baja con el COS, sin un patrón claro.










Figura 4. Importancia de las covariables para el modelado del almacenamiento de carbono orgánico del suelo. Referencias: LST_Día: Temperatura media diurna; Bio04: Estacionalidad de la temperatura (Desvío estándar * 100); Banda azul: Reflectancia de superficie Banda Azul; SAVI: Índice de vegetación ajustado por suelo; %Arcilla: Contenido de arcilla (0-30 cm); Prec: Precipitación media anual; LST_Noche: Temperatura media nocturna; Tavg: Temperatura media anual; Tmáx.: Temperatura máxima anual; Bio19: Precipitación del trimestre más frío.

Figure 4. Importance of covariates for soil organic carbon storage modelling. References: LST_Día: Mean daytime temperature; Bio04: Temperature seasonality (Standard deviation * 100); Banda Azul: Blue Band surface reflectance; SAVI: Soil-adjusted vegetation index; %Arcilla: Clay content (0-30 cm); Prec: Mean annual precipitation; LST_Noche: Mean

nighttime temperature; Tavg: Mean annual temperature; Tmax: Maximum annual temperature;

Bio19: Precipitation of the coldest quarter.






Figura 5. Relación entre el stock de carbono orgánico del suelo (COS) y las 10 covariables utilizadas para el modelado del almacenamiento de COS en la República Argentina: temperatura media máxima anual (a), estacionalidad de la temperatura (desvío estándar * 100) (b), temperatura media diurna (c), temperatura media anual (d), temperatura media nocturna (e), contenido de arcilla (símbolos vacíos corresponden a suelos del Orden Andisoles y símbolos llenos a otros Órdenes de suelo) (f), reflectancia en la banda azul (g), índice SAVI (h), precipitación media anual (i) y precipitación del trimestre más frío (j).

Figure 5. Relationship between soil organic carbon (COS) stock and the 10 covariates used for modeling SOC storage in Argentina: mean annual maximum temperature (a), temperature seasonality (standard deviation * 100) (b), mean daytime temperature (c), mean annual temperature (d), mean nighttime temperature (e), clay content (empty symbols correspond to soils of the Order Andisols and filled symbols correspond to other soil Orders) (f), reflectance in the blue band (g), SAVI index (h), mean annual precipitation (i), and precipitation of the coldest quarter (j).

En la Tabla 3 se muestran los datos de superficie, reserva de COS por hectárea y reserva de COS total para las cuatro principales categorías de uso/cobertura del suelo establecidas por el IPCC y tomadas del mapa Nivel I para el año 2020 (Volante et al., 2024). La reserva de COS por hectárea sigue el siguiente gradiente: Humedales > Tierras forestales > Tierras de cultivos > Pastizales. Sin embargo, al considerar la reserva total, los Pastizales acumularon el 61% del COS total del país, las Tierras forestales el 23%, las Tierras de cultivos el 13% y los Humedales el 3%. Al considerar el Nivel II de la cartografía de uso/cobertura del suelo, los Pastizales fueron desglosados en dos categorías: los Pastizales cerrados, cuya reserva de COS por hectárea es alrededor de un 30% mayor que en las Estepas arbustivo-graminosas, aunque estas últimas, debido a su mayor superficie, representan el 35% de la reserva total de COS del país. Las Tierras forestales fueron desglosadas en tres categorías, cuya reserva media de COS sigue el orden: Tierras forestales nativas > Plantaciones forestales > Otras tierras forestales nativas.

Tabla 3. Reserva de carbono orgánico del suelo (COS) por hectárea (media $\pm$ desvío estándar), superficie y reserva de COS total para las categorías Tierras forestales (Tierras forestales nativas, Otras tierras forestales nativas y Plantaciones forestales), Tierras de cultivos, Pastizales (Pastizales cerrados y Estepas arbustivo-graminosas) y Humedales (Volante et al., 2024).

Table 3. Soil organic carbon (COS) stock per hectare (mean $\pm$ standard deviation), area and total COS stock for the categories Forest land (Native forest land, Other native forest land and Forest plantations), Cropland, Grassland (Closed grassland and Shrub-grass steppe) and Wetlands (Volante et al., 2024).

Clase uso/cobertura del suelo	Reserva media	Superficie	Reserva	%
	COS (Mg ha ⁻¹)	(Millones ha)	total COS	
			(Pg)	

Tierras forestales	54,62 $\pm$ 27,7	55,08	3,09	22,75
<i>Tierras forestales nativas</i>	66,31 $\pm$ 27,5	31,65	2,09	15,39
<i>Otras tierras forestales nativas</i>	43,33 $\pm$ 23,2	22,43	0,97	7,14
<i>Plantaciones forestales</i>	52,51 $\pm$ 28,4	1,00	0,03	0,22
Tierras de cultivos	53,07 $\pm$ 21,5	32,53	1,73	13,07
Pastizales	49,76 $\pm$ 21,2	162,43	8,08	61,17
<i>Pastizales cerrados</i>	58,38 $\pm$ 22,8	60,17	3,46	26,19
<i>Estepas arbustivo-graminosas</i>	45,62 $\pm$ 19,0	102,26	4,62	34,98
Humedales	58,58 $\pm$ 25,7	6,78	0,40	3,01
Superficie sin suelo	-	22,41	-	-
Total	51,35 $\pm$ 22,6	279,23	13,19	100

