

Machine Learning Algorithms Performance for Mapping Soil Organic Matter Variability at Field Scale

García Seleme, F.A.¹² , Paccioretti, P.¹² , Balzarini, M.¹²  y Córdoba, M.A.¹² 

¹ Universidad Nacional de Córdoba. Facultad de Ciencias Agropecuarias. Cátedra de Estadística y Biometría. Córdoba, Argentina.

² Grupo de Estadística Vinculado. Unidad de Fitopatología y Modelización Agrícola. Consejo Nacional de Investigaciones Científicas y Técnicas (UFyMA-CONICET). Córdoba, Argentina.
fabrizio.garcia.seleme@mi.unc.edu.ar

Abstract. Soil organic matter (SOM) variability maps at the field-scale are commonly generated using geostatistical models, which enable site-specific prediction and estimation of prediction uncertainty. Alternatively, spatial predictions can be performed using machine learning algorithms. Quantile Regression Forests (QRF) provide spatial predictions along with associated uncertainty measures. Artificial Neural Networks (ANN) have the potential to generate predictions based on multiple covariates; however they present challenges for uncertainty estimation when applied to small datasets, such as those typically obtained from soil sampling. In this study the predictive performances of these two algorithms were compared for within-field SOM mapping. QRF and ANN were evaluated using proximal sensors data as covariates. A geostatistical model, Regression Kriging (RK), was used as reference method. Spatial predictions were conducted for seven agricultural fields located in the provinces of Córdoba and Santiago del Estero, Argentina. Model calibration was performed using information from all fields jointly (global model) and individually for each field (local model). In all cases, ANN showed the best predictive performance, with the lowest site-specific prediction error values. The uncertainty reported by ANN was higher than the one reported by QRF. Field sample size, as well as SOM spatial variability, influenced the performance of both global and local models. Overall, ANN outperformed the other models to supporting field-scale decision-making in precision agriculture.

Keywords: Spatial Interpolation, Regression Forests, Neural Networks, Precision Agriculture, Prediction Uncertainty.

Desempeño de algoritmos de aprendizaje automático para mapear variabilidad de materia orgánica de suelo a escala de lote

Resumen. Los mapas de variabilidad de materia orgánica del suelo (MO), a escala de lote, usualmente son generados mediante modelos geoestadísticos que permiten la predicción sitio-específica y la obtención de medidas de

Received May 2026; Accepted June 2026; Published July 2026



This work is licensed under a Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License.

incertidumbre. Alternativamente, la predicción espacial puede realizarse mediante aprendizaje automático. Los bosques de regresión cuantílica (QRF) pueden proveer predicciones espaciales con su incertidumbre. Las redes neuronales artificiales (ANN), de potencial uso para predicción desde múltiples covariables, presentan desafíos para medir incertidumbre en bases de datos pequeñas, como las de muestreos edáficos. En este trabajo se comparan las capacidades predictivas de estos algoritmos aplicados al mapeo de MO intralote. Se evaluaron QRF y ANN utilizando como covariables de sitio datos obtenidos por sensores proximales. Como método de referencia se empleó el modelo geoestadístico regresión Kriging (RK). Las predicciones espaciales se realizaron en siete lotes agrícolas ubicados en las provincias de Córdoba y Santiago del Estero, Argentina. Los ajustes se realizaron teniendo en cuenta la información de todos los lotes (modelo global) y de manera individual para cada lote (modelo local). En todos los casos, ANN presentó el mejor desempeño, mostrando los menores valores de error de predicción sitio-específica, aunque con incertidumbre de la predicción mayor a la obtenida mediante QRF. La cantidad de observaciones por lote, así como la variabilidad de la MO y las covariables, influyeron en el desempeño de modelos globales y locales. La ANN resultó la mejor herramienta como soporte para la toma de decisiones de manejo a escala de lote en agricultura de precisión.

Palabras clave: Interpolación Espacial, Bosques de Regresión, Redes Neuronales, Agricultura de Precisión, Incertidumbre de la Predicción.

1 Introducción

El contenido de materia orgánica del suelo (MO) desempeña un papel fundamental en los sistemas agrícolas y se considera un indicador clave de la fertilidad edáfica (Córdoba et al., 2025). A escala de lote agrícola, el mapeo de MO constituye una herramienta estratégica para identificar áreas degradadas y optimizar medidas agroambientales (Piccini et al. 2014), favoreciendo la implementación de técnicas de agricultura de precisión que permiten mejorar la eficiencia en el uso de insumos y reducir costos de producción (Vázquez, 2016). Tradicionalmente, la obtención de mapas de MO se ha realizado mediante el uso de técnicas de interpolación espacial aplicadas a datos obtenidos mediante muestreo de suelo. Sin embargo, este enfoque requiere una gran cantidad de puntos de muestreo para generar mapas confiables y de alta calidad. El alto costo asociado a la recolección intensiva de MO ha impulsado la necesidad de desarrollar métodos para predecir su distribución espacial a partir de variables auxiliares (covariables). Métodos geoestadísticos como la regresión kriging (RK) incorporan covariables que mejoran la capacidad predictiva y reducen la cantidad de sitios de muestreo requeridos para la obtención de un mapa confiable (Odeh et al. 1995). En este contexto, la relación entre la MO y variables edáficas, como la conductividad eléctrica, ha sido ampliamente documentada (Omonode & Vyn, 2006; Kweon et al., 2013). Asimismo, se ha demostrado su relación con variables como el rendimiento de los cultivos, variables climáticas e índices de vegetación (Oldfield et al, 2022, Bashie et al., 2024). En agricultura de precisión, la disponibilidad de grandes volúmenes de datos para un mismo lote se ha incrementado significativamente gracias al desarrollo y difusión de equipamientos con sensores proximales como monitores de rendimiento y otros, remotos o proximales, también capaces de recopilar datos de manera automática y en tiempo real (Adamchuk et al., 2004).

