

Mapeo de materia orgánica del suelo a escala de campo

Mariano Córdoba¹, Mónica Balzarini

¹Universidad Nacional de Córdoba, Facultad de Ciencias Agropecuarias,
Unidad de Fitopatología y Modelización Agrícola (UFyMA), INTA – CONICET.
marianoacba@agro.unc.edu.ar

Resumen. La información sobre la distribución de la materia orgánica (MO) a escala fina es clave no solo para el manejo de la fertilidad del suelo sino también para estimar la reserva de carbono orgánico del suelo. En este trabajo se comparan dos métodos para mapear la variabilidad de MO a escala de campo: el algoritmo de aprendizaje automático *quantile regression forest* (QRF) y la regresión bayesiana, estimada por INLA. Ambos métodos se aplican para estimar la relación entre MO y variables de sitio, de fácil obtención, que es usada para predecir MO en sitios no muestreados. Se emplearon 279 puntos georreferenciados de MO muestreados en tres periodos (2005, 2008 y 2011) en una superficie de 2.240 ha bajo agricultura. Para el ajuste de los modelos de regresión se utilizaron variables topográficas e índices de vegetación como variables explicativas. Los resultados sugieren que la regresión bayesiana para datos con correlación espacio-temporal supera a QRF en términos de error de predicción y mapeo de la variabilidad al menos para el tipo de condiciones topográficas y de suelos del estudio. La posibilidad de mapear la evolución del contenido de MO del suelo a esta escala representa un avance para el monitoreo de la sustentabilidad. Los mapas de variabilidad espacial de la MO a escala de campo pueden ser usados para monitorear el efecto de diferentes prácticas de manejo de suelos o como alertas de medidas de manejo que incrementen la entrada de carbono al sistema.

Palabras claves: fertilidad, aprendizaje automático, regresión bayesiana

1 Introducción

La materia orgánica del suelo (MO) juega un papel importante en los sistemas agrícolas. Está estrechamente asociado con la fertilidad del suelo a través de su control sobre las propiedades fisicoquímicas y biológicas del suelo [1]. Además, es uno de los principales indicadores de la calidad y productividad del suelo [2]. Los suelos representan una importante reserva de carbono. El aumento de la MO puede mitigar el cambio climático mediante el almacenamiento de carbono en suelo [3]. Para usar los suelos de manera eficiente y mantener su productividad es esencial lograr estimaciones precisas del contenido de MO y de su variación espacio-temporal. El mapeo digital del suelo (MDS) ha sido propuesto como una alternativa a los estudios de mapeo clásicos del suelo. El MDS permite el mapeo cuantitativo de propiedades del suelo [4]. Se han

llevado a cabo numerosos estudios orientados al MDS con el objetivo de predecir la distribución espacial de MO en los que se ha utilizado una gama amplia de modelos predictivos basados en datos del suelo y el ambiente [5]. Los modelos de predicción espacial embebidos en MDS son generados desde técnicas de regresión lineal por mínimos cuadrados [6], modelos lineales mixtos con estimación máximo verosímil [7] e incluso con métodos de inferencia Bayesiana [8]. A esta diversidad de marcos teóricos conceptuales de la estimación debe agregarse el uso de algoritmos de aprendizaje automático invocados principalmente en contextos de abundante volumen de datos donde las estimaciones de covarianzas espaciales se vuelven imprácticas.

En el marco teórico que soporta la inferencia Bayesiana es necesario estimar la variabilidad en los parámetros del modelo usado para el mapeo en presencia de covarianzas espaciales y temporales [9]. La distribución a estimar no tiene una forma cerrada y se recurre a métodos numéricos para aproximarla. Recientemente se han desarrollado enfoques que permiten la estimación aún en contexto de grandes matrices de covarianza como es el método INLA (del inglés “Integrated Nested Laplace Approximation”) [10] usado para caracterizar la distribución espacial de MO [8, 11]. La incertidumbre en la predicción se describe explícitamente por la densidad posterior que se está estimando [9]. El enfoque bayesiano produce intervalos de credibilidad que indican explícitamente la probabilidad de que los parámetros se encuentren dentro de un rango específico. Dado que cuando se aplica el MDS la predicción de la variable de interés no es el único *output* a generar, sino que también es requisito fundamental generar un mapa con la incertidumbre de predicción [5], contar con una distribución de valores predichos para cada sitio, como la que provee la inferencia Bayesiana, es útil.

