



Cofinanciado por
la Unión Europea



Grupo Operativo Supraautonómico

REGAGE23e00064076457



**Validación de una propuesta
metodológica de agricultura regenerativa
de carbono**

ACTIVIDAD 2

**Establecimiento de la línea base, a través
de muestreos de tierras, de las
explotaciones para su posterior ingreso al
programa de Carbon Farming**

30 – Abril – 2025



Cofinanciado por
la Unión Europea



Agr Regen Carbon

CONSORCIO FORMADO POR:



AENOR



PROGRAMA	Proyectos de Innovación de Interés General por Grupos Operativos Supraautonómicos
ACRÓNIMO PROYECTO	AgriRegenCarbon
PÁGINA WEB PROYECTO	www.agriregencarbon.es
OBJETIVO ESPECÍFICO	OE1. Establecer la viabilidad técnica, logística y económica de la metodología planteada para la monitorización, reporte y verificación de la remoción de emisiones de GEI en el sector agrícola.
RESULTADO	1. Elaboración del documento de diseño del proyecto (PDD) de las explotaciones para su posterior participación en el programa Carbon Farming
ACTIVIDAD	Actividad 2. Establecimiento de la línea base, a través de muestreos de tierras, de las explotaciones para su posterior ingreso al programa de Carbon Farming
ENTREGABLE	Actividad 2. Informe de línea base
PARTNER LIDER	Fundació Universitària Balmes. Centro Tecnológico Beta Tech
PARTNERS COLABORADORES	Azolla EFKT SL
SUBCONTRATADOS PARTICIPANTES	Fundació Universitària Balmes. Centro Tecnológico Beta Tech
VERSIÓN DEL DOCUMENTO	1.0
FECHA FINALIZACIÓN ENTREGABLE	30 de abril de 2025
PASOS PREVIOS	Actividad 1. Elaboración del anteproyecto con distintos escenarios
VINCULADO CON LAS TAREAS	Actividad 1. Elaboración del anteproyecto con distintos escenarios
SIGUIENTES PASOS	Actividad 6. Recopilación de los datos relacionados con la logística, las dificultades y puntos de mejora en el desarrollo del proceso de muestreo



ÍNDICE

Abreviaturas	7
Lista de tablas	8
Resumen	8
1. Estimación de Carbono en el Suelo: Desafíos Metodológicos	11
1.1. Métodos de Muestreo del Suelo	11
1.2. Diferencias en los Procedimientos de Laboratorio	11
1.3. Período de Muestreo del Suelo	12
1.4. Representación Espacial, Escala y Número de Muestras en Estudios del Suelo	12
1.5. Caracterización bioclimática de las áreas de estudio:	13
1.5.1. <i>Condiciones Bioclimáticas del Agricultor 10</i>	13
1.5.2. <i>Condiciones Bioclimáticas de la región central de Aragón</i>	14
2. Créditos de Carbono en Europa y la Estimación de Líneas Base de Carbono en el Suelo	15
2.1. Créditos de Carbono en Europa: Contexto y Relevancia	15
2.2. La Importancia de la Estimación de las Líneas Base de Carbono en el Suelo	15
2.3. Tipos de Carbono en el Suelo	17
3. Estratificación Espacial del Muestreo del Suelo	18
3.1. Áreas continuas y homogéneas	18
3.2. Áreas con heterogeneidad espacial y desconectadas	18
3.3. Errores y Limitaciones en la Estratificación Espacial	19
3.4. Herramientas para Mitigar Incertidumbres	19
4. Objetivos	19
5. Metodología	20



5.1.	Materiales y Programas para la Recolección y Manipulación de Datos	20
5.2.	Metodología de Muestreo	21
5.3.	Diseño muestral para áreas continuas en el Agricultor 10-Castillo de Canena (Jaén, Andalucía)	21
5.4.	Diseño muestral para áreas discontinuas en fincas situadas en la zona central de Aragón	23
5.5.	Metodología para el Cálculo del índice de calidad del suelo (SQI)	26
5.6.	Interpolación Espacial y Modelado para líneas de bases de carbono total	27
5.6.1.	<i>Método de interpolación para Agricultor 10</i>	27
5.6.2.	<i>Método de interpolación para zona central de de Aragón</i>	28
5.7.	Análisis de laboratorio de las muestras de suelo	29
5.7.1.	<i>Cálculo de la Densidad Aparente</i>	30
6.	Resultados y Discusión: muestreo del Agricultor 10	31
6.1.	Línea base de Agricultor 10	31
6.1.1.	<i>Validación Cruzada y Robustez del Modelo</i>	33
6.1.2.	<i>Discusión de Resultados: Índice de Calidad del Suelo (ICS) en Agricultor 10</i>	35
7.	Resultados y Discusión zona central de Aragón	38
7.1.	Línea de base de los agricultores de la zona central de Aragón	38
7.1.1.	<i>Validación Cruzada y Robustez del Modelo</i>	40
7.1.2.	<i>Estructura Espacial (Autocorrelación)</i>	45
7.1.3.	<i>Discusión de Resultados: Índice de Calidad del Suelo (SQI) en FACA</i>	45
7.1.4.	<i>Análisis de la calidad del suelo por Agricultor de la zona central de Aragón</i>	49
8.	Mapas finales de % de Carbono	50
8.1.	Guía para la interpretación de los mapas y tabla final	50
8.1.1.	<i>Agricultor 5</i>	52