DISCUSIÓN

Los resultados obtenidos, indican que el COS almacenado en los suelos de la Argentina representa aproximadamente el 1,95 % de la reserva mundial para los primeros 30 cm del perfil edáfico, estimada en el estudio global de FAO e ITPS (2018). Asimismo, los resultados ratifican a Random Forest como un poderoso algoritmo de aprendizaje automático para modelar el almacenamiento de COS, aspecto ya informado en varios estudios previos (e.g. Lamichhane et al.; 2019; Gomes et al., 2019; Ellili et al., 2019). El algoritmo RF-RFE no mejoró el rendimiento del modelo, como encontraron Stevens et al. (2013), pero la selección del mejor subconjunto de covariables (de un total de 38 a 10 covariables), redujo considerablemente el tiempo de procesamiento. Esto resulta un aspecto particularmente relevante para la evaluación de grandes superficies, como lo es el territorio de la República Argentina. La incertidumbre en la predicción derivada del modelo, con un 90% de probabilidad, fue, en promedio, equivalente al 8,5% de la estimación media. Este resultado es consistente con lo hallado por Kempen et al. (2019), quienes sugieren que una distribución adecuada de puntos, bajo un esquema de muestreo no probabilístico, repercute en la obtención de incertidumbres bajas.

Los resultados difieren considerablemente con el mapa previamente publicado por Olmedo et al. (2018), con diferencias mayores o menores a 30 Mg ha^{-1} en regiones particulares del país. Sin embargo, el total de toneladas estimadas fue levemente menor (5,7%) y con diferencias espaciales marcadas entre regiones. Las mayores diferencias se observan en la llanura Chaco pampeana, selva de Yungas y el sur de la Patagonia donde el presente estudio estima reservas de COS entre 0 y -30 Mg ha^{-1} en relación con el estudio previo, mientras que en la diagonal árida central y el sudeste Bonaerense la estimación actual es entre 0 y $+20 \text{ Mg ha}^{-1}$ y en la provincia de Misiones mayor a $+20 \text{ Mg ha}^{-1}$. Las discrepancias observadas entre el presente estudio y el de Olmedo et al. (2018), pueden deberse a que en nuestro estudio se utilizó una base de datos reciente y homogénea (2015–2022), con observaciones de carbono a 0–30 cm y densidad aparente medida o estimada bajo protocolos estandarizados. En contraste, Olmedo et al. (2018) utilizaron datos recolectados entre 1950 y 2010, a profundidades variables y con estimaciones indirectas de densidad aparente., lo que puede influir significativamente en los valores obtenidos. Aunque no puede determinarse de forma absoluta cuál estimación es más precisa, consideramos que los valores presentados en este trabajo reflejan mejor las condiciones actuales del suelo, debido a la actualidad de los datos y a la robustez del enfoque metodológico. No obstante, se reconoce la necesidad de continuar fortaleciendo la base empírica en regiones con alta variabilidad, así como de explorar técnicas complementarias para representar de manera más explícita la incertidumbre y la estructura espacial de los datos.

Las reservas de COS son el resultado del equilibrio entre las entradas y salidas de C en los suelos; varios factores afectan este equilibrio dependiendo de las condiciones climáticas (Davidson y Janssens, 2006) y las características locales como la vegetación (Jobbágy y Jackson, 2000; Berhongaray y Álvarez, 2019), la topografía (Tang et al., 2017) y el manejo del suelo (Martínez et al., 2008). En este trabajo, se encontró una relación negativa entre la temperatura y el COS. Este patrón está respaldado por otros estudios que muestran que el contenido de materia orgánica del suelo disminuye con el aumento de la temperatura (Nian-Peng et al., 2014; Ke et al., 2024), como resultado del aumento de las tasas de

mineralización por mayor actividad de los microorganismos del suelo (McDaniel y Munn 1985; Raich y Schlesinger 1992 ; Kirschbaum,1995). El porcentaje de arcilla se relacionó en forma positiva con el COS, lo que coincide con otros estudios que analizaron los factores que controlan el almacenamiento de COS (eg., Burke et al., 1989; Buschiazzo et al., 1991; Nian-Peng et al., 2014; Álvarez y Berhongaray, 2021). Esto podría deberse a que la arcilla protege activamente la materia orgánica por adsorción y agregación, ralentizando la mineralización y aumentando los tiempos de residencia del COS (Paul, 1984; Schimel et al., 1985). Además, la textura influye sobre la disponibilidad de agua del suelo: a mayor contenido de arcilla aumenta la capacidad de retención de agua de los suelos (Rawls et al., 2003 ; Saxton y Rawls, 2006). Esto suele tener un efecto positivo en la PPN y en el aporte de materia orgánica al suelo (Huenneke y Schlesinger, 2006). Los suelos del Orden Andisoles que se desarrollan en la cordillera patagónica y donde domina la cobertura de bosques, presentaron un patrón diferente en la relación entre el contenido de arcilla y la reserva de COS. Estos suelos muestran, para un mismo contenido de arcilla, una mayor reserva de COS respecto a los suelos de otros Órdenes. En los Andisoles, el elevado contenido de COS se atribuye a la formación de complejos estables de sustancias húmicas con aluminio, hierro y constituyentes no cristalinos, derivados de las cenizas volcánicas que dan origen a estos suelos, que los protegen de la degradación microbiana (Gaitán y López, 2007). A su vez, estos microagregados estables son difíciles de dispersar por los métodos tradicionales, y se comportan como una partícula más gruesa que enmascara la granulometría verdadera del suelo (i.e., pseudolimos o pseudoarenas), de modo que no puede descartarse una subestimación de las partículas tamaño arcilla.