Entre los algoritmos de aprendizaje automático, aquellos basados en árbol de regresión como *random forest* (RF) ya han sido usados para mapear distribución espacial de carbono orgánico [12]. Sin embargo, en estos algoritmos la cuantificación de la incertidumbre es más novedosa [13] y no se desprende directamente del RF clásico. Meinshausen (2006) [14] propuso una modificación del algoritmo RF que permite la estimación de los intervalos de predicción de la variable modelada. El procedimiento es denominado *quantile regression forest* (QRF) y considera la propagación de la variable de respuesta para construir los intervalos de predicción. En este trabajo se comparan el algoritmo QRF y la regresión bayesiana en su capacidad predictiva de datos espacio-temporales de MO a escala de campo.

Materiales y Métodos

1.1 Datos experimentales

Se analizaron datos del departamento Río Seco de la provincia Córdoba, Argentina. El área de relevamiento pertenece a la región semiárida y se caracteriza por una topografía de sierra ondulada y una precipitación anual de 700 mm con veranos calurosos. Se analizó la tendencia temporal en un periodo de 12 años (con mediciones cada tres años: 2005, 2008 y 2011) de MO (%). Los datos experimentales fueron recolectados en 12 lotes de 160 a 220 has cada uno, abarcando una superficie total de 2.240 ha bajo

agricultura continua con rotaciones de cultivos anuales (Soja, Maíz y Trigo). Se obtuvieron entre 242 y 279 muestras de suelo en cada año; relevando los mismos sitios de muestreo (Fig. 1). Para ello las muestras fueron georreferenciadas con un DGPS.




Fig. 1. Distribución espacial de los sitios de muestreo.

Los factores ambientales incluidos como variables predictivas en los modelos fueron: variables topográficas derivadas de un modelo digital de elevación (MDE) y atributos relacionados con la dinámica temporal del índice de vegetación normalizado (NDVI). El MDE proviene de la misión ALOS-PALSAR con una resolución de 12.5 m. El cálculo de las variables topográficas se llevó a cabo en SAGA GIS [15], y corresponde a 18 índices topográficos. Para el NDVI en cada año de muestreo se calculó la media y el desvío estándar temporal de todas las imágenes recolectadas durante tres años previos a la toma de la muestra (17, 32 y 24 imágenes para 2005, 2008 y 2011, respectivamente). Las imágenes provinieron de la misión LandSat-5 con una resolución de 30 m. También se calculó el NDVI promedio y desviación estándar temporal usando imágenes Sentinel 2 con una resolución de 10 m para la ventana temporal 2015 a 2020 (130 imágenes). Todas las variables fueron reescaladas para generar una grilla de predicción de forma regular, de dimensión 12.5 m×12.5 m. Previo al ajuste de los modelos se realizó la selección de las variables que serían usadas como predictoras mediante algoritmo Boruta que implementa un enfoque de selección envolvente basado en el algoritmo RF[16]

1.2 Algoritmos de predicción comparados

El algoritmo RF se basa en la combinación de los resultados de múltiples árboles de decisión donde cada árbol depende de los valores de un vector aleatorio independiente y con la misma distribución para cada uno de ellos [17]. En el caso de árboles de regresión la predicción se obtiene promediando las predicciones de todos los árboles. RF calcula y almacena la observación promedio para cada nodo de cada árbol. En el algoritmo QRF, en cada nodo de cada árbol se almacenan todas las observaciones, no

solo su promedio, información con la que se puede evaluar la distribución condicional. Para el ajuste del modelo QRF se incluyó como covariable el año de la toma de muestra como una alternativa para contemplar la variación temporal [12]. En el entrenamiento de QRF se valoraron vía validación cruzada el número de variables a considerar para dividir en cada nodo (*mtree*) usando para ello una cuadrícula de valores (2 a 20) mientras que el número mínimo de nodos terminales y el número de árboles se fijó en 5 y 500, respectivamente. Adicionalmente al modelo QRF se utilizó una alternativa que incorpora la información espacial en la predicción (QRF_KO). Esta aproximación es similar a kriging regresión [18]. Para ello, los residuos obtenidos a partir de QRF fueron modelados usando semivariogramas con modelo exponencial, gaussiano y esférico. El modelo de mejor ajuste fue posteriormente utilizado para predecir valores asociados al patrón espacial en la grilla de predicción y sumar a éstos los valores predichos por QRF. En ambas aproximaciones (QRF y QRF_KO) se incluyó en la grilla de predicción el año 2011 para poder realizar la predicción del contenido de MO para dicho año.