Cofinanciado por
la Unión Europea



8.1.2.	Agricultor 4	Error! Bookmark not defined.
8.1.3.	Agricultor 3	Error! Bookmark not defined.
8.1.4.	Agricultor 1	Error! Bookmark not defined.
8.1.5.	Agricultor 7	Error! Bookmark not defined.
8.1.6.	Agricultor 2	Error! Bookmark not defined.
8.1.7.	Agricultor 6	Error! Bookmark not defined.
8.1.8.	Agricultor 9	Error! Bookmark not defined.
8.1.9.	Agricultor 8	Error! Bookmark not defined.
8.1.10.	Agricultor 10-Castillo de Canena	61
8.1.11.	Resumen de Parámetros de Modelado y Resultados de Carbono por Agricultor	62
9.	Conclusión	63
10.	Referencias	65



Abreviaturas

AR – Agricultura Regenerativa

DA – Densidad Aparente

C_o – Efecto Pepita (en semivariogramas)

C_o + C – Meseta (Sill en semivariogramas)

CIS – Carbono Inorgánico del Suelo

COS – Carbono Orgánico del Suelo

CRCF – Climate Reserve Carbon Fund (Reglamento de Eliminaciones de Carbono y Agricultura de Carbono, UE 2024)

DOC – Carbono Orgánico Disuelto

EU ETS – EU Emissions Trading System (Sistema de Comercio de Emisiones de la UE)

FACA – Federación Aragonesa de Cooperativas Agrarias

FAO – Organización de las Naciones Unidas para la Alimentación y la Agricultura

FS – Código SIGPac para Frutos Secos

GIS/SIG – Sistema de Información Geográfica

IPCC – Panel Intergubernamental sobre Cambio Climático

ISO – Organización Internacional de Normalización

LUCAS – Land Use and Coverage Area frame Survey (programa europeo de muestreo de suelos)

ME – Error Medio

MRV – Monitoreo, Reporte y Verificación

MSDR – Mean Squared Deviation Ratio

MT – Código SIGPac para Matorrales

NDVI – Índice de Vegetación de Diferencia Normalizada

PCA – Análisis de Componentes Principales

POM – Materia Orgánica Particulada

PS – Código SIGPac para Pastizales

R² – Coeficiente de Determinación

RMSE – Raíz del Error Cuadrático Medio

SHARInG-MeD – (Iniciativa regional mediterránea mencionada)

SOC – Soil Organic Carbon (Carbono Orgánico del Suelo, equivalente a COS)

SQI – Índice de Calidad del Suelo (Soil Quality Index)

SVM – Máquina de Vectores de Soporte (Support Vector Machine)

TA – Código SIGPac para Tierras Arables

VI – Código SIGPac para Viñas



Lista de tablas

Tabla 1 - Parámetros usados para la estratificación - Agricultor 10-Castillo de Canena

Tabla 2 - Agrupamiento de Clústeres con Base en la Área y Variabilidad Espacial zona central de Aragón

Tabla 3 - Distribución muestral por clúster con ajuste mínimo por clase en Agricultor 10 (Jaén)

Tabla 4 - Métodos Analíticos para la Determinación de Parámetros Edáficos

Tabla 5. Ajuste del Semivariograma y Validación del Modelo para el COS en Agricultor 10 (Jaén)

Tabla 6. Indicadores de Autocorrelación Espacial y Detección de Hotspots por Agricultor – zona central de Aragón

Tabla 7. Categorías de Ajuste Espacial y Factores Explicativos por Agricultor-zona central de Aragón

Lista de figuras

Figura 1A-B - Tipología de muestreo (submuestras por punto) - Agricultor 10

Figura 2 - Diseño muestral en Agricultor 10 en la Comunidad Autónoma de Andalucía (Jaén)

Figura 3 - Diseño muestral en la zona central de la Comunidad Autónoma de Aragón

Figura 4. Estoques de carbono por hectárea en el área del Agricultor 10.