La relación positiva entre el COS y el índice SAVI (como un proxy de la biomasa de la vegetación) también es consistente con otros estudios (Gaitán et al., 2019) y se relaciona con un mayor aporte de materia orgánica desde la vegetación. Por el contrario, la relación negativa entre el COS y la reflectancia en la banda azul puede deberse a que el suelo desnudo presenta una reflectancia relativamente mayor a la de la vegetación en esta banda. Por lo tanto, mayores valores de reflectancia en el azul indicarían mayor proporción de suelo

desnudo, con bajo aporte de materia orgánica desde la vegetación y, por ende, bajos valores de COS. De esta forma, los resultados evidencian la retroalimentación positiva que existe entre el contenido de arcilla, PPN y COS o, por el contrario, una retroalimentación negativa entre pérdida de cobertura vegetal (i.e. mayor suelo desnudo) y pérdida de carbono (i.e. por menor aporte de carbono y/o erosión de suelo) (Lei et al., 2019; Lal, 2020).

El análisis del almacenamiento de COS para los principales tipos de uso/cobertura del suelo del país mostró que las Tierras forestales nativas tienen la mayor reserva por unidad de superficie, debido al alto aporte de biomasa vegetal que realiza la vegetación leñosa. En segundo lugar, se encuentran los Pastizales cerrados, ubicados en zonas húmedas, y los Humedales, ubicados en áreas inundables donde la escasez de O_2 limita la actividad de los microorganismos que mineralizan la materia orgánica que, por lo tanto, tiende a acumularse (Kayranli et al., 2010). A continuación, se encuentran las categorías de agroecosistemas transformados por la actividad antrópica: Cultivos y Plantaciones forestales. Por último, las categorías con menor reserva de COS por hectárea son las Estepas arbustivo-graminosas y las Otras tierras forestales nativas, las cuales se encuentran en extensas superficies de zonas áridas y semiáridas (Estepa patagónica, Monte y Puna), que representan ecosistemas limitados por el agua, y donde la productividad de la vegetación y, por lo tanto, el aporte de materia orgánica al suelo es relativamente bajo (Whitford 2002).

Este estudio presenta una estimación a escala nacional del COS utilizando una base de datos robusta y actualizada, junto con técnicas de modelización basadas en aprendizaje automático. No obstante, se reconocen algunas limitaciones metodológicas. En primer lugar, no se consideró explícitamente la autocorrelación espacial en el proceso de calibración y validación del modelo. La partición aleatoria de los datos puede haber incluido sitios geográficamente cercanos en ambos conjuntos, lo que podría conducir a una sobreestimación del desempeño predictivo debido a la similitud ambiental entre puntos próximos. Los análisis de autocorrelación espacial evidenciaron una fuerte dependencia espacial en los datos observados de COS, particularmente a distancias menores a 200 km (datos no mostrados). En línea con lo planteado por Kmoch et al. (2025), la autocorrelación

espacial es una característica inherente a los datos ambientales espaciales y no puede eliminarse completamente, incluso al utilizar métodos que incorporan explícitamente coordenadas o estructuras espaciales. De hecho, los autores destacan que “incluso los modelos geoestadísticos o los algoritmos como ‘Random Forest Spatial Interpolation’ no eliminan por completo la dependencia espacial residual”. A pesar de ello, consideramos que la amplia cobertura geográfica y la diversidad ambiental de los puntos muestreados en nuestro estudio contribuyen en parte a mitigar este efecto, aunque no lo reemplazan. Por lo tanto, recomendamos que futuros estudios implementen esquemas de validación espacial que aseguren mayor independencia entre los conjuntos de entrenamiento y validación, como la partición por bloques geográficos o regiones ecológicas. En segundo lugar, si bien la base de datos utilizada es actual y consistente (2015–2022), su rango temporal acotado impidió incorporar la dimensión temporal en la modelización, a diferencia de otros estudios que analizan tendencias a largo plazo mediante series históricas más extensas (e.g., Heuvelink et al., 2021). Esto restringe la posibilidad de evaluar dinámicas temporales del COS, como acumulaciones o pérdidas asociadas a cambios en el uso del suelo o prácticas de manejo. En futuras versiones del mapa recomendamos incorporar técnicas espacio-temporales en la modelización, especialmente si se dispone de series temporales más extensas o si se busca modelar tendencias de cambio.

Las estimaciones de reservas de COS a nivel nacional presentadas en este mapa proporcionan una línea de base para iniciativas y estudios de secuestro de C asociados al cambio de uso del suelo y/o la intensificación agropecuaria. Un manejo sustentable de las tierras debe mantener y/o incrementar las reservas de COS, que mejora la fertilidad y productividad de los suelos. Esto contribuye a los Objetivos de Desarrollo Sostenible (ODS) de acción por el clima (meta 13.2), de neutralidad de la degradación de tierras (meta 15.3), y de hambre cero (metas 2.1 y 2.4). Sin embargo, se requiere de estudios e iniciativas focalizadas que permitan definir mejores escenarios para resolver las limitaciones particulares que se presentan en los diferentes sistemas y ecorregiones. Los suelos y la agricultura pueden representar al mismo tiempo soluciones para problemas globales como

el cambio climático (ODS 13) y promover la seguridad alimentaria (ODS 2). Esto ha dado lugar a varias iniciativas internacionales, a las que la Argentina adhiere, que buscan conservar e incrementar la reserva de COS. Por ejemplo, el Acuerdo de París (COP21) en el contexto de la Convención Marco de las Naciones Unidas sobre el Cambio Climático de 2015, promueve la reducción de las emisiones de gases de efecto invernadero y el aumento de los sumideros para la mitigación del cambio climático. También la Convención de las Naciones Unidas de Lucha contra la Desertificación, como organismo custodio del indicador 15.3.1 de los Objetivos de Desarrollo Sostenible, ha adoptado el mapeo de las reservas de COS como uno de los indicadores para estimar el área de tierras degradadas en el contexto de monitorear la meta de alcanzar la neutralidad en la degradación de las tierras hacia el año 2030.