El algoritmo de inferencia bayesiana ajustado utiliza el método INLA para estimar las distribuciones posteriores marginales del valor predicho para cada sitio. Para estimar el modelo, es necesario obtener una representación de la estructura de dependencia desde una estructura de vecindario para datos continuos (malla). La malla se obtuvo mediante triangulación de Delaunay la cual fue generada usando una longitud máxima de borde de triángulo de 80 m y una distancia mínima entre puntos de 20 m. Estos valores se determinaron de manera que los triángulos fueran lo más regulares posible en tamaño y forma [19]. Luego se estableció un modelo para datos geoestadísticos espacio-temporales [20] donde y_{it} representa el contenido de MO (%) medida en el sitio i ($i = 1, \dots, n$) y el año $t = 1, \dots, T$, suponiendo la siguiente distribución para las observaciones:

$$y_{it} \sim \text{normal}(n_{it}, \sigma_e^2),$$

siendo σ_e^2 la varianza del error de medición definido por un proceso de ruido blanco gaussiano, no correlacionado en el tiempo y espacio, y

$$n_{it} = b_0 \sum_{m=1}^M \beta_m x_{mi} + \omega_{it},$$

donde b_0 es el intercepto y β_1, \dots, β_M , son los efectos fijos relacionados con las covariables topográficas y derivadas de índices de vegetación x_1, \dots, x_M . El término ω_{it} se refiere al proceso espacio-temporal latente que cambia con el tiempo con una función autorregresiva de primer orden con coeficiente a e innovaciones espacialmente correlacionadas:

$$\omega_{it} = a\omega_{i(t-1)} + \xi_{it},$$

con $t = 2, \dots, T, |a| < 1$ y $\omega_{i1} \sim \text{normal}(0, \sigma^2 / (1 - a^2))$. Además, ξ_{it} es un campo gaussiano de media cero, que se supone temporalmente independiente y caracterizado por la siguiente función de covarianza espacio-temporal:

$$\text{Cov}(\xi_{it}, \xi_{ju}) = \begin{cases} 0 & \text{if } t \neq u \\ \text{Cov}(\xi_i, \xi_j) & \text{if } t = u \end{cases}$$

para $i \neq j$, con $Cov(\xi_i, \xi_j)$ denotando la covarianza espacial de Matérn (Cressie, 1993).

1.3 Criterios de comparación de las predicciones

Se realizó una validación cruzada del tipo k-fold (con $k=10$) para estimar el error de predicción (diferencia entre el valor observado y predicho por el modelo) y se calcularon cinco medidas de desempeño, el error absoluto medio (MAE), raíz del error cuadrático medio (RMSE), coeficiente de determinación (R^2), cantidad de varianza explicada (AVE) [21] y el coeficiente de correlación de concordancia de Lin (CCC) [22]. MAE y RMSE indican la magnitud del error de predicción promedio. El CCC cuantifica el nivel de concordancia entre los valores observados y predichos mientras que AVE brinda información sobre la proporción de la variación en los datos explicada por el modelo. Además, se realizó una comparación gráfica utilizando el diagrama de Taylor [23], que permiten la visualización del desempeño de los modelos utilizando coeficientes de correlación, RMSE y desviaciones estándar (SD) [24]. También se realizó un diagrama de cuantiles condicionales el cual representan una forma útil para evaluar como las predicciones del modelo concuerdan con las observaciones, a través de la distribución completa de valores observados. Este diagrama divide los datos en “bins” o contenedores espaciados uniformemente. Para cada “bin” de valor predicho, se identifican los valores observados correspondientes y se calcula la mediana, el percentil 25/75 y el percentil 10/90. Los datos se grafican para mostrar cómo éstos valores varían en todos los “bins”.