Figura 5 - Semivariograma del COS - Agricultor 10

Figura 6 - Mapa de Moran I para el COS con Valor del Índice y Significancia (p-valor) - Agricultor 10

Figura 7. Validación del Kriging para el COS mediante RMSE y R^2 - Agricultor 10

Figura 8. Relación entre el Carbono Orgánico del Suelo (COS) y el Índice de Calidad del Suelo (SQI)

Figura 9. Índice de Calidad del Suelo (SQI) - Agricultor 10

Figura 10. Matriz de Correlación - Agricultor 10

Figura 11. Carbono por Hectárea por agricultor, método SVM – zona central de Aragón

Figura 12. Relación entre carbono orgánico y calidad del suelo (SQI) – zona central de Aragón

Figura 13. Distribución del SQI por agricultor – zona central de Aragón

Figura 14. Matriz de correlación-zona central de Aragón



Resumen

La agricultura regenerativa de carbono se ha consolidado como un pilar estratégico para enfrentar la crisis climática, restaurar la fertilidad de los suelos y aumentar la resiliencia de los sistemas agrícolas. Basada en prácticas como la reducción de labranza, cultivos de cobertura y rotación diversificada, esta aproximación no solo secuestra carbono atmosférico, sino que también mejora la estructura del suelo, incrementa su biodiversidad microbiana y optimiza la retención de agua. Su relevancia se ve reforzada por el Reglamento de Eliminaciones de Carbono y Agricultura de Carbono (CRCF, 2024) de la UE, que establece un marco voluntario de certificación alineado con el Pacto Verde Europeo y la meta de neutralidad climática para 2050.

Marco Normativo y Proyectos Piloto

El CRCF, complementado por directrices técnicas de la Comisión Europea para monitoreo, reporte y verificación (MRV), busca estandarizar prácticas agrícolas que integren servicios ecosistémicos, conservación de suelos y seguridad alimentaria. En este contexto, el proyecto AgriRegenCarbon emerge como iniciativa pionera en España, validando metodologías de Agricultura Regenerativa (AR) en 3.000 hectáreas de cultivos de olivo, viña, leñosos y extensivos en Andalucía y Aragón. Su diseño innovador incluye:

1. **Estratificación espacial** de parcelas (convencional, transición, regenerativo) para cuantificar la **adicionalidad** en secuestro de carbono orgánico del suelo (COS).
2. **Geoestadística avanzada** (Kriging y Máquina de Vectores de Soporte (SVM)) adaptada a paisajes mediterráneos.
3. **Protocolos de laboratorio estandarizados** (normas ISO 13878:1998, 11265:1994 y 11465:1993 y método de Walkley-Black) para garantizar trazabilidad y escalabilidad.

Resultados, Aplicabilidad, Limitaciones y Consideraciones

- **Área de Agricultor 10-Castillo de Canena):**
 - El carbono orgánico del suelo (COS) promedio fue de **8,9 t/ha**, significativamente inferior a la línea base nacional española (17,5 t/ha), evidenciando discrepancias debido a la resolución espacial gruesa de los datos nacionales de las prácticas regenerativas.
 - La geoestadística (kriging ordinario) reveló **autocorrelación espacial moderada** (Moran's I = 0,611; * $p < 0,001$), con alcances de variograma de hasta 3.896 m, indicando patrones espaciales estructurados en áreas homogéneas.
 - El **RMSE elevado (1,39 t/ha)** y el **R² moderado (0,479)** destacaron limitaciones en el modelado de la heterogeneidad local.
- **Áreas de la Zona Central de Aragón (FACA):**
 - Los modelos SVM mostraron un desempeño variable: **R² entre 0,04 y 0,85**, dependiendo de la estructura espacial (Moran's I) y covariables no espaciales.
 - Áreas con **autocorrelación positiva** (ej.: Agricultor 1, Moran's I = 0,33) alcanzaron mayor precisión (**R² = 0,75; RMSE = 0,72**), mientras que zonas con



variabilidad no estructurada (ej.: Agricultor 7, Moran's I = -0,02) presentaron errores críticos (RMSE > 1,0 t/ha).

- o La línea base nacional **subestimó la variabilidad local**, con valores de COS 43–82% inferiores a los evaluados nacionalmente.

Aplicabilidad

- **Certificación de Carbono:** Los modelos geoestadísticos (kriging y SVM) son viables para estimar COS en áreas homogéneas (*range* > 1.000 m), pero exigen alta resolución espacial (< 500 m) para evitar distorsiones.
- **Agricultura de Precisión:** La identificación de "puntos fríos" de COS (ej.: posibles zonas erosionadas o de diferentes manejos) permite intervenciones localizadas, como enmiendas orgánicas o cultivos de cobertura.
- **Mercados de Carbono:** La armonización metodológica (MRV) es crítica para la credibilidad, especialmente en proyectos con RMSE < 1,0 t/ha y $R^2 \geq 0,3$.