CONCLUSIONES

La metodología utilizada en este estudio, basada en algoritmos de aprendizaje automático, se puede aplicar con éxito para mapear las reservas de COS y la incertidumbre asociada a escala nacional, optimizando el proceso al seleccionar sólo las variables más importantes y el mejor modelo. Los suelos argentinos almacenan 13,19 PgC en los primeros 30 cm de profundidad, representando el 1,95% de la reserva global. La temperatura fue la covariable más importante influyendo en forma negativa en la distribución de las reservas de COS. Estos resultados podrían tener importantes implicaciones en el contexto del cambio climático global, dado que el aumento proyectado en la temperatura podría inducir una disminución en la reserva de COS. Las tierras forestales nativas son la categoría de uso/cobertura del suelo con mayor reserva de COS por unidad de superficie ($66,3 \text{ Mg ha}^{-1}$), mientras que las estepas arbustivo-graminosas y los pastizales cerrados son las categorías con mayor reserva absoluta con el 35% y el 25% del total del país, respectivamente.

El mapa del presente estudio, y sus futuras actualizaciones, podrá ser utilizado para reportar avances (o retrocesos) del país respecto de sus compromisos internacionales, así como también para diseñar estrategias de uso y manejo del suelo que permitan mantener y/o

incrementar las reservas de COS. Para ello resulta fundamental sostener redes de sitios de monitoreo permanentes y a largo plazo que permitan la actualización periódica del mapa.

REFERENCIAS

- Alvarez, R., y Berhongaray, G. (2021). Soil organic carbon sequestration potential of Pampean soils: comparing methods and estimation for surface and deep layers. *Soil Research*, 59(4), 346-358. <https://doi.org/10.1071/SR20257>
- Batjes, N. H. (2016). Harmonized soil property values for broad-scale modelling (WISE30sec) with estimates of global soil carbon stocks. *Geoderma*, 269, 61-68. <https://doi.org/10.1016/j.geoderma.2016.01.034>
- Battle-Aguilar, J., Brovelli, A., Porporato, A., y Barry, D. A. (2011). Modelling soil carbon and nitrogen cycles during land use change. A review. *Agronomy for Sustainable Development*, 31, 251-274. <https://doi.org/10.1051/agro/2010007>
- Berhongaray, G., y Alvarez, R. (2019). Soil carbon sequestration of Mollisols and Oxisols under grassland and tree plantations in South America-A review. *Geoderma Regional*, 18, e00226. <https://doi.org/10.1016/j.geodrs.2019.e00226>
- Blake, G. R. y Hartge, K. H. (1986). Bulk density. A. Klute (Ed.), *Methods of Soil Analysis. Part 1. Physical and Mineralogical Methods* (pp. 363-375). American Society of Agronomy - Soil Science Society of America Publisher, Madison, WI, USA (1986),
- Brady, N. C. y Weil, R. R. (2002). *The Nature and Properties of Soils* (13th Edition). Prentice Hall.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>
- Burke, I. C., Yonker, C. M., Parton, W. J., Cole, C. V., Flach, K., y Schimel, D. S. (1989). Texture, climate, and cultivation effects on soil organic matter content in US grassland soils. *Soil Science Society of America Journal*, 53(3), 800-805. <https://doi.org/10.2136/sssaj1989.03615995005300030029x>

- Buschiazzo, D. E., Quiroga, A. R., y Stahr, K. (1991). Patterns of organic matter accumulation in soils of the semiarid Argentinian Pampas. *Zeitschrift für Pflanzenernährung und Bodenkunde*, 154(6), 437-441. <https://doi.org/10.1002/jpln.19911540608>
- Davidson, E. A., y Janssens, I. A. (2006). Temperature sensitivity of soil carbon decomposition and feedbacks to climate change. *Nature*, 440(7081), 165-173. <https://doi.org/10.1038/nature04514>
- Ellili, Y., Walter, C., Michot, D., Pichelin, P., y Lemerrier, B. (2019). Mapping soil organic carbon stock change by soil monitoring and digital soil mapping at the landscape scale. *Geoderma*, 351, 1-8. <https://doi.org/10.1016/j.geoderma.2019.03.005>
- FAO. (2001). *Soil organic sequestration for improved land management*. Food and Agriculture Organization of the United Nations.
- FAO e ITPS. (2018). *Global soil organic carbon map (gsocmap) technical report*. Food and Agriculture Organization of the United Nations.
- Farr, T. G., Rosen, P. A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D. y Alsdorf, D. (2007). The shuttle radar topography mission. *Reviews of Geophysics*, 45(2), 1-33. <https://doi.org/10.1029/2005RG000183>
- Feeney, C. J., Cosby, B. J., Robinson, D. A., Thomas, A., Emmett, B. A., y Henrys, P. (2022). Multiple soil map comparison highlights challenges for predicting topsoil organic carbon concentration at national scale. *Scientific Reports*, 12(1), 1379. <https://doi.org/10.1038/s41598-022-05476-5>
- Folberth, C., Skalský, R., Moltchanova, E., Balkovič, J., Azevedo, L. B., Obersteiner, M., y Van Der Velde, M. (2016). Uncertainty in soil data can outweigh climate impact signals in global crop yield simulations. *Nature communications*, 7(1), 11872. <https://doi.org/10.1038/ncomms11872>
- Gaitán, J. J., y López, C. R. (2007). Análisis del gradiente edáfico en la región Andino-patagónica. *Ciencia del Suelo*, 25(1), 53-63.