3 Resultados y Discusión

La comparación de los valores promedios del contenido de MO, entre los diferentes años de estudio (Tabla 1), indicó un incremento en 2008 y posterior caída hacia el 2011. La variación de la MO fue mayor en 2005 (18%) mientras que para 2008 y 2011 fue similar (14%).

Tabla 1. Media, coeficiente de variación (CV), valores mínimos (Min.) y máximos (Max.) del contenido de materia orgánica del suelo (%).

Año	n	Media	CV (%)	Min.	Max.
2005	279	2.88	18	1.47	4.69
2008	279	2.98	14	2.00	4.40
2011	241	2.61	14	1.73	3.89


El desempeño QRF con y sin restricción espacial fue similar (Tabla 2). Si, se observaron diferencias respecto a la regresión bayesiana (INLA) principalmente en el R^2 y CCC. No existe una sola mejor medida para validar los modelos predictivos, por ello es necesario usar una combinación de las medidas de desempeño cuando se tienen como objetivo la comparación de modelos de predicción [25]. Dependiendo de la situación, algunas medidas de desempeño pueden ser más apropiadas que otras [26].

Tabla 2. Medidas del desempeño de modelos de predicción del contenido de materia orgánica en suelo (%).

Modelo	MAE	RMSE	R ²	CCC	AVE
QRF	24.74	0.32	0.23	0.37	0.22
QRF_KO	24.66	0.32	0.22	0.38	0.22
INLA	24.74	0.31	0.30	0.51	0.24

Error absoluto medio (MAE), raíz cuadrada del error cuadrático medio raíz (RMSE), coeficiente de determinación (R²), cantidad de varianza explicada (AVE) y coeficiente de correlación de concordancia de Lin (CCC).

La visualización del desempeño de los modelos usando el diagrama de Taylor sugiere una mejor performance del modelo Bayesiano estimado con INLA (Fig. 2). La variabilidad es representada por la desviación estándar de los valores observados y predichos. El gráfico muestra que la variabilidad observada (dada por la desviación estándar) es de aproximadamente 0.35 (%) y está marcada como "Observado" en el eje de las abscisas. La magnitud de la variabilidad se mide como la distancia radial desde el origen del gráfico. Sobre esta base, todos los modelos tienen menor variabilidad en los valores predichos que la variabilidad observada, aunque INLA presenta una variabilidad más parecida a la medida. El coeficiente de correlación también muestra valores más altos para INLA.

**Fig. 2.** Comparación del desempeño de modelos predictivos del contenido de MO del suelo utilizando el diagrama de Taylor.

En la Fig. 3 se presenta el diagrama de cuantiles condicionales. La línea celeste muestra los resultados para un modelo perfecto. En este caso, las observaciones cubren un rango de 1.7 a 3.9%. La línea roja muestra los valores medios de las predicciones y observaciones correspondientes. Para el caso de ilustración, la regresión bayesiana con INLA muestra una mayor cobertura de los valores observado siendo el mínimo y

máximo de 2 y 3.4%, respectivamente, mientras que para QRF_KO la cobertura fue menor, estos valores fueron de 2.4 a 3.2%. Sin embargo, en INLA las predicciones tienden a ser algo más bajas que las observaciones para la mayoría de los valores de MO (la línea media está debajo de la línea azul). Finalmente, el histograma muestra la distribución de los valores observados (gris) y predichos (celeste). En el modelo bayesiano se observa una mayor concordancia entre ambas distribuciones.

Tabla 3. Media, desvío estándar y cuantiles de los parámetros estimados del modelo bayesiano. Varianza del error experimental (σ_{ε}^2), varianza estructura espacialmente (σ_{ω}^2), distancia donde la correlación es cercana a 0.1 (ρ) y coeficiente de correlación temporal (a).

Parámetro	Media	DE	Cuantiles		
			0.025	0.50	0.975
σ_{ε}^2	0.09	0.01	0.07	0.09	0.12
σ_{ω}^2	0.08	0.01	0.05	0.08	0.11
ρ	546	210	258	504	1071
a	0.75	0.09	0.54	0.77	0.90




Fig. 3. Comparación del desempeño de modelos predictivos del contenido de MO del suelo utilizando un diagrama de cuantiles condicionales.