Existen diversos métodos de interpolación para predecir valores en sitios no muestreados a partir de covariables. El método geoestadístico kriging es una de las técnicas de interpolación espacial más utilizadas en la agricultura de precisión (Oliver, 2010). Sin embargo, su aplicación requiere cumplir con ciertos supuestos estadísticos para la característica de interés y disponer de un número suficiente de muestras ($n > 100$) para llevar a cabo un modelado confiable de la semivarianza (Oliver & Webster, 2015). La incorporación de covariables en el modelado ha permitido flexibilizar los métodos de interpolación geoestadística mediante su integración con modelos de regresión lineal, en un procedimiento conocido como RK (Odeh et al., 1995). En este enfoque, primero se ajusta un modelo lineal entre la variable respuesta y las covariables de sitio; luego se modela la estructura espacial de los residuos mediante un semivariograma, y finalmente la interpolación es generada como la suma de los valores predichos del modelo de regresión lineal y la predicción kriging de los residuos. La integración de los conceptos detrás de la RK con técnicas de aprendizaje automático (*machine learning*, ML) permitió expandir el alcance de esta herramienta, combinando las fortalezas de ambos enfoques (Mohammadpour et al., 2024). Entre sus ventajas, se destaca que kriging modela en forma explícita la autocorrelación espacial de los datos y permite obtener una medida cuantificable de la incertidumbre asociada a la predicción. Por su parte, los métodos de ML son más flexibles que los enfoques geoestadísticos, ya que permiten capturar relaciones no lineales en los datos mejorando la precisión predictiva en escenarios de relaciones complejas.

Los algoritmos de ML revolucionaron el análisis de datos y son ampliamente utilizados para la resolución de problemáticas asociadas a la producción agrícola (Bhat & Huang, 2021). Los métodos basados en bosques aleatorios (*random forest*, RF) se destacan por su capacidad predictiva y robustez. Estos algoritmos combinan los resultados de múltiples bosques de decisión o regresión según la naturaleza de las variables (Lantz, 2015). Específicamente, las predicciones de los bosques de regresión son obtenidas a partir de un promedio de los valores predichos de todos los árboles. Una variante de RF, conocida como bosques de regresión cuantílica (*quantile regression forest*, QRF), permite estimar cuantiles de la distribución condicional de las variables, y no solo su valor medio (Meinshausen & Ridgeway, 2006), permitiendo estimar la incertidumbre de la predicción. La aplicación de este método para la interpolación espacial a escala de lote mostró una mayor capacidad predictiva y menor tiempo de ejecución respecto a RK (Córdoba & Balzarini, 2021).

Las redes neuronales artificiales (*artificial neural network*, ANN) constituyen otro método dentro de ML, a veces considerado en una categoría más específica, aprendizaje profundo, según el grado de complejidad que alcanzan (Jurafsky & Martin, 2024). Estos algoritmos presentan una estructura de pequeñas unidades de cómputo, llamadas “neuronas”, interconectadas y dispuestas en varias capas que procesan la información de manera iterativa, recibiendo n señales de entrada x_i (*input*), que son modificadas por una serie de pesos w_i y un término de sesgo b (ecuación 1). En base a la información recibida, cada neurona emite señales de salida a (*output*) reguladas por una función $f(a)$ no lineal conocida como función de activación (Candel & LeDell, 2024)

$$a = \sum_{i=1}^n w_i x_i + b. \quad (1)$$

Aspectos como el número de iteraciones pueden ser fijados en distintos valores con el fin de minimizar la función de pérdida de información (Goodfellow et al., 2016).

Dicha función también se puede modificar mediante técnicas de regularización, como Lasso (L1) y Ridge (L2), para evitar sobreajuste. Con el mismo fin es posible controlar aspectos asociados a la detención temprana del ajuste, siendo factible determinar una métrica, usualmente una medida de error, para la cual se especifica un criterio numérico de tolerancia y la cantidad de iteraciones por debajo de dicho criterio necesarias para detener el ajuste. Otros parámetros a considerar para entrenar una ANN son la tasa de aprendizaje y la proporción de datos usada para validación respecto al total de datos (Kamilaris & Prenafeta, 2018). Por otro lado, la estructura de las ANN presenta dos grandes aspectos: la cantidad de capas ocultas y la cantidad de neuronas en cada capa oculta. Relaciones más complejas entre las variables intervinientes conllevan la necesidad de emplear redes más complejas, ya sea con mayor número de neuronas o mayor cantidad de capas. Excederse en la complejidad de esta arquitectura puede llevar al sobreajuste.

Si bien comparadas con otros métodos las ANN mejoraron predicciones, este algoritmo no proporciona, de manera directa, una medida de la variabilidad de la predicción como los algoritmos RK y QRF. En este sentido, para poder obtener medidas de incertidumbre de la predicción algunos autores integraron algoritmos ANN con Kriging, siguiendo una metodología similar a la de RK (Zhao & Shi, 2010). Además, se han desarrollado métodos de regresión cuantílica vía redes neuronales (Cannon, 2010; Zhang et al., 2019). Estos algoritmos se han utilizado para obtener algunas medidas de incertidumbre (Tagasovska & López-Paz, 2018; Haynes et al., 2023), sin embargo, no fueron aplicados en contextos con correlación espacial. Recientemente, el uso de técnicas de remuestreo para generar intervalos de predicción y métricas de confiabilidad ha sido aplicado en datos espaciales (Paranavithana et al., 2024; Kakhani et al., 2024).

En los últimos años, las ANN han ganado protagonismo en la predicción de propiedades del suelo (Wang et al., 2024; Zhang et al., 2025). Fernandes et al. (2019) calibraron y validaron modelos ANN para la predicción de MO a escala regional a partir de valores de covariables de suelo mostrando buena precisión. Otros estudios emplearon información de imágenes satelitales y variables ambientales para predecir MO (Heil et al., 2022). Sin embargo, existen pocos estudios sobre el uso de ANN para la predicción de MO a escala de lote integrando información no sólo del lote para el cual se interesa mapear MO, sino también de las relaciones entre MO y las covariables de sitio de otros lotes. El objetivo del presente trabajo fue evaluar la capacidad de predicción a escala fina de los algoritmos QRF y ANN para el mapeo a escala de lote de la variabilidad de MO a partir de covariables de suelo y de rendimientos de cultivos en el lote de objeto de la predicción y en una muestra de lotes complementarios.

2 Materiales y Métodos

2.1 Datos

Se analizaron datos de siete lotes provenientes de dos establecimientos productivos. Cinco lotes (A-E) provenían de un establecimiento situado en el departamento Juárez Celman, provincia de Córdoba. Los restantes dos lotes (G, F) se encontraban en un establecimiento del departamento Moreno, provincia de Santiago del Estero, Argentina. En total se tomaron 218 muestras de propiedades de suelo distribuidas en

los siete lotes (Fig. 1). La densidad de muestreo entre lotes varió desde 0.26 a 0.34 muestras por hectáreas, en promedio fue de 0.285 muestras por hectárea.