Limitaciones

- **Temporalidad:** La recuperación del COS en suelos mediterráneos requiere décadas, posiblemente limitando la evaluación de nuevos resultados a corto plazo.
- **Modelado:** El kriging subestima la microvariabilidad en áreas heterogéneas (ej.: pendientes, textura del suelo y etc.), mientras que el SVM depende de covariables externas en ausencia de autocorrelación.
- **Agregación de Datos:** Las líneas de base nacionales ocultan variaciones locales, generando riesgos de sobre/subestimación en certificaciones.

Consideraciones Estratégicas

1. **Muestreo Estratificado:** Priorizar zonas críticas (ej.: laderas, cultivos mixtos) para reducir RMSE en áreas heterogéneas.
2. **Modelos Híbridos:** Combinar otros métodos de interpolación espacial con SVM (para covariables no lineales) en paisajes fragmentados.
3. **Escala de Trabajo:** Adoptar resoluciones $\leq 1:5.000$ en proyectos de carbono para alinearse con los criterios CRCF (2024).
4. **Monitoreo Continuo:** Implementar protocolos para carbonatos y pH en suelos alcalinos, evitando degradación estructural.

Conclusión Operativa

Los resultados refuerzan la viabilidad de la agricultura regenerativa para el secuestro de carbono, pero exigen enfoques adaptativos: modelos espaciales precisos para certificación, intervenciones localizadas para resiliencia edáfica y crítica metodológica a las líneas de base nacionales. La integración de geoestadística avanzada y gestión estratificada es esencial para cumplir las metas del Pacto Verde Europeo (2050).



1. Estimación de Carbono en el Suelo: Desafíos Metodológicos

1.1. Métodos de Muestreo del Suelo

La agricultura regenerativa de carbono es un enfoque que tiene como objetivo restaurar la salud del suelo mientras secuestra carbono atmosférico. El objetivo principal de este informe es identificar los principales desafíos y prácticas metodológicas asociadas con la validación de esta propuesta, con énfasis en:

- Estrategias de muestreo de suelos.
- Estratificación espacial.
- Procedimientos de laboratorio.
- Incertidumbres en la cuantificación de carbono.

Estos elementos constituyen la base teórica para establecer líneas de base de carbono

1.2. Diferencias en los Procedimientos de Laboratorio

La elección del método analítico en estudios de suelos es un factor crítico que impacta directamente en la precisión y la comparabilidad de los resultados. Métodos comunes como la combustión seca (LECO) y la oxidación húmeda (Walkley-Black) presentan diferencias sustanciales en términos de sensibilidad, recuperación de carbono y reproducibilidad, lo cual puede generar estimaciones divergentes incluso para una misma muestra (Nelson & Sommers, 1996).

Además, las incertidumbres asociadas a los procedimientos analíticos y de muestreo deben ser consideradas. Estudios han demostrado que la variabilidad del muestreo puede superar ampliamente a la del análisis químico, especialmente en suelos con heterogeneidad estructural o bajos niveles de contaminantes (Buczko et al., 2012; Kim, 2013). Otras fuentes de incertidumbre incluyen:

- Reducción del tamaño de la muestra.
- Manipulación en laboratorio.
- Calibración de equipos (errores relativos de hasta 20-40%) (Alves et al., 2009; Ma, 2009).

Asimismo, es crucial distinguir entre:

- Incertidumbre aleatoria: Variabilidad inherente del suelo.
- Incertidumbre epistémica: Limitaciones por falta de conocimiento (Robinson et al., 2015).

Por ello, instituciones como la FAO y el IPCC recomiendan la estandarización de procedimientos y la evaluación explícita de incertidumbres para garantizar la trazabilidad y comparabilidad de los datos (FAO, 2019).



1.3. Período de Muestreo del Suelo

La estacionalidad impacta significativamente los niveles de carbono en el suelo, especialmente en capas superficiales, donde influyen:

- Descomposición de biomasa.
- Humedad del suelo.
- Actividad microbiana.

Por ejemplo, fracciones como el carbono orgánico disuelto (DOC) y la materia orgánica particulada (POM) presentan variaciones estacionales, con máximos en primavera y mínimos en verano (Schiedung et al., 2017). La biomasa microbiana también sigue este patrón, con picos en primavera y otoño (Evangelou et al., 2020; Xiong et al., 2022).

Recomendaciones:

- Muestreo en períodos de baja actividad biológica (finales de invierno/inicios de primavera).
- Consistencia en la temporada de muestreo para comparabilidad interanual (FAO, 2019).

1.4. Representación Espacial, Escala y Número de Muestras en Estudios del Suelo

Uno de los principales desafíos en la cuantificación del carbono orgánico del suelo radica en la adecuada representación espacial de los parámetros medidos, considerando tanto la heterogeneidad intrínseca del terreno como la escala de muestreo empleada. La variabilidad espacial de las propiedades edáficas, incluyendo el contenido de carbono, nutrientes, puede manifestarse incluso a escalas muy reducidas (Taylor et al., 2005). Esta característica afecta directamente la precisión de los resultados y la confiabilidad de las inferencias realizadas a partir de los datos obtenidos.