Los mapas de la predicción espacial obtenida con INLA y QRF_KO se muestran en la Fig. 4. Puede observarse que para QRF_KO los valores de MO presentan una tendencia decreciente desde el noroeste (>3.1%) hacia el este (<2.5%). El rango de variación fue similar en el mapa de INLA aunque la tendencia no fue tan marcada mostrando un comportamiento que depende más de su localización intralote. Este comportamiento puede atribuirse al impacto de las variables explicativas usadas. En el caso de QRF_KO el coeficiente de correlación de Pearson entre los valores predichos y las principales variables topográficas presenta valores significativos que varían entre 0.53 y 0.76 mientras que para INLA estos fueron de 0.37 a 0.53. Estas variables topográficas presentan una marcada estructura de variación espacial la cual se refleja

en la predicción de QRF_KO. En el caso de INLA el desvío estándar del NDVI previo a la toma de la muestra fue la de mayor correlación entre las variables usadas y también respecto a QRF_KO (0.60 vs. 0.44). A diferencia de las variables topográficas, los NDVI no presentaron una tendencia acentuada en su patrón de variación espacial, más bien se observó mayor estructura de variabilidad intralote.

La similitud en el patrón general de valoración obtenido con QRF_KO e INLA puede explicar en parte los resultados de la Tabla 1. La escasa diferencia a nivel de MAE o RMSE entre ambas aproximaciones se debe a que ambos modelos muestran un patrón de variación de la MO acorde a los datos. Cuando se calculan los errores de predicción, que luego son promediados para tener una medida de error global, no se reflejan las diferencias locales. Si se observó una mayor explicación de la variabilidad total en el contenido de MO (R^2) por parte de la regresión bayesiana y una mayor concordancia entre los valores observados y predichos. Los gráficos de Taylor (Fig. 2) y de cuantiles condicionales (Fig. 3) confirman el mejor desempeño de la regresión bayesiana para datos con correlación espacio-temporal. Los mapas de incertidumbre de predicción (Fig. 5) medida como desviación estándar, muestran un comportamiento diferencial que refleja en mayor medida diferencias en la confiabilidad de la predicción de cada celda de la grilla de predicción. Para la regresión bayesiana el mapa muestra menor incertidumbre en sitios cercanos a los puntos de muestreo, comportamiento que comúnmente se observa cuando se obtienen la incertidumbre con métodos geoestadísticos (varianza kriging). Los valores de desvío estándar estuvieron, en la mayor parte de los valores predichos, por debajo de 0.25%. Para QRF_KO el desvío estándar de la predicción sigue la tendencia marcada por los valores predichos. Este comportamiento ha sido observado en el mapeo digital a escala de lote [27] y es comúnmente observado en productos obtenidos desde MDS. Los valores estuvieron en su mayoría por encima de 0.35%. Estas diferencias pueden deberse al hecho que en el caso de modelo bayesiano explícitamente contempla la estructura de correlación espacio-temporal. El alto valor del coeficiente de correlación temporal AR (1) (Tabla 3) de INLA confirma la dependencia temporal del contenido de MO en suelo. En QRF_KO la dimensión temporal es contemplada en forma indirecta incorporando una covariable del año de muestreo. Si bien en este trabajo la predicción se generó para una fecha determinada la misma puede realizarse para cualquiera de las fechas analizadas (2005, 2008, 2011). Esto permite mapear la evolución del contenido de MO del suelo en el tiempo, herramienta clave para monitorear la sustentabilidad de los sistemas productivos

En cuanto a la dimensión espacial en QRF_KO la cual es contemplada incluyendo la interpolación kriging de los residuos en la predicción, no mostró diferencias respecto a QRF en la validación de los modelos. Esto también se observada en el modelo INLA donde la varianza del error experimental fue de mayor magnitud respecto a la estructurada espacialmente (0.09% vs. 0.08%) (Tabla 3). Este impacto menor de la correlación espacial puede deberse al hecho que las covariables usadas, principalmente las topográficas, describen la ubicación espacial y explican la autocorrelación espacial. Diferentes estudios proponen un marco genérico para el modelado predictivo de variables espaciales y espacio-temporales que utilizan como variables explicativas distancias buffer desde los puntos de observación, incorporando así los efectos de proximidad geográfica en el proceso de predicción [12, 28, 29]. La MO se caracterizan por presentar autocorrelación espacial que puede tener cierta redundancia con la

información contenida en las covariables topográficas disponibles. Si la información espacial contenida en los puntos de muestreo se superpone fuertemente con la contenida en las covariables ambientales, incluir ambos tipos de información en un mismo modelo puede conducir a una complejidad innecesaria en el modelo [30].