Gaitán, J. J., Navarro, M.F., Tenti, L., Pizarro, M.J., Carfagno, P. y Rigo, S. (2017).

Estimación de la pérdida de suelo por erosión hídrica en la República Argentina.

Ediciones INTA. <http://hdl.handle.net/20.500.12123/1981>

Gaitán, J. J., Maestre, F., Buono, G., Bran, D., Dougill, A., García Martínez, G., Ferrante, D., Guuroh, R., Lindstaeter, A., Massara, V., Thomas, A. y Oliva, G. (2019). Biotic and abiotic factors controlling soil organic C content have similar effects in regional and global drylands. *Ecosystems*, 4, 1141-1151. <https://doi.org/10.1007/s10021-019-00348-y>

Gaitán, J. J., Acuña, F., Agüero, W., Álvarez, C. A., Ballón, M., Banegas, N., Barraza, G., Bassanetti, A., Blanco, L., Caballero, E., Cavallero, M. I., Céspedes, F. E., Córdoba, A., Cortez, D., De Abelleira, D., Fernández, H., Flores, J., Gándara, L., Garay, D., ... Ybarra, D. D. (2021). *Cartografía del estado de degradación de las pasturas del Gran Chaco Americano*. Informe Convenio de Asistencia Técnica INTA-The Nature Conservancy. <https://doi.org/10.13140/RG.2.2.32026.16321>

Gaitán, J. J., Testani, M. L., Micou, A. P., Parmuchi, G., Schofrin, A., Céliz, Y. y Rojo, V. (2022). *Ficha metodológica para el cálculo del índice de cobertura verde de montaña (ICVM) de la República Argentina*. MAYyDS, CONICET, IGN.

Gomes, L. C., Faria, R. M., de Souza, E., Veloso, G. V., Schaefer, C. E. G., y Fernandes Filho, E. I. (2019). Modelling and mapping soil organic carbon stocks in Brazil. *Geoderma*, 340, 337-350. <https://doi.org/10.1016/j.geoderma.2019.01.007>

Gregorutti, B., Michel, B., y Saint-Pierre, P. (2017). Correlation and variable importance in random forests. *Statistics and Computing*, 27, 659-678. <https://doi.org/10.1007/s11222-016-9646-1>

Heuvelink, G. B. M., Angelini, M. E., Poggio, L., Bai, Z., Batjes, N. H., Van den Bosch, R., Bossio, D., Estella, S., Lehmann, J., Olmedo, G. F. y Sanderman, J. (2021). Machine learning in space and time for modelling soil organic carbon change. *European Journal of Soil Science*, 72, 1607-1623. <https://doi.org/10.1111/ejss.12998>

- Hijmans, R. J., Cameron, S. E., Parra, J. L., Jones, P. G., y Jarvis, A. (2005). Very high resolution interpolated climate surfaces for global land areas. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 25(15), 1965-1978.
<https://doi.org/10.1002/joc.1276>
- Holz, M., y Augustin, J. (2021). Erosion effects on soil carbon and nitrogen dynamics on cultivated slopes: A meta-analysis. *Geoderma*, 397, 115045.
<https://doi.org/10.1016/j.geoderma.2021.115045>
- Huenneke, L. F., y Schlesinger, W. H. (2006). Patterns of net primary production in Chihuahuan Desert ecosystems. *Structure and function of a Chihuahuan Desert ecosystem: the Jornada Basin Long-term Ecological Research Site* (pp. 232-46). Oxford University Press.
- Huete, A.R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295-309.
- Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X. y 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.
- IPCC. (2000). Special Report on Emissions Scenarios. *Intergovernmental Panel on Climate Change*. Cambridge University Press.
- IUCN. (2015). Land degradation neutrality: implications and opportunities for conservation. Technical Brief (2nd edition), IUCN, Nairobi.
- Jackson, R. D., y Huete, A. R. (1991). Interpreting vegetation indices. *Preventive Veterinary Medicine*, 11(3-4), 185-200.
- Jenny, H. (1941). *Factors of Soil Formation*. McGraw-Hill.
- Jobbágy, E. G., y Jackson, R. B. (2000). The vertical distribution of soil organic carbon and its relation to climate and vegetation. *Ecological applications*, 10(2), 423-436.
[https://doi.org/10.1890/1051-0761\(2000\)010\[0423:TVDOSO\]2.0.CO;2](https://doi.org/10.1890/1051-0761(2000)010[0423:TVDOSO]2.0.CO;2)

Kayranli, B., Scholz, M., Mustafa, A., y Hedmark, Å. (2010). Carbon storage and fluxes within freshwater wetlands: a critical review. *Wetlands*, 30, 111-124.

<https://doi.org/10.1007/s13157-009-0003-4>

Ke, P., Ciais, P., Sitch, S., Li, W., Bastos, A., Liu, Z., Xu, Y., Gui, X., Bian, J., Goll, D. S., Xi, Y., Li, W., O'Sullivan, M., Goncalves De Souza, J., Friedlingstein, P. y Chevallier, F. (2024). Low latency carbon budget analysis reveals a large decline of the land carbon sink in 2023. *National Science Review*, 11(12), nwae367.

<https://doi.org/10.1093/nsr/nwae367>

Kempen, B., Dalsgaard, S., Kaaya, A. K., Chamuya, N., Ruipérez-González, M., Pekkarinen, A., y Walsh, M. G. (2019). Mapping topsoil organic carbon concentrations and stocks for Tanzania. *Geoderma*, 337, 164-180.