La relación entre escala de observación y variabilidad de los parámetros del suelo ha sido ampliamente documentada. Estudios comparativos han demostrado que al incrementar la escala espacial de análisis - desde parcelas experimentales hasta unidades de paisaje - se produce un aumento sustancial en la variabilidad de los parámetros medidos (Hong, 2008). Este fenómeno impone requerimientos específicos sobre el número mínimo de muestras necesarias para mantener un nivel aceptable de precisión estadística. En condiciones de relativa homogeneidad edáfica, un número limitado de puntos de muestreo puede resultar suficiente; sin embargo, en ambientes con alta heterogeneidad estructural o bajo diferentes usos del suelo, se hace indispensable implementar diseños de muestreo más densos que permitan capturar adecuadamente esta variabilidad espacial (Buczko et al., 2012).

La determinación del número óptimo de muestras representa un balance entre consideraciones estadísticas y limitaciones prácticas. Investigaciones realizadas a diferentes escalas han demostrado que la incertidumbre asociada a las mediciones puede reducirse significativamente mediante el empleo de escalas de muestreo más finas (Li et al., 2014). No obstante, este enfoque conlleva incrementos sustanciales en los costos operativos y analíticos, lo que obliga a buscar estrategias de optimización.

Un aspecto particularmente relevante es que, en muchos casos, la incertidumbre asociada al proceso de muestreo supera ampliamente la incertidumbre analítica propia de los procedimientos de laboratorio. Esta diferencia se acentúa notablemente en suelos con presencia de contaminantes o con alta variabilidad interna en sus propiedades físicas y químicas. Algunos estudios reportan que la incertidumbre derivada del muestreo puede



llegar a ser hasta veinte veces mayor que la generada en las etapas analíticas posteriores (Taylor et al., 2005; Argyraki & Petrakaki, 2017).

Para abordar estos desafíos, se han desarrollado diversas estrategias metodológicas. El muestreo compuesto, los análisis de variogramas y las simulaciones condicionales han demostrado su eficacia para optimizar los diseños de muestreo, permitiendo reducir tanto los costos como las incertidumbres asociadas (Einax & Kraft, 2002; Guo et al., 2020). Estas aproximaciones resultan particularmente valiosas cuando se trabaja con grandes extensiones o cuando los recursos disponibles son limitados. La integración de estas técnicas con los sistemas de información geográfica abre posibilidades para refinar y estandarizar el diseño de protocolos de muestreo más eficientes y representativos.

1.5. Caracterización bioclimática de las áreas de estudio:

1.5.1. Condiciones Bioclimáticas del Agricultor 10

La provincia de Jaén, ubicada en el noreste de Andalucía, se caracteriza por un clima mediterráneo con marcado carácter continental, especialmente en sus zonas interiores. Esta región presenta inviernos fríos a moderados y veranos cálidos y secos, con una notable aridez estival. La temperatura media anual oscila entre 17 y 18 °C, con máximas que superan los 35 °C durante los meses de julio y agosto, particularmente en el valle del Guadalquivir (Tocados-Franco et al., 2023).

Las precipitaciones anuales varían entre 500 y 700 mm, distribuyéndose de forma irregular y concentrándose entre los meses de octubre y abril, debido a la influencia de frentes húmedos procedentes del Atlántico (Casas-Castillo et al., 2022). Durante los meses estivales (junio a septiembre), la pluviometría es escasa, con acumulados inferiores a 20 mm/mes, lo que define un periodo seco de aproximadamente cuatro meses. A finales del verano e inicios del otoño, pueden producirse tormentas convectivas localizadas, más frecuentes en áreas orientales como Almería.

La provincia se encuentra integrada en la Cuenca Hidrográfica del Guadalquivir, que representa alrededor del 25 % del área regada de España. Esta cuenca tiene una precipitación media de 590 mm/año y una disponibilidad de recursos hídricos que asciende a 7540 hm³/año en aguas superficiales y 1851 hm³/año en aguas subterráneas. La demanda total de agua alcanza los 3720.48 hm³/año, siendo el 86 % destinado a uso agrícola, mientras que el 11 % corresponde al uso urbano. Del total de agua utilizada, el 76 % proviene de fuentes superficiales reguladas y no reguladas (CHG, 2022; Tocados-Franco et al., 2023).