Fig. 1. Distribución de los puntos de muestreo de suelo en los lotes ubicados en la provincia de Córdoba (izq.) y Santiago del Estero (der.).

Para cada lote se contó con datos de rendimiento de soja (*Glycine max* L.) o maíz (*Zea mays* L.) en la campaña 2022/23 obtenidos con monitor de cosecha, además de valores de conductividad eléctrica superficial, subsuperficial y elevación obtenidos con rastra Veris. En cada lote, cada una de las cuatro covariables fue interpolada mediante Kriging universal utilizando grillas de resolución 10×10 metros. Se extrajeron los valores predichos en los puntos de muestreo y dichos valores se estandarizaron por lote.

2.2 Algoritmos comparados

Se comparó la capacidad predictiva de RK, QRF y ANN considerando un modelo local y un modelo global. El modelo local utilizó exclusivamente los datos del lote objetivo, mientras que el modelo global además de los datos del lote, incorporó información proveniente de todos los lotes en estudio. Para los algoritmos QRF y ANN se adicionó, a la base de datos y a la grilla de predicción, una covariable con el objeto de incorporar la correlación espacial de los datos. Para cada punto muestral se generó una red de vecindario con los cinco puntos de muestreo más cercanos. Con estos valores se calculó un valor predicho de MO mediante ponderación inversa a la distancia (*inverse distance weighting*, IDW). Dado que los modelos globales se ajustaron independientemente para cada lote y algoritmo, los valores predichos para cada uno se obtuvieron con estimaciones diferentes y no provenientes de un único algoritmo ajustado.

El algoritmo ANN se entrenó mediante retro-propagación a través del optimizador de descenso de gradiente estocástico (H2O.ai, 2024). La optimización de hiperparámetros se realizó mediante un criterio de búsqueda aleatorio (Bergstra & Bengio, 2012) el cual permite obtener un desempeño similar al método de grilla con una mínima fracción del tiempo computacional que éste requiere. Se fijó un tope de 20 redes ajustadas para cada búsqueda. Las redes se ejecutaron con 100 épocas verificando ausencia de sobreajuste mediante las curvas de aprendizaje. Entre los hiperparámetros a optimizar se listaron la estructura general de la red (opciones: (5),

(10), (20), (30), (5 5), (10 10), (20 20), (30 30), (256 256) y (30 30 30)); función de activación (*Rectifier, Tanh, Maxout*); desactivación de neuronas (*dropout*); funciones de pérdida L1 y L2 (parámetro 0 ó 1e-5 para cada una) e iteraciones de detención temprana (3, 5). Respecto a los hiperparámetros numéricos se optó por emplear listas discretas de valores y no un intervalo continuo para facilitar la comparación y análisis posterior de los modelos ajustados.

Para comparar el ajuste de los modelos, se utilizó la raíz del error cuadrático medio de predicción (*root mean square error, RMSE*) obtenido mediante validación cruzada k-fold (k = 5). El RMSE se calculó como la media de los residuos elevados al cuadrado (error cuadrático medio, MSE) y aplicando la raíz cuadrada. Además, se calculó una variante normalizada de este indicador (nRMSE) (ecuación 2) la cual divide el valor de RMSE valor por el valor promedio de las observaciones (\bar{Y}).

$$nRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_{pred} - y_{obs})^2}}{\bar{Y}} \quad (2)$$

Adicionalmente, los valores predichos por cada modelo para cada lote fueron comparados de a pares mediante una prueba T modificada, la cual corrige el estadístico para contemplar la autocorrelación espacial de los datos (Kvamme, 1993). Esta prueba permite evaluar la correlación lineal entre las predicciones generadas por los distintos métodos de predicción espacial.

Para el estudio de la variabilidad de las predicciones obtenidas mediante los modelos QRF, se utilizó la fórmula reportada por Hengl et al. (2018), que estima el desvío estándar de la predicción para cada ubicación s_j a partir del área teóricamente ocupada por el rango $[(\mu - \sigma); (\mu + \sigma)]$ (ecuación 3).

$$\sigma(s_j) \approx \frac{\hat{y}_{q=0.841}(s_j) - \hat{y}_{q=0.159}(s_j)}{2} \quad (3)$$

Para el estudio de la variabilidad de las predicciones obtenidas por medio de algoritmos ANN, utilizado como indicador de la incertidumbre de la predicción, se procedió a realizar el ajuste de la red optimizada para cada lote empleando 100 conjuntos de datos producidos mediante remuestreo *bootstrap* de los datos originales (Efron, 1979). Este procedimiento se aplicó sobre los datos de entrenamiento para cada iteración, con el objeto de evitar duplicación de los datos de validación que podría brindarle información de ellos a la red neuronal durante su entrenamiento. Se estimó la media y el desvío estándar de las predicciones obtenidas mediante *bootstrap*. Este procedimiento se extendió a las grillas de cada lote para obtener mapas de predicción y de incertidumbre de la predicción del contenido de MO. Para los análisis fueron utilizadas los paquetes *automap* (Hiemstra et al., 2008), *caret* (Kuhn, 2008), *h2o* (Fryda et al., 2024), *gstat* (Gräler et al., 2016), *meteo* (Sekulic et al., 2020), *paar* (Paccioretti et al., 2024), *SpatialPack* (Vallejos et al., 2020) y *sf* (Pebesma & Bivand, 2023) del software R (R Core Team, 2025).

3 Resultados y Discusión

Los valores de MO promedio para cada lote variaron entre 1.46% y 2.66% (Tabla 1), con coeficientes de variación (CV) entre 8% y 20%. Los lotes F y G, de Santiago del Estero, presentaron los valores promedio más elevados (2.66% y 2.27%,

respectivamente) y menor variabilidad relativa (CV = 10% y 8%, respectivamente). En el lote A se registró la mayor variabilidad (CV = 20%).

Tabla 1. Media, coeficiente de variación (CV), valores mínimos (Min) y máximos (Max) para el contenido de materia orgánica del suelo (%) evaluado en siete lotes.

Lote	n	Media	CV	Min	Max
A	55	1.92	20	1.15	2.82
B	57	2.07	17	1.03	2.99
C	17	2.09	17	1.36	2.73
D	17	1.79	14	1.36	2.34
E	17	1.46	18	0.77	1.84
F	28	2.66	10	2.29	3.37
G	27	2.27	8	1.94	2.65

Al estudiar los lotes mediante un método de clúster jerárquico (Fig. 2) se distinguieron dos grupos principales, que resultaron equivalentes a los dos establecimientos evaluados.