<https://doi.org/10.1016/j.geoderma.2018.09.011>

Kirschbaum, M. U. (1995). The temperature dependence of soil organic matter decomposition, and the effect of global warming on soil organic C storage. *Soil Biology and Biochemistry*, 27(6), 753-760. [https://doi.org/10.1016/0038-](https://doi.org/10.1016/0038-0717(94)00242-S)

[0717\(94\)00242-S](https://doi.org/10.1016/0038-0717(94)00242-S)

Kmoch, A., Harrison, C. T., Choi, J., y Uuemaa, E. (2025). Spatial autocorrelation in machine learning for modelling soil organic carbon. *Ecological Informatics*, 103057.

<https://doi.org/10.1016/j.ecoinf.2025.103057>

Lal, R. (2004). Soil carbon sequestration impacts on global climate change and food security. *Science*, 304(5677), 1623-1627.

<https://www.science.org/doi/10.1126/science.1097396>

Lal, R. (2020). Managing soils for negative feedback to climate change and positive impact on food and nutritional security. *Soil Science and Plant Nutrition*, 66(1), 1-9.

<https://doi.org/10.1080/00380768.2020.1718548>

Lei, L., Zhang, K., Zhang, X., Wang, Y. P., Xia, J., Piao, S., Hui, D., Zhong, M., Ru, J., Zhou, Z., Song, H., Yang, Z., Wang, D., Miao, Y., Yang, F., Liu, B., Zhang, A., Yu, M., Liu, X ... Wan, S. (2019). Plant feedback aggravates soil organic carbon loss associated

- with wind erosion in northwest China. *Journal of Geophysical Research: Biogeosciences*, 124(4), 825-839. <https://doi.org/10.1029/2018JG004804>
- Lamichhane, S., Kumar, L. y Wilson, B. (2019). Digital soil mapping algorithms and covariates for soil organic carbon mapping and their implications: A review. *Geoderma*, 352, 395-413. <https://doi.org/10.1016/j.geoderma.2019.05.031>
- Le Quéré, C., Andrew, R. M., Canadell, J. G., Sitch, S., Korsbakken, J. I., Peters, G. P., Manning, A. C., Boden, T. A., Tans, P. P., Houghton, R. A., Keeling, R. F., Alin, S., Andrews, O. D., Anthoni, P., Barbero, L., Bopp, L., Chevallier, F., Chini, L. P., Ciais, P., ... y Zaehle, S. (2016). Global carbon budget 2016. *Earth System Science Data*, 8(2), 605-649. <https://doi.org/10.5194/essd-8-605-2016>
- Lorenz, K., y Lal, R. (2018). *Carbon sequestration in agricultural ecosystems*. Springer.
- Martínez, H. E., Fuentes, E. J. P. y Acevedo H. E. (2008). Carbono orgánico y propiedades del suelo. *Revista de la Ciencia del Suelo y Nutrición Vegetal*, 8(1), 68-96. <http://dx.doi.org/10.4067/S0718-27912008000100006>
- McBratney, A.B., Santos, M. M. y Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117(1-2), 3-52. [https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4)
- McDaniel, P. A., y Munn, L. C. (1985). Effect of temperature on organic carbon-texture relationships in Mollisols and Aridisols. *Soil Science Society of America Journal*, 49(6), 1486-1489. <https://doi.org/10.2136/sssaj1985.03615995004900060031x>
- McGill, W. B., y Cole, C. V. (1981). Comparative aspects of cycling of organic C, N, S and P through soil organic matter. *Geoderma*, 26(4), 267-286. [https://doi.org/10.1016/0016-7061\(81\)90024-0](https://doi.org/10.1016/0016-7061(81)90024-0)
- Minasny, B., McBratney, A. B., Malone, B. P., y Wheeler, I. (2013). Digital mapping of soil carbon. *Advances in Agronomy*, 118, 1-47. <https://doi.org/10.1016/B978-0-12-405942-9.00001-3>

- Müller, N. D. y Chaplot, V. (2015). Soil carbon losses by sheet erosion: a potentially critical contribution to the global carbon cycle. *Earth Surface Processes and Landforms*, 40(13), 1803–1813. <https://doi.org/10.1002/esp.3758>
- Nian-Peng, H. E., Ruo-Meng, W. A. N. G., Zhang, Y. H., y Quan-Sheng, C. H. E. N. (2014). Carbon and nitrogen storage in Inner Mongolian grasslands: relationships with climate and soil texture. *Pedosphere*, 24(3), 391-398. [https://doi.org/10.1016/S1002-0160\(14\)60025-4](https://doi.org/10.1016/S1002-0160(14)60025-4)
- Nijbroek, R., Piikki, K., Söderström, M., Kempen, B., Turner, K.G., Hengari, S. y Mutua, J. (2018). Soil organic carbon baselines for land degradation neutrality: Map accuracy and cost tradeoffs with respect to complexity in Otjozondjupa, Namibia. *Sustainability*, 10(5), 1610. <https://doi.org/10.3390/su10051610>
- Oliva, G., Dos Santos, E., Sofía, O., Umaña, F., Massara, V., García Martínez, G., Caruso, C., Cariac, G., Echeverreía, D., Fantozzi, A., Butti, L., Bran, D., Gaitán, J. J., Ferrante, D., Paredes, P., Domínguez, E. y Maestre, F.T. (2020). The MARAS dataset, vegetation and soil characteristics of dryland rangelands across Patagonia. *Scientific Data*, 7(1), 1-14. <https://doi.org/10.1038/s41597-020-00658-0>
- Olson, K. R., Al-Kaisi, M., Lal, R. y Cihacek, L. (2016). Impact of soil erosion on soil organic carbon stocks. *Journal of Soil and Water Conservation*, 71(3), 61A–67A. <https://doi.org/10.2489/jswc.71.3.61A>
- O'Rourke, S. M., Angers, D. A., Holden, N. M. y McBratney, A. B. (2015). Soil organic carbon across scales. *Global Change Biology* 21, 35. <https://doi.org/10.1111/qcb.12959>
- Olmedo, G. F., Angelini, M. E., Schulz, G. A., Rodríguez, D. M., Taboada, M. A., Pascale, C., Escobar, D., Guevara, M., Heuvelink, G. B. M., Colazo, J. C., Gaitán, J. J., Aleksa, A. S., Babelis, G. C., Peralta, A. R., Peralta, G., Rojas, J. M., Sainz Rozas, H. R. y Vizgarra, L. A. (2018). *Prediction stock of soil organic carbon in Argentina (1.5)* [Data set]. Zenodo. <https://doi.org/10.5281/zenodo.6323695>
- Olsson, L., Cotrufo, F., Crews, T., Franklin, J., King, A., Mirzabaev, A., Scown, M., Tengberg, A., Villarino, S. y Wang, Y. (2023). The State of the World's Arable Land. *Annual*