La climatología de Jaén favorece el cultivo del olivar (*Olea europaea*), el cual constituye la base del modelo agronómico provincial. Estudios realizados en plantaciones irrigadas de olivo en Andalucía indican que este cultivo presenta una elevada eficiencia en el uso del agua, con una evapotranspiración media anual de entre 850 y 1000 mm, dependiendo de la localización y las condiciones climáticas específicas (Pastor et al., 2007). Las variedades de olivo predominantes, como la Picual, muestran buena adaptación tanto a la sequía estival como a las bajas temperaturas invernales.

En cuanto al ombrotipo, la región se clasifica como seco-subhúmedo (I_o = 3.5–4.5), aunque se observa un aumento de la pluviometría con la altitud. En zonas montañosas como la Sierra de Cazorla, las precipitaciones pueden alcanzar los 1000 mm/año (Casas-Castillo et al., 2022). La altitud también influye significativamente en la temperatura media anual. En áreas superiores a los 1000 m sobre el nivel del mar., como la Sierra Mágina, se registran temperaturas medias entre 12 y 14 °C, con frecuentes heladas (30–60 días/año) y nevadas



invernales. Por el contrario, en zonas deprimidas como La Loma, las inversiones térmicas provocan mínimas invernales de hasta -5°C .

1.5.2. *Condiciones Bioclimáticas de la región central de Aragón*

La región central de Aragón, que incluye la Depresión del Ebro y áreas adyacentes, presenta una notable complejidad bioclimática como resultado de su diversidad topográfica y altitudinal. Esta zona integra sistemas montañosos como el Sistema Ibérico y el Prepirineo, además de áreas áridas como los Monegros, configurando una matriz ambiental de gran heterogeneidad (López et al., 2015).

Desde una perspectiva térmica, Aragón muestra una marcada variabilidad espacial en las temperaturas. Datos de reconstrucción climática de alta resolución indican que las temperaturas medias anuales en la depresión del Ebro alcanzan los 15°C , mientras que en las zonas prepirenaicas descienden considerablemente, en particular en altitudes superiores a 1.000 metros sobre el nivel de mar (Serrano-Notivoli et al., 2024). Esta amplitud térmica se traduce en veranos extremadamente cálidos y secos, con máximas que pueden superar los 40°C , y en inviernos fríos, particularmente en áreas montañosas.

Las precipitaciones muestran un patrón irregular, con valores que oscilan entre menos de 300 mm en sectores esteparios como los Monegros, hasta más de 700 mm en áreas montañosas del norte. Esta distribución está fuertemente condicionada por la altitud y la exposición orográfica, siendo el régimen pluviométrico típicamente mediterráneo, con máximos en primavera y otoño (del Valle Melendo, 2017).

El viento del noroeste, conocido como cierzo, es uno de los factores climáticos predominantes. Su presencia, además de influir en la evapotranspiración, desempeña un papel importante en la propagación de incendios forestales, especialmente en periodos secos. Estudios sobre el riesgo ambiental han correlacionado la incidencia de incendios con condiciones meteorológicas extremas, como elevadas temperaturas y fuertes vientos (Álvarez Lamata, 2005).

La diversidad climática se refleja en la zonificación bioclimática. En Aragón se identifican al menos seis bioclimas, con predominio del macrobioclima mediterráneo, aunque también se presentan zonas de carácter templado, especialmente en altitudes elevadas. Aproximadamente el 40% del territorio es estepario, el 50% mesomediterráneo, y casi la mitad del área muestra condiciones secas o muy secas (López et al., 2015).



2. Créditos de Carbono en Europa y la Estimación de Líneas Base de Carbono en el Suelo

2.1. Créditos de Carbono en Europa: Contexto y Relevancia

Los créditos de carbono son certificados que representan la reducción o eliminación de una tonelada de dióxido de carbono equivalente (CO₂e) de la atmósfera. En Europa, forman parte de una posible estrategia de mitigación del cambio climático, alineada con el Pacto Verde Europeo y el objetivo de neutralidad climática para 2050.

El principal sistema regulado es el Sistema de Comercio de Emisiones de la Unión Europea (EU ETS), orientado principalmente a los sectores industrial y energético. Sin embargo, el sector del uso del suelo, especialmente la agricultura y la gestión de suelos, se está convirtiendo en un componente clave del mercado voluntario de carbono, donde prácticas como la siembra directa, la rotación de cultivos y la adición de materia orgánica al suelo pueden generar créditos validados por secuestro de carbono.

En 2023, la Comisión Europea lanzó un marco regulatorio para certificar la eliminación de carbono, que incluye mecanismos como:

- Agricultura de carbono (“carbon farming”)
- Reforestación y bosques de manejo sostenible
- Biochar y mejora del suelo con materiales ricos en carbono
- Captura directa de aire con almacenamiento geológico

La credibilidad de estos créditos depende de la capacidad de demostrar que la práctica adoptada realmente aumentó la reserva de carbono en comparación con lo que ocurriría en el escenario de referencia. Para ello, la estimación de las líneas base de carbono en el suelo es fundamental.