Fig. 2. Dendrograma obtenido mediante análisis de clúster jerárquico de los siete lotes en estudio provenientes de dos establecimientos agrícolas.

Para todos los lotes analizados en este estudio, los algoritmos ANN presentaron un mejor ajuste que los algoritmos QRF y RK (Tabla 2). Para los lotes A, B y F el modelo que mejor ajustó fue un ANN local (nRMSE = 11.0, 11.1 y 6.8, respectivamente), mientras que para los demás la mejor opción fue un modelo global. El estudio de Liu et al. (2022) sobre un lote agrícola con superficie y densidad de muestreo similar a las del presente trabajo obtuvo errores de predicción semejantes (nRMSE = 8%) para carbono orgánico utilizando ANN con información de sensores proximales como covariables. Guo et al. (2013) reportó errores de predicción similares (nRMSE próximas a 10%) para algoritmos ANN utilizando información topográfica con una mayor intensidad de muestreo. En contraste, los errores de predicción obtenidos en este trabajo, fueron menores a los reportados por García-Tomillo et al. (2016) quienes utilizaron algoritmos derivados de Kriging. La mejora en el desempeño de los algoritmos ML comparado con métodos Kriging, en contextos de tamaños de muestra pequeños, fue a su vez reportada por Pereira et al. (2022).

La cantidad de observaciones en los lotes A y B ($n = 55$ y 57 , respectivamente) fue casi el doble que la de los demás lotes. Esta mayor disponibilidad de información pudo contribuir al menor error de predicción de los modelos locales. Por otro lado, los lotes con menor número de observaciones (C, D y E; $n = 17$ en cada uno) exhibieron, en general, mejor ajuste en los modelos globales para los diferentes métodos de predicción (Tabla 2). En el lote F el modelo local mostró menor error de predicción comparado con el modelo global. Esto podría deberse a que la mayoría de los valores de MO observados en el lote F se encontraban por encima del percentil 90 del total de las observaciones de MO. Los modelos globales, alimentados con valores de MO menores a los de este lote, podrían incurrir en un sesgo y predecir valores más bajos.

El algoritmo QRF mostró, en líneas generales, errores de predicción menores que el algoritmo RK (Tabla 2). Luego de ANN, QRF local fue la segunda mejor combinación de algoritmo y modelo en la mayoría de los lotes (cinco de siete). En el lote B el modelo RK local mostró menor nivel de error ($nRMSE = 11.5$), mientras que en el lote C, QRF global mostró el menor error ($nRMSE = 15.7$).

Tabla 2. Raíz del error cuadrático medio expresada como porcentaje ($nRMSE$) para la predicción del contenido de materia orgánica en siete lotes agrícolas, mediante algoritmos de aprendizaje automático: Bosques de Regresión Cuantílica (QRF) y Redes Neuronales Artificiales (ANN). En negrita se señala el mejor modelo para cada lote.

Lote	QRF		ANN		RK	
	Global	Local	Global	Local	Global	Local
A	14.5	11.7	16.1	11.0	13.9	12.8
B	13.8	12.3	13.0	11.1	14.8	11.5
C	15.7	19.8	12.4	21.2	17.8	23.4
D	16.9	14.4	12.4	16.7	17.1	22.8
E	22.5	16.4	14.6	18.9	29.1	17.5
F	9.9	9.2	7.7	6.8	15.1	10.5
G	15.3	12.7	11.2	18.1	15.2	15.2

Regresión Kriging (RK); método de referencia

Para el lote E, los métodos QRF y RK mostraron un menor nivel de error de predicción cuando utilizaron únicamente los datos del lote, a pesar del tamaño de muestra limitado ($n = 17$). Esto podría deberse a los valores observados en este lote. Un 23.5% de los datos del lote E presentó valores por debajo del rango de valores observados en los demás lotes. La baja representación de estos valores en los datos de entrenamiento podría haber generado los aumentos registrados en el error de predicción de modelos globales.

Dado que la densidad de muestreo fue relativamente homogénea en todos los lotes, los resultados sugieren que los modelos pierden capacidad predictiva cuando la cantidad de muestras del lote es baja (< 20), sin importar la superficie. Los tamaños muestrales relevados en este trabajo son inferiores a los óptimos reportados por Saurette et al. (2022) y Schmidlinger et al. (2024) para algoritmos RF y modelos RK para predicción del porcentaje de carbono orgánico a escala de lote, los cuales sugieren tamaños de muestra mayores a 100. Un muestreo de suelo de lotes agrícolas más denso podría reducir los errores de predicción. Sin embargo, esto tornaría el muestreo más laborioso y por ende costoso, algo no deseable en la producción agrícola.

Los valores predichos con todos los métodos evaluados mostraron correlación positiva con los valores observados (Fig. 3). Las predicciones obtenidas mediante algoritmos ML representaron el rango de valores observados de MO de mejor manera que RK. El rango de predicciones obtenidas con QRF y ANN globales cubrió un 60.8% y 57.5% – respectivamente – del rango de los valores observados, frente a un 38.6% de cobertura reportado con RK. Estas proporciones aumentaron en los modelos locales (86.4%, 83.7% y 71.2% para QRF, ANN y RK, respectivamente).




Fig. 3. Diagramas de dispersión de valores predichos y observados de materia orgánica del suelo utilizando algoritmos de aprendizaje automático: bosques de regresión cuantílica (QRF) y redes neuronales artificiales (ANN); como método de referencia se utilizó regresión Kriging (RK). En columnas se encuentran modelos globales (ajustes utilizando los datos de todos los lotes) y locales (ajustes utilizando datos del lote objetivo únicamente). r = estadístico de correlación de Pearson.