Review of Environment and Resources, 48(1), 451-475.

<https://doi.org/10.1146/annurev-environ-112320-113741>

Paul, E. A. (1984). Dynamics of organic matter in soils. *Plant and Soil*, 76, 275-285.

<https://doi.org/10.1007/BF02205586>

Peri, P. L., Lencinas, M. V., Bousson, J., Lasagno, R., Soler, R., Bahamonde, H. y Pastur, G. M. (2016). Biodiversity and ecological long-term plots in Southern Patagonia to support sustainable land management: The case of PEBANPA network. *Journal for Nature Conservation*, 34, 51-64. <https://doi.org/10.1016/j.jnc.2016.09.003>

Peri, P. L., Gaitán, J. J., Mastrangelo, M., Nosoetto, M., Villagra, P. E., Balducci, E., Pinazo, M., Ecclesia, R. P., Von Wallis, A., Villarino, S., Gonzalez Polo, M., Manrique, S., Meglioli, P. A., Fernández, P., Aravena, M. C., Tenti, L., Mónaco, M., Chaves, J. E., Medina, A.,...Martinez Pastur, G. (2021). Reporte Nacional: Carbono almacenado en suelos en los bosques nativos de diferentes ecorregiones del país. Proyecto de Apoyo para la Preparación de REDD + en el marco del Fondo Cooperativo para el Carbono de los Bosques. Dirección de Bosques del Ministerio de Ambiente y Desarrollo Sostenible (MAyDS). <http://hdl.handle.net/20.500.12123/14594>

Peri, P. L., Maradei, D., Lupi, A., Tato Vazquez, C. y Gyenge, J. (2022). Estimación de las reservas de carbono orgánico del suelo con plantaciones forestales y otros usos de la tierra, en distintas regiones de Argentina. INTA-Dirección Nacional de Desarrollo Foresto-Industrial del Ministerio de Agricultura Ganadería y Pesca.

<http://hdl.handle.net/20.500.12123/12650>

Polyakov, V. y Lal, R. (2004). Modeling soil organic matter dynamics as affected by soil water erosion. *Environment International*, 30(4), 547-556.

<https://doi.org/10.1016/j.envint.2003.10.011>Get rights and content

Raich, J. W., y Schlesinger, W. H. (1992). The global carbon dioxide flux in soil respiration and its relationship to vegetation and climate. *Tellus B: Chemical and Physical Meteorology*, 44(2), 81–99. <https://doi.org/10.3402/tellusb.v44i2.15428>

Rawls, W. J., Pachepsky, Y. A., Ritchie, J. C., Sobecki, T. M. y Bloodworth, H. (2003). Effect of soil organic carbon on soil water retention. *Geoderma*, 116(1-2), 61-76.

[https://doi.org/10.1016/S0016-7061\(03\)00094-6](https://doi.org/10.1016/S0016-7061(03)00094-6)

Romero, F., Labouyrie, M., Orgiazzi, A., Ballabio, C., Panagos, P., Jones, A., Tedersoo, L., Bahram, M., Guerra, C. A., Eisenhauer, N., Tao, D., Delgado-Baquerizo, M., Garcia-Palacios, P. y van der Heijden, M. G. (2024). Soil health is associated with higher primary productivity across Europe. *Nature Ecology y Evolution*, 8(10), 1847-1855.

<https://doi.org/10.1038/s41559-024-02511-8>

Rouse, J. W., Haas, R. H., Schell, J. A., y Deering, D. W. (1973). Monitoring vegetation systems in the great plains with ERTS (Earth Resources Technology Satellite). In *Proceedings of the 3rd Earth Resources Technology Satellite Symposium* (pp. 309-317).

Safanelli, J. L., Poppiel, R. R., Ruiz, L. F. C., Bonfatti, B. R., Mello, F. A. D. O., Rizzo, R., y Demattê, J. A. (2020). Terrain analysis in google earth engine: A method adapted for high-performance global-scale analysis. *ISPRS International Journal of Geo-Information*, 9(6), 400. <https://doi.org/10.3390/ijgi9060400>

Saxton, K. E., Rawls, W., Romberger, J. S., y Papendick, R. I. (1986). Estimating generalized soil-water characteristics from texture. *Soil Science Society of America Journal*, 50(4), 1031-1036.

<https://doi.org/10.2136/sssaj1986.03615995005000040039x>

Schimel, D., Stillwell, M. A., y Woodmansee, R. G. (1985). Biogeochemistry of C, N, and P in a soil catena of the shortgrass steppe. *Ecology*, 66(1), 276-282.