2.2. La Importancia de la Estimación de las Líneas Base de Carbono en el Suelo

La línea base (LB) de carbono orgánico del suelo (COS) constituye el núcleo metodológico para cuantificar la adicionalidad en proyectos de secuestro de carbono. Su estimación es un requisito técnico para certificaciones como el CRCF (Climate Reserve Carbon Fund), sino también un imperativo científico para evitar la sobreestimación de créditos, un problema crítico evidenciado en la literatura científica. Estudios recientes revelan que prácticas como la labranza reducida y los cultivos de cobertura, aunque promueven ganancias promedio de ~0,3 t C/ha/año en sistemas templados (Eagle & Olander, 2012; Poeplau & Don, 2015), pueden generar sesgos metodológicos si solo se consideran los primeros 10-30 cm del suelo. Esto se debe a que estas prácticas redistribuyen el carbono a capas más profundas sin necesariamente aumentar el almacenamiento total, lo que inflaría artificialmente los créditos si no se incluyen muestras de subsuelo (Meurer et al., 2018; Cai et al., 2022).



Además, la dependencia de modelos simplificados (ej. Tier 1 del IPCC) que no incorporan interacciones entre prácticas (ej. cobertura vegetal + rotaciones diversificadas) ni efectos en emisiones de N₂O limita la precisión de las LB (Oldfield et al., 2021). En respuesta, enfoques innovadores como el marco práctico-agnóstico propuesto por Sykes et al. (2020) priorizan métricas intermedias (ej. producción primaria, perturbación del suelo) sobre listas de prácticas predeterminadas, permitiendo adaptación local.

Por ejemplo, en Francia, donde el 59% de los pastizales ya presentan saturación de COS (Martin et al., 2021), este enfoque identifica límites físicos de almacenamiento basados en la textura del suelo (fracción mineral fina <63 µm) mediante la ecuación de Hassink (Chen et al., 2018). Herramientas como *Soils Revealed*, que combinan datos históricos de pérdidas de COS (Sanderman et al., 2017) con proyecciones espaciotemporales, estiman ganancias potenciales de hasta 20 t C/ha en 20 años bajo manejo mejorado, destacando la necesidad de LB dinámicas y contextualizadas para evitar extrapolaciones irreales.

La precisión en la definición de la línea base es esencial para garantizar:

1. **Adicionalidad:** Solo el carbono que supera la línea base puede ser acreditado, evitando financiar cambios que ocurrirían bajo prácticas convencionales. Esto es crítico en prácticas como la labranza reducida, que redistribuyen el carbono a capas más profundas (>30 cm) sin aumentar el almacenamiento total, lo que inflaría los créditos si solo se miden los primeros centímetros del suelo (Meurer et al., 2018; Cai et al., 2022).
2. **Credibilidad:** Estimaciones robustas evitan sesgos como los generados por modelos simplificados (ej. Tier 1 del IPCC) que ignoran interacciones entre prácticas (ej. cultivos de cobertura + rotaciones) y efectos en emisiones de N₂O (Oldfield et al., 2021).
3. **Permanencia:** Permite monitorear si las reservas se mantienen a largo plazo, considerando límites físicos como la saturación de COS en suelos (ej. 59% de pastizales franceses; Martin et al., 2021).

Las estimaciones de línea base pueden realizarse mediante:

- **Modelos biofísicos y empíricos:** Marcos práctico-agnósticos (Sykes et al., 2020) que priorizan métricas como producción primaria y perturbación del suelo, evitando listas rígidas de prácticas.
- **Datos de campo:** Muestreo estratificado (0–30 cm o más profundo) para capturar redistribuciones verticales, esencial en prácticas como labranza reducida (Meurer et al., 2018).
- **Teledetección y SIG:** Plataformas como *Soils Revealed* combinan datos históricos de pérdidas de COS (Sanderman et al., 2017) con proyecciones espaciotemporales, mapeando ganancias potenciales de hasta 20 t C/ha en 20 años bajo manejo mejorado.

Sin una línea base sólida, los créditos pueden ser engañosos, como ocurre en mercados voluntarios que certifican labranza reducida a pesar de su bajo impacto real en el secuestro neto (Oldfield et al., 2021). Esto compromete la integridad del mercado y la confianza de inversores, destacando la urgencia de protocolos actualizados que incorporen límites de saturación (Chen et al., 2018) y escalas temporales realistas.



2.3. Tipos de Carbono en el Suelo

El carbono del suelo representa uno de los mayores reservorios terrestres de carbono, desempeñando un papel clave en la regulación del clima y la sostenibilidad de los ecosistemas. Su dinámica, determinada por la interacción de fracciones orgánicas e inorgánicas, influye directamente en su capacidad para secuestrar carbono a largo plazo. En esta sección se analizan los tipos de carbono presentes en el suelo, su estabilidad y tiempo de residencia, fundamentando la elección del carbono total como indicador integral en programas de monitoreo ambiental.