La combinación de hiperparámetros del modelo de mejor ajuste fue diferente para cada uno de los lotes (Tabla 3). En dos lotes (A y D) se utilizó *dropout*. En tres de los lotes (D, E y F) fue preferible el uso de las funciones de regularización L1 y L2 en conjunto; estos tres casos presentaron una estructura neuronal con más de una capa oculta. Lo contrario ocurrió para los lotes A, B, C y G, los cuales además presentaron

estructuras más sencillas, con una única capa oculta. Para los lotes B, C y G no fue necesario emplear ninguna técnica de regularización. La complejidad de la red empleada para el lote F podría explicar el bajo error de predicción registrado. Para los lotes D y F la estructura con mejor ajuste (menor error de predicción) fue una estructura compleja, ya sea por número de neuronas (lote D) o por número de capas (lote F). Si bien no hay un criterio claro en la bibliografía sobre una estructura neuronal óptima, modelos complejos podrían generar predicciones con sobreajuste, principalmente en conjuntos de datos con pocas observaciones (Ying, 2018).

Tabla 3. Hiperparámetros correspondientes a la red neuronal de menor grado de error para cada lote (L). L1 y L2: funciones de pérdida; SR: iteraciones de detención anticipada.

L	Modelo*	Función de Activación	Estructura	L1	L2	SR
A	Local	Maxout with Dropout	(10)	1e-5	0	3
B	Local	Rectifier	(20)	0	0	3
C	Global	Rectifier	(20)	0	0	3
D	Global	Rectifier with Dropout	(256,256)	1e-5	1e-5	5
E	Local	Tanh	(20,20)	1e-5	1e-5	5
F	Local	Tanh	(30,30,30)	1e-5	1e-5	5
G	Global	Maxout	(5)	0	0	3

*Modelo local utilizó exclusivamente los datos del lote objetivo, mientras que el modelo global además de los datos del lote, incorporó información proveniente de todos los lotes en estudio.

El tiempo de ajuste de las ANN locales fue menor respecto a aquél de las globales (2.6 vs. 10.2 segundos en promedio), aunque hay que considerar el tamaño del conjunto de datos cargado en cada uno (13-44 vs. 174 considerando dimensiones de los datos de entrenamiento). El procesamiento y análisis de los datos, se realizó en un servidor remoto Ubuntu 20.04.6 LTS, con procesador Intel(R) Core(TM) i7-8700K CPU @ 3.70GHz × 12 núcleos y 62 GB de RAM.

Los mapas evaluados a partir del mejor modelo para cada lote mostraron coherencia desde el punto de vista espacial, sin observarse artefactos como líneas rectas u otros elementos no deseados (Fig. 4), los cuales son comunes en métodos que incorporan información de covariables geográficas y no contemplan la correlación espacial (Xie et al., 2022). En los bordes de algunos lotes (ej. Sur del lote B y norte del lote C) se observó cambios a nivel del valor promedio de MO, lo cual es esperable dado que los modelos usados para la predicción fueron específicos para cada lote. No obstante, se observó cierta continuidad en el patrón espacial, lo que indicó coherencia en la distribución de MO a nivel de establecimiento agrícola.

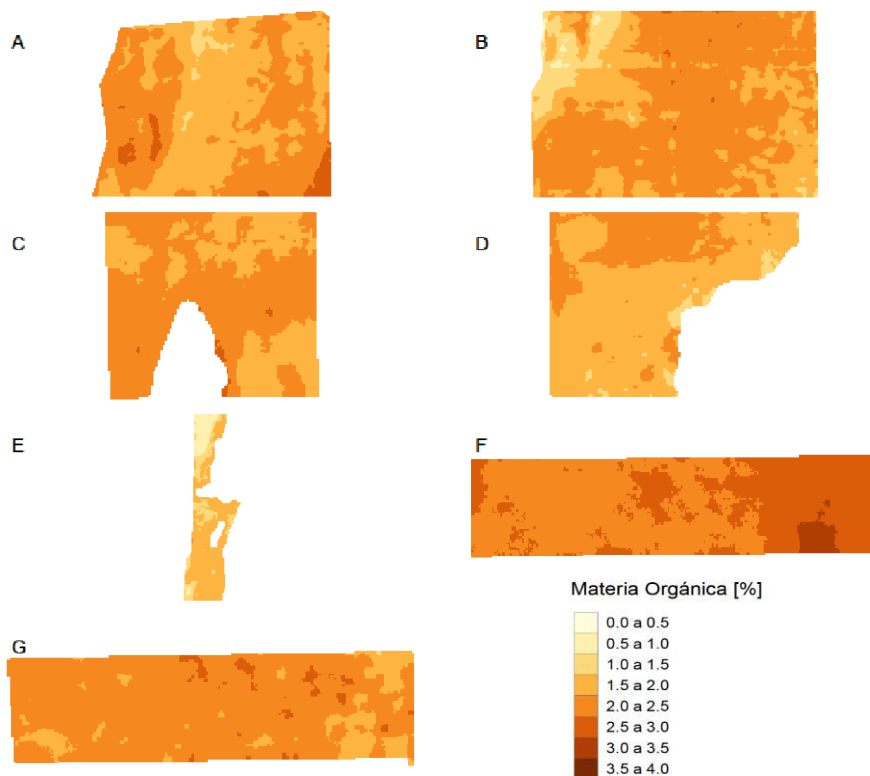


Fig. 4. Mapa de porcentajes de materia orgánica del suelo predichos para los siete lotes evaluados, utilizando redes neuronales.

Las predicciones de todos los modelos en general presentaron una correlación positiva significativa ($p < 0.05$), según la prueba T modificada. Como excepción, el método RK global presentó una correlación negativa con el modelo RK local en el lote C ($r = -0.58$, $p < 0.05$) y con el modelo ANN local en el lote G ($r = -0.54$, $p < 0.01$). Los modelos ANN local y global presentaron correlación positiva significativa en todos los lotes, al igual que los modelos QRF, con excepción del lote F, donde la correlación no fue significativa.

La incertidumbre promedio obtenida con el algoritmo ANN de menor grado de error, medida como desvío estándar de las 100 predicciones obtenidas remuestreando los datos de entrenamiento, fue de 0.17. Los mapas de incertidumbre obtenidos no mostraron artefactos o elementos no deseados (Fig. 5). Los lotes A y F exhibieron desvíos estándar notablemente superiores a los de los demás lotes. El lote A fue el que presentó mayor variabilidad en los valores observados de MO, lo que podría haber afectado los valores de incertidumbre obtenidos.