<https://doi.org/10.2307/1941328>

Schulz, G. A., Rodríguez, D. M., Angelini, M. E., Moretti, L. M., Olmedo, G. F., Tenti Vuegen, L. M., Colazo, J. C. y Guevara, M. (2022). Digital soil texture maps of Argentina (2.0) [Data set]. Zenodo. <https://doi.org/10.5281/zenodo.6312654>

Sleutel, S., De Neve, S., Beheydt, D., Li, C. y Hofman, G. (2006). Regional simulation of long-term organic carbon stock changes in cropland soils using the DNDC model: 1.

- Large-scale model validation against a spatially explicit data set. *Soil Use and Management*, 22(4), 342-351. <https://doi.org/10.1111/j.1475-2743.2006.00045.x>
- Smith, P. y Powlson, D. S. (2003). Sustainability of soil management practices - a global perspective. En: L. K. Abbott y D. V. Murphy (Eds.). *Soil Biological Fertility - A Key to Sustainable Land Use in Agriculture* (pp. 241-254). Kluwer Academic Publishers. https://doi.org/10.1007/978-1-4020-6619-1_12
- Smith, P. (2004). Soils as carbon sinks: the global context. *Soil Use and Management*, 20(2), 212-221. <https://doi.org/10.1111/j.1475-2743.2004.tb00361.>
- Smith, P. (2008). Land use change and soil organic carbon dynamics. *Nutrient Cycling in Agroecosystems*, 81, 169-178. <https://doi.org/10.1007/s10705-007-9138-y>
- Stevens, A., Nocita, M., Tóth, G., Montanarella, L. y van Wesemael, B. (2013). Prediction of soil organic carbon at the European scale by visible and near infrared reflectance spectroscopy. *PloS one*, 8(6), e66409. <https://doi.org/10.1371/journal.pone.0066409>
- Stockmann, U., Adams, M. A., Crawford, J. W., Field, D. J., Henakaarchchi, N., Jenkins, M., Minasny, B., McBratney, A. B., de Remy de Courcelles, V., Singh, K., Wheeler, I., Abbott, L., Angers, D. A., Baldock, J., Bird, M., Brookes, P. C., Chenu, C., Jastrow, J. D., Lal, R., ... Zimmermann, M. (2013). The knowns, known unknowns and unknowns of sequestration of soil organic carbon. *Agriculture, Ecosystems & Environment*, 164, 80-99. <https://doi.org/10.1016/j.agee.2012.10.001>
- Tang, X., Xia, M., Pérez-Cruzado, C., Guan, F. y Fan, S. (2017). Spatial distribution of soil organic carbon stock in Moso bamboo forests in subtropical China. *Scientific Reports*, 7(1), 42640. <https://doi.org/10.1038/srep42640>
- Tisdall, J. M., y Oades, J. M. (1982). Organic matter and water-stable aggregates in soils. *Journal of Soil Science*, 33(2), 141-163. <https://doi.org/10.1111/j.1365-2389.1982.tb01755.x>
- Viscarra Rossel, R. A. y Hicks, W. S. (2015). Soil organic carbon and its fractions estimated by visible–near infrared transfer functions. *European Journal of Soil Science*, 66(3), 438-450. <https://doi.org/10.1111/ejss.12237>

Volante, J., Gaitán, J., Mosciaro, J., Calamari, N., Navarro, M. F., Winschel, C., Pezzola A. y Peri, P.L. (2024.) Dinámica de la cobertura y uso del suelo en Argentina en las décadas comprendidas entre 2000 y 2020. Informe Técnico Instituto Nacional de Tecnología Agropecuaria (INTA), Secretaría de Agricultura, Ganadería y Pesca de la Nación. Ciudad Autónoma de Buenos Aires. Argentina.

<https://repositorio.inta.gob.ar/handle/20.500.12123/19783?show=full>

Walkley, A., y Black, I. A. (1934). An examination of the Degtjareff method for determining soil organic matter, and a proposed modification of the chromic acid titration method. *Soil Science*, 37(1), 29-38.

Wan, Z., Hook, S., y Hulley, G. (2015). MOD11A2 MODIS/Terra land surface temperature/emissivity 8-day L3 global 1km SIN grid V006. [Data set]. *NASA EOSDIS Land Processes DAAC*.

Wiesmeier, M., Spörlein, P., Geuß, U., Hangen, E., Haug, S., Reischl, A., Schilling, B., von Lützow, M. y Kögel-Knabner, I. (2012). Soil organic carbon stocks in southeast Germany (Bavaria) as affected by land use, soil type and sampling depth. *Global Change Biology*, 18(7), 2233-2245. <https://doi.org/10.1111/j.1365-2486.2012.02699.x>

Whitford, W. G. (2002). *Ecology of desert systems*. Academic Press, Elsevier Science Imprint

Zhu, M., Feng, Q., Qin, Y., Cao, J., Zhang, M., Liu, W., Deo, R. C., Zhang, C., Li, R, y Li, B. (2019). The role of topography in shaping the spatial patterns of soil organic carbon. *Catena*, 176, 296-305. <https://doi.org/10.1016/j.catena.2019.01.029>

APÉNDICE I




Figura 1. Error absoluto medio (MAE) para diferentes números de covariables incluidas en el modelo de Random Forest obtenido luego de aplicar el algoritmo Random-Forest-Recursive Feature Elimination. El círculo lleno se refiere al número óptimo de covariables seleccionadas para el modelo final.

Figure 1. Mean absolute error (MAE) for different numbers of covariates included in the Random Forest model obtained after applying the Random-Forest-Recursive Feature Elimination algorithm. The filled circle refers to the optimal number of covariates select for the final modelling