Para el mapeo de MO se generó una grilla de predicción mediante un reescalado de cada co-variable. Esto es necesario ya que los algoritmos de aprendizaje automático como QRF requieren que la grilla de predicción no tenga datos faltantes. Esto marca una diferencia respecto a INLA, el cual tiene la ventaja de poder realizar la predicción espacial aún en escenarios de datos faltantes en grilla. Esta característica más la posibilidad de derivar mapas de incertidumbre en forma directa y abordar en forma explícita la estructura de correlación espacio-temporal hacen de la regresión bayesiana una estrategia efectiva para la estimación y predicción espacio-temporal.




Fig. 4. Mapas de predicción del contenido de MO del suelo obtenidos a partir del ajuste de un modelo de regresión espacio-temporal bayesiano (izquierda) y del algoritmo *quantile regression forest* con restricción espacial (derecha).




Fig. 5. Mapas de la incertidumbre de predicción (desvío estándar) del contenido de MO del suelo (%) obtenidos a partir del ajuste de un modelo de regresión espacio-temporal bayesiano (izquierda) y del algoritmo *quantile regression forest* con restricción espacial (derecha).

4 Conclusiones

En este artículo hemos comparado el uso de un modelo bayesiano de regresión espacio-temporal vs. un enfoque basado en algoritmo de aprendizaje automático para la predicción espacial de MO del suelo a escala de campo. Los resultados mostraron que la regresión bayesiana estimada por INLA tuvo un mejor desempeño respecto a QRF en sus versiones con y sin restricción espacial para predecir MO en sitios donde no fue medida. El enfoque de la regresión bayesiana mostró una menor incertidumbre en las predicciones. El modelo de regresión para datos correlacionados estimado por INLA muestra gran potencial en la estimación de modelos espacio temporales que, aplicado al mapeo digital de MO del suelo representa un sustancial avance para el monitoreo de la sustentabilidad y de los efectos de las prácticas de manejo aplicadas a escala de campo.

Referencias

1. Tiessen, H., Cuevas, E., Chacon, P.: The role of soil organic matter in sustaining soil fertility. *Nature*. 371, 783–785 (1994).
2. Al-Kaisi, M.M., Yin, X., Licht, M.A.: Soil carbon and nitrogen changes as influenced by tillage and cropping systems in some Iowa soils. *Agric. Ecosyst. Environ.* 105, 635–647 (2005). <https://doi.org/10.1016/j.agee.2004.08.002>.
3. McBratney, A., Field, D.J., Koch, A.: The dimensions of soil security. *Geoderma*. 213, 203–213 (2014).
4. McBratney, A.B., Mendonça Santos, M.L., Minasny, B.: On digital soil mapping. (2003). [https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4).
5. Minasny, B., McBratney, A.B.: Digital soil mapping: A brief history and some lessons. *Geoderma*. 264, (2016).
6. Arrouays, D., Vion, I., Kicin, J.L.U.C.: Spatial analysis and modeling of topsoil carbon storage in temperate forest humic loamy soils of France. *Soil Sci.* 159, (1995).
7. Zhao, K., Fu, W., Liu, X., Huang, D.: Spatial variations of concentrations of copper and its speciation in the soil-rice system in Wenling of southeastern China. (2014).
8. Poggio, L., Gimona, A., Spezia, L., Brewer, M.J.: Bayesian spatial modelling of soil properties and their uncertainty: The example of soil organic matter in Scotland using R-INLA. *Geoderma*. 277, 69–82 (2016).
9. Blangiardo, M., Cameletti, M.: *Spatial and Spatio-temporal Bayesian Models with R-INLA*. John Wiley & Sons, Ltd, Chichester, UK (2015).
10. Rue, H., Riebler, A., Sørbye, S.H., Illian, J.B., Simpson, D.P., Lindgren, F.K.: Bayesian Computing with INLA: A Review. *Annu. Rev. Stat. Its Appl.* 4, 395–421 (2017).
11. Huang, J., Malone, B.P., Minasny, B., McBratney, A.B., Triantafyllis, J.: Evaluating a Bayesian modelling approach (INLA-SPDE) for environmental mapping. *Sci. Total Environ.* 609, 621–632 (2017).
12. Hengl, T., Nussbaum, M., Wright, M.N., Heuvelink, G.B.M., Gräler, B.: Random

- forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. *PeerJ*. 6, e5518 (2018).
13. Szatmári, G., Pásztor, L.: Comparison of various uncertainty modelling approaches based on geostatistics and machine learning algorithms. *Geoderma*. 337, 1329–1340 (2019).
 14. Meinshausen, N.: Quantile regression forests. *J. Mach. Learn. Res.* 7, 983–999 (2006).
 15. Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J., Wichmann, V., Böhner, J.: System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. *Geosci. Model Dev.* 8, 1991–2007 (2015).
 16. Kursa, M.B., Rudnicki, W.R.: Feature selection with the boruta package. *J. Stat. Softw.* 36, 1–13 (2010).
 17. Breiman, L.: Random Forests. *Mach. Learn.* 45, 5–32 (2001).
 18. Hengl, T., Heuvelink, G.B.M., Rossiter, D.G.: About regression-kriging: From equations to case studies. *Comput. Geosci.* 33, 1301–1315 (2007).
 19. Krainski, E.T., Lindgren, F.: The R-INLA tutorial: SPDE models Warning: work in progress. Suggestions are welcome to elias@r-inla.org. (2013).
 20. Blangiardo, M., Cameletti, M., Baio, G., Rue, H.: Spatial and spatio-temporal models with R-INLA. *Spat. Spatiotemporal. Epidemiol.* 4, 33–49 (2013).
 21. Angelini, M.E., Heuvelink, G.B.M., Kempen, B., Morrás, H.J.M.: Mapping the soils of an Argentine Pampas region using structural equation modelling. *Geoderma*. 281, 102–118 (2016).
 22. Steichen, T., Cox, N.: A note on the concordance correlation coefficient. *Stata J.* 2, 183–189 (2002).
 23. Taylor, K.E.: Summarizing multiple aspects of model performance in a single diagram. *J. Geophys. Res. Atmos.* 106, 7183–7192 (2001).
 24. Choubin, B., Malekian, A., Samadi, S., Khalighi-Sigaroodi, S., Sajedi-Hosseini, F.: An ensemble forecast of semi-arid rainfall using large-scale climate predictors. *Meteorol. Appl.* 24, 376–386 (2017).
 25. Chang, J.C., Hanna, S.R.: Air quality model performance evaluation. *Meteorol. Atmos. Phys.* 87, (2004).
 26. Guevara, M., Olmedo, G.F.: Model evaluation in digital soil mapping. In: Yusuf Yigini, Guillermo Federico Olmedo, Stephanie Reiter, Rainer Baritz, Kostiantyn Viatkin, Ronald Vargas. *Global Soil Partnership, F.O. of the U.N. (ed.) Soil Organic Carbon Mapping Cookbook 2nd edition*. p. 220. FAO, Rome (2018).
 27. Arshad, M., Li, N., Bella, L. Di, Triantafyllis, J.: Field-scale digital soil mapping of clay: Combining different proximal sensed data and comparing various statistical models. *Soil Sci. Soc. Am. J.* 84, 314–330 (2020).
 28. Behrens, T., Schmidt, K., Viscarra Rossel, R.A., Gries, P., Scholten, T., MacMillan, R.A.: Spatial modelling with Euclidean distance fields and machine learning. *Eur. J. Soil Sci.* 69, 757–770 (2018).
 29. Walsh, E.S., Kreakie, B.J., Cantwell, M.G., Nacci, D.: A Random Forest approach to predict the spatial distribution of sediment pollution in an estuarine system. *PLoS One*. 12, e0179473 (2017).
 30. Beguin, J., Fuglstad, G., Mansuy, N., Paré, D.: Predicting soil properties in the Canadian boreal forest with limited data: Comparison of spatial and non-spatial statistical approaches. *Geoderma*. 306, 195–205 (2017).