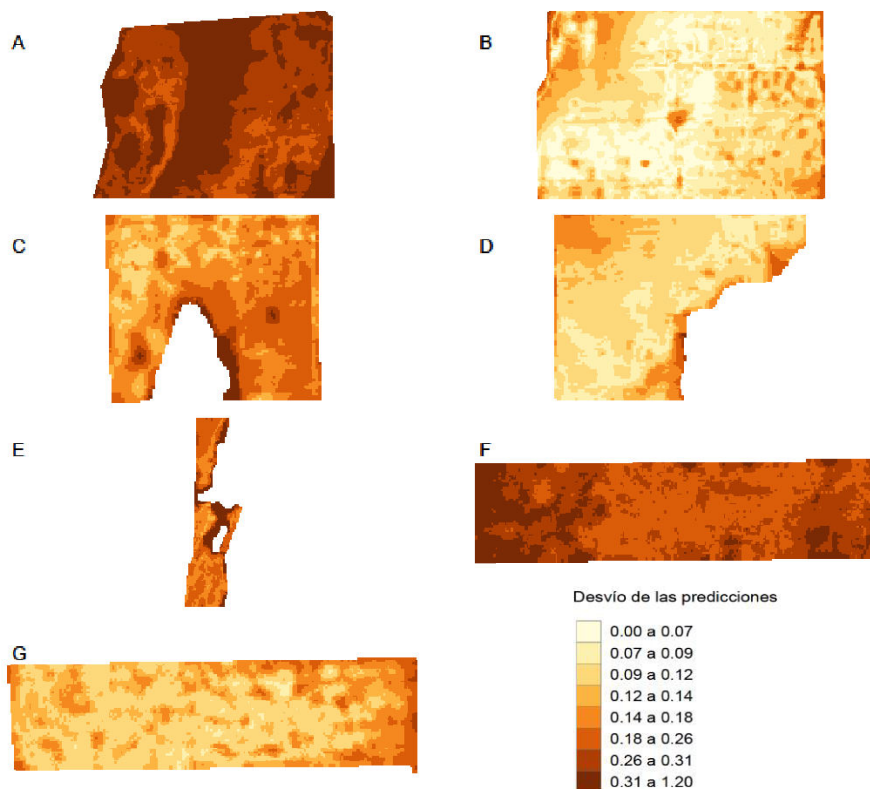


Fig. 5. Mapa de desvío estándar de las predicciones de materia orgánica (%) del suelo (MO) obtenidas mediante redes neuronales, para los siete lotes evaluados.

Los valores de incertidumbre reportados en este trabajo fueron similares a los obtenidos por Dash et al. (2025) para carbono orgánico, los cuales fueron aproximadamente 0.08 % utilizando algoritmos de perceptrón multicapa con tamaño de muestra similar ($n = 25$). En dicho trabajo se observó que la incertidumbre disminuye con el aumento del tamaño muestral. La incertidumbre obtenida mediante ANN fue, en promedio, mayor que la reportada por los modelos QRF (0.10 %). Asimismo, la incertidumbre promedio fue menor en las predicciones mediante ANN que utilizaron los datos de todos los lotes (0.12 vs. 0.23), no habiendo diferencias entre ambas estrategias usando QRF. Dash et al. (2025) reportó que otros algoritmos como RF arrojaron valores de incertidumbre aproximadamente 10 veces menores que los obtenidos mediante perceptrón multicapa.

4 Conclusiones

Los algoritmos basados en redes neuronales artificiales (ANN) mejoraron las predicciones con respecto a bosques de regresión cuantílica (QRF), otro algoritmo de aprendizaje automático utilizado para la predicción de materia orgánica (MO) a escala de lote. Ambos métodos mejoraron la capacidad predictiva con respecto a kriging regresión (RK). Las predicciones realizadas mediante los distintos algoritmos estuvieron correlacionadas con las observaciones, mostrando convergencia en la captura de tanto de los valores observados como los patrones de variabilidad espacial del contenido de MO en el suelo. La ANN resultó la mejor herramienta como soporte para la toma de decisiones de manejo agrícola a escala de lote en contexto de agricultura de precisión.

5 Agradecimientos

Agradecemos a la Agencia Nacional de Promoción de la Investigación, el Desarrollo Tecnológico y la Innovación (ANPCyT-PICT 2021-0682, 2021-00319), al Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET) y a la Secretaría de Ciencia y Tecnología de la Universidad Nacional de Córdoba (UNC) por el apoyo brindado para la realización de esta investigación. Asimismo, agradecemos a los productores y al personal técnico de Experta AGD por su colaboración en la recolección de los datos experimentales.

Referencias

- Adamchuk, V. I., Hummel, J. W., Morgan, M. T. y Upadhyaya, S. K. (2004). On-the-go sensors for precision agriculture. *Computers and Electronics in Agriculture*, 44(1), 71–91. <https://doi.org/10.1016/j.compag.2004.03.002>
- Bashie, A. L., Ayankukwa, A. U., Owojoku, O. D., Nicholas, O. G., Ishoro, A. P. y Christiana, U. A. (2024). Predicting environmental covariates of soil organic matter at sub-regional scale for sustainable agricultural development in Southeast Nigeria. *Polish Journal of Environmental Studies*, 34(3), 2011–2021. <https://doi.org/10.15244/pjoes/186888>
- Bergstra, J. y Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(1), 281–305.
- Bhat, S.A. y Huang, N. (2021). Big Data and AI revolution in precision agriculture: Survey and challenges. *IEEE Access*, 9, 110209–110222. <https://doi.org/10.1109/ACCESS.2021.3102227>
- Candel, A. y LeDell, E. (2024). *Deep learning with H2O*. (6ª ed.). H2O ai.
- Cannon, A. (2010). Quantile regression neural networks: Implementation in R and application to precipitation downscaling. *Computers & Geoscience*, 37(9), 1277–1284. <https://doi.org/10.1016/j.cageo.2010.07.005>
- Córdoba, M., Paccioretti P. A., Giannini Kurina, F., Bruno, C. I. y Balzarini, M. G. (2020). *Guía para el análisis de datos espaciales: aplicaciones en agricultura*. (1ª ed.). Editorial Brujas. <https://ri.conicet.gov.ar/handle/11336/195087>
- Córdoba, M. y Balzarini, M. (2020). *Mapeo de materia orgánica del suelo a escala de campo [ponencia]*. Congreso Argentino de Agroinformática-Jornadas Argentinas de Informática e Investigación Operativa. Ciudad Autónoma de Buenos Aires, Argentina. <https://sedici.unlp.edu.ar/handle/10915/115515>
- Córdoba, M. y Balzarini, M. (2021). A random forest-based algorithm for data-intensive spatial interpolation in crop yield mapping. *Computers and Electronics in Agriculture*, 184, 106094. <https://doi.org/10.1016/j.compag.2021.106094>

- Córdoba, M., Hang, S., Bozzer, C., Álvarez, C., Faule, L., Kowaljow, E., Vaieretti, M., Bongiovanni, M. y Balzarini, M. (2025). Spatial Variability and Temporal Changes of Soil Properties Assessed by Machine Learning in Córdoba, Argentina. *Soil Systems*, 9(4), 109. <https://doi.org/10.3390/soilsystems9040109>
- Dash, P., Ferhatoglu, C. y Miller, B. (2025). Influence of sample size and machine learning algorithms on digital soil nutrient mapping accuracy. *Environment Monitoring and Assessment*, 197, 996. <https://doi.org/10.1007/s10661-025-14322-w>
- Efron, B. (1979). Bootstrap Methods: Another Look at the Jackknife. *The Annals of Statistics*, 7(1), 1–26. <https://doi.org/10.1214/aos/1176344552>
- Fryda, T., LeDell, E., Gill, N., Aiello, S., Fu, A., Candel, A., Click, C., Kraljevic, T., Nykodym, T., Ahoyoum, P., Kurka, M., Malohlava, M., Poirier, S., Wong, W., Rehak, L., Eckstrand, E., Hill, B., Vidrio, S., Jadhawani, S., ... Novotny, M. (2024). H2o: R Interface for the 'H2O' Scalable Machine Learning Platform. *CRAN.R*. <https://doi.org/10.32614/CRAN.package.h2o>
- García Tomillo, A., Mirás Avalos, J. M., Dafonte Dafonte, J. y Paz González, A. (2017). Estimating soil organic matter using interpolation methods with a electromagnetic induction sensor and topographic parameters: a case study in a humid region. *Precision Agriculture*, 18, 882–897. <https://doi.org/10.1007/s11119-016-9481-6>
- Goodfellow, I., Bengio, Y. y Courville, A. (2016). *Deep learning*. MIT Press. <https://mitpress.mit.edu/9780262035613/deep-learning/>
- Gräler, B., Pebesma, E. y Heuvelink, G. (2016). Spatio-Temporal Interpolation using gstat. *The R Journal*, 8, 204-218. <https://doi.org/10.32614/RJ-2016-014>
- Guo, P., Wu, W., Sheng, Q., Li, M., Liu, H. y Wang, Z. (2013). Prediction of soil organic matter using artificial neural network and topographic indicators in hilly areas. *Nutrient Cycling in Agroecosystems*, 95, 333–344. <https://doi.org/10.1007/s10705-013-9566-9>
- H2O.ai. (2024). Deep learning (Neural Networks). <https://docs.h2o.ai/h2o/latest-stable/h2o-docs/data-science/deep-learning.html>
- Haynes, K., Lagerquist, R., McGraw, M., Musgrave, K. y Ebert-Uphoff, I. (2023). Creating and evaluating uncertainty estimates with neural networks for environmental-science applications. *Artificial Intelligence for the Earth Systems*, 2(2), 220061. <https://doi.org/10.1175/AIES-D-22-0061.1>
- Heil, J., Jörges, C. y Stumpe, B. (2022). Fine-scale mapping of soil organic matter in agricultural soils using UAVs and Machine Learning. *Remote Sensing*, 14(14), 3349. <https://doi.org/10.3390/rs14143349>
- Hengl, T., Nussbaum, M., Wright, M., Heuvelink, G. y Gräler, B. (2018). Random forest as a generic framework for predictive model for spatial and spatio-temporal variables. *PeerJ*, 6, e5518. <https://doi.org/10.7717/peerj.5518>
- Hiemstra, P., Pebesma, E., Twenhofel, C. y Heuvelink, G. (2008). Real-time automatic interpolation of ambient gamma dose rates from the Dutch Radioactivity Monitoring Network. *Computers & Geosciences*, 35(8), 1711–1721. <https://doi.org/10.1016/j.cageo.2008.10.011>
- Honorato Fernandes, M. M., Prates Coelho, A., Fernandes, C., da Silva, M. F. y Campos Dela Marta, C. (2019). Estimation of soil organic matter content by modelling with artificial neural networks. *Geoderma*, 350, 46–51. <https://doi.org/10.1016/j.geoderma.2019.04.044>
- Jurafsky, D. y Martin, J. H. (2024). *Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition with language models* [PDF]. (3ª ed.). Inédito. https://web.stanford.edu/~jurafsky/slp3/ed3book_Jan25.pdf
- Kakhani, N., Alamdar, S., Kebonye, N. M., Amani, M. y Scholten, T. (2024). Uncertainty quantification of soil organic carbon estimation from remote sensing data with conformal prediction. *Remote Sensing*, 16(3), 438. <https://doi.org/10.3390/rs16030438>
- Kamilaris, A. y Prenafeta-Baldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Kuang, B. y Mouazen, A. (2012). Influence of the number of samples on prediction error of visible and near infrared spectroscopy of selected soil properties at the farm scale. *European Journal of Soil Sciences*, 63, 421–429. <https://doi.org/10.1111/j.1365-2389.2012.01456.x>

- Kuhn, M. (2008). Building predictive models in R using the caret package. *Journal of Statistical Software*, 28(5), 1–26. <https://doi.org/10.18637/jss.v028.i05>
- Kvamme, K. L. (1993). Spatial statistics and GIS: An integrated approach. En J. Andresen, T. Madsen e I. Scollar (Eds.), *Computing the past: Computer applications and quantitative methods in archaeology* (pp. 91-103). Aarhus University Press.
- Kweon, G., Lund, E. y Maxton, C. (2013). Soil organic matter and cation-exchange capacity sensing with on-the-go electrical conductivity and optical sensors. *Geoderma*, 199, 80–89. <https://doi.org/10.1016/j.geoderma.2012.11.001>
- Lantz, B. (2015). *Machine learning with R*. (2^a ed.). Packt Publishing Ltd. <https://faculty.cengage.com/works/9780357387528>
- LeCun, Y., Bengio, Y. y Hinton, G. (2015). Deep learning. *Nature*, 521, 436–444. <https://doi.org/10.1038/nature14539>
- Liu, Q., He, L., Guo, L., Wang, M., Deng, D., Lv, P., Wang, R., Jia, Z., Hu, Z., Wu, G. y Shi, T. (2022). Digital mapping of soil organic carbon density using newly developed bare soil spectral indices and deep neural network. *CATENA*, 219, 106603. <https://doi.org/10.1016/j.catena.2022.106603>
- Mohammadpour, M., Roshan, H., Arashpour, M. y Masoumi, H. (2024). Machine learning assisted Kriging to capture spatial variability in petrophysical property modelling. *Marine and Petroleum Geology*, 167, 106967. <https://doi.org/10.1016/j.marpetgeo.2024.106967>
- Meinshausen, N. y Ridgeway, G. (2006). Quantile Regression Forests. *Journal of Machine Learning Research*, 7(6), 983–999.
- Odeh, I. O. A., McBratney, A. B. y Chittleborough, D. J. (1995). Further results on prediction of soil properties from terrain attributes: Heterotopic cokriging and regression-kriging. *Geoderma*, 67(3-4), 215–226. [https://doi.org/10.1016/0016-7061\(95\)00007-B](https://doi.org/10.1016/0016-7061(95)00007-B)
- Oldfield, E. E., Bradford, M. A., Augarten, A. J., Cooley, E. T., Radatz, A. M., Radatz, T. y Ruark, M. D. (2022). Positive associations of soil organic matter and crop yields across a regional network of working farms. *Soil Science Society of America Journal*, 86(2), 384–397. <https://doi.org/10.1002/saj2.20349>
- Oliver, M. A. (2010). *Geostatistical applications for precision agriculture*. (1^a ed.). Springer. <https://link.springer.com/book/10.1007/978-90-481-9133-8>
- Oliver, M. A. y Webster, R. (2015). *Basic steps in Geostatistics: The variogram and kriging*. (1^a ed.). Springer. <https://link.springer.com/book/10.1007/978-3-319-15865-5>
- Omonode, R. A. y Vyn, T. J. (2006). Spatial dependence and relationships of electrical conductivity to soil organic matter, phosphorus, and potassium. *Soil Science*, 171(3), 223–238. <https://doi.org/10.1097/01.ss.0000199698.94203.a4>
- Paccioretti, P., Córdoba, M., Giannini Kurina, F. y Balzarini, M. (2024). Paar: Precision agriculture data analysis. *CRAN.r*. <https://doi.org/10.32614/CRAN.package.paar>
- Paranavithana, T. M., Karunaratne, S. B., Wimalathunge, N., Malone, B. P., Macdonald, B., Bishop, T. F. A. y Ratnayake, R. R. (2024). Unravelling spatial drivers of topsoil total carbon variability in tropical paddy soils of Sri Lanka. *Geoderma Regional*, 26, e00745. <https://doi.org/10.1016/j.geodrs.2023.e00745>
- Pebesma, E. y Bivand, R. (2023). *Spatial Data Science: With applications in R*. Chapman and Hall/CRC. <https://doi.org/10.1201/9780429459016>
- Piccini, C., Marchetti, A. y Francaviglia, R. (2014). Estimation of soil organic matter by geostatistical methods: Use of auxiliary information in agricultural and environmental assessment. *Ecological Indicators*, 36, 301–314. <https://doi.org/10.1016/j.ecolind.2013.08.009>
- R Core Team. (2025). *R: A Language and Environment for Statistical Computing (Versión 4.5.1)* [Software]. R-Foundation. <https://www.R-project.org/>
- Sekulić, A., Kilibarda, M., Heuvelink, G. B. M., Nikolić, M. y Bajat, B. (2020). Random forest spatial interpolation. *Remote Sensing*, 12, 1687. <https://doi.org/10.3390/rs12101687>
- Schmidlinger, J., Schröter, I., Bönecke, E., Gebbers, R., Ruehlmann, J., Kramer, E., Mulder, V., Heuvelink, G. y Vogel, S. (2024). Effect of training sample size, sampling design and prediction model on soil mapping with proximal sensing data for precision liming. *Precision Agriculture*, 25, 1529–1555. <https://doi.org/10.1007/s11119-024-10122-3>
- Tagasovska, N. y López-Paz, D. (2018). Frequentist uncertainty estimates for deep learning. *ArXiv*, 1811.00908.

- Vallejos, R., Osorio, F. y Bevilacqua, M. (2020). *Spatial Relationships Between Two Georeferenced Variables: with Applications in R*. Springer. <https://link.springer.com/book/10.1007/978-3-030-56681-4>
- Vázquez, J. M. (2016). Manejo sitio específico. En J. M. Gueçaimburu, V. Rojo, G.Reposo, J. M. Vázquez y M. Martínez (Eds.), *Manejo del sistema agropecuario* (1ª ed., pp. 91–103). Editorial Universidad Nacional de Luján (EdUNLu). <https://ri.unlu.edu.ar/xmlui/handle/rediunlu/1360>
- Wang, Y., Shi, L., Hu, Y., Hu, X., Song, W. y Wang, L. (2024). A comprehensive study of Deep learning for soil moisture prediction. *Hydrology and Earth System Sciences*, 28(4), 917–943. <https://doi.org/10.5194/hess-28-917-2024>
- Xie, J., Huang, J., Zheng, C., Huang, S. y Burton, G. (2022). A generic framework for geotechnical subsurface modeling with machine learning. *Journal of Rock Mechanics and Geotechnical Engineering*, 14(5), 1366–1379. <https://doi.org/10.1016/j.jrmge.2022.08.001>
- Ying, X. (2019). An overview of overfitting and its solutions. *Journal of Physics: Conference Series*, 1168, 022022. <https://doi.org/10.1088/1742-6596/1168/2/022022>
- Zhao, Y. y Shi, X. (2010). Spatial prediction and uncertainty assessment of soil organic carbon in Hebei Province, China. En J. Boettinger, D. Howell, A. Moore, A. Hartemink y S. Kienast-Brown (Eds.), *Digital soil mapping*. Springer. https://doi.org/10.1007/978-90-481-8863-5_19
- Zhang, W., Quan, H. y Srinivasan, D. (2019). An improved quantile regression neural network for probabilistic load forecasting. *IEEE Transactions on Smart Grid*, 10(4), 4425–4434. <https://doi.org/10.1109/TSG.2018.2859749>
- Zhang, Y., Luo, C., Zhang, W., Wu, Z. y Zang, D. (2025). Mapping soil organic matter in black soil cropland areas using remote sensing and environmental covariates. *Agriculture*, 15(3), 339. <https://doi.org/10.3390/agriculture15030339>