Carbono Orgánico: Fracciones y Estabilidad

El carbono orgánico deriva de la descomposición de materia vegetal y microbiana, clasificándose en tres fracciones según su estabilidad:

1. **Carbono lábil:** Compuesto por azúcares, aminoácidos y biomasa microbiana, es la fracción más reactiva, con un tiempo de residencia de días a meses. Su disponibilidad responde rápidamente a cambios en el manejo agrícola o climático (Zou et al., 2005). Estudios recientes demuestran que esta fracción está sujeta a efectos de *priming* microbiano, donde la adición de sustratos frescos acelera su mineralización (Blagodatskaya & Kuzyakov, 2008).
2. **Carbono de descomposición intermedia:** Incluye celulosas y hemicelulosas parcialmente degradadas, con una resistencia moderada a la mineralización (10–100 años). Su persistencia depende de factores como la temperatura y la formación de microagregados (Paul et al., 2001).
3. **Carbono estable (recalcitrante):** Asociado a minerales arcillosos o encapsulado en macroagregados, presenta tiempos de residencia milenarios. Su protección fisicoquímica limita su participación en ciclos biogeoquímicos activos (Fontaine et al., 2004; Guenet et al., 2010). Esta fracción contribuye al secuestro a largo plazo, aunque su acumulación puede suprimir la mineralización de carbono lábil (*efecto negativo de priming*) en condiciones áridas (Guenet et al., 2010).

Carbono Inorgánico del Suelo (CIS)

Predominante en zonas áridas, el CIS incluye carbonatos primarios (litogénicos) y secundarios (pedogénicos). Aunque tradicionalmente considerado estático, estudios recientes evidencian su movilización por procesos erosivos o transformación microbiana a formas orgánicas (Liu et al., 2020). Con un tiempo de residencia promedio de ~85.000 años, regula flujos geológicos de CO₂ pero contribuye marginalmente al ciclo activo del carbono (LaI, 2004). En ecosistemas secos, su acumulación puede alcanzar el 40% del stock total de carbono edáfico.

Tiempo de Residencia del Carbono en el Suelo

El tiempo de residencia refleja la interacción entre las propiedades del carbono, el ambiente edáfico y las prácticas antropogénicas. Las estimaciones globales indican:

- **Carbono lábil:** días a meses (Zou et al., 2005).
- **Carbono intermedio:** 10–100 años (Paul et al., 2001; Ferraz de Almeida et al., 2019).
- **Carbono estable:** 1.000–6.000 años (Fontaine et al., 2004; Guenet et al., 2010).
- **CIS:** hasta decenas de miles de años (LaI, 2004).



La profundidad del suelo también modula esta dinámica: las capas superficiales albergan carbono más lábil, mientras que en profundidad predominan formas estables asociadas a minerales (Paul et al., 2001). Esta estratificación vertical debe considerarse en modelos de secuestro (Crowther et al., 2019).

3. Estratificación Espacial del Muestreo del Suelo

La estratificación espacial es un método utilizado para dividir un área de estudio en subzonas o "estratos" homogéneos desde el punto de vista de ciertas características relevantes del suelo (como textura, uso del suelo, pendiente, tipo de cobertura vegetal, etc.), antes de realizar el muestreo. El objetivo es reducir la variabilidad dentro de cada estrato y aumentar la precisión y representatividad de los resultados del muestreo.

Esta técnica permite optimizar la distribución de las muestras, asegurando que se recojan datos significativos en cada tipo de condición presente en el terreno. Además, mejora la eficiencia del análisis, ya que permite inferencias más robustas y comparaciones más precisas entre diferentes áreas del suelo.

3.1. Áreas continuas y homogéneas

En áreas con homogeneidad edáfica y climática, la estratificación se simplifica al reducirse la variabilidad espacial intrínseca. En estos casos, el diseño de mallas de muestreo amplias (>100 m) es viable, ya que la autocorrelación espacial del carbono orgánico del suelo (COS) y otras propiedades suele ser alta (Minasny et al., 2013). La estratificación aquí puede basarse en factores únicos dominantes, como series de suelo o pendientes uniformes, minimizando el número de muestras sin sacrificar precisión. No obstante, incluso en áreas aparentemente homogéneas, la subestimación de micro variabilidades (p. ej., contenido de arcilla, prácticas históricas de manejo) puede introducir errores sistemáticos en los modelos de predicción (Webster & Oliver, 2014).

3.2. Áreas con heterogeneidad espacial y desconectadas

En paisajes discontinuos o con alta fragmentación (p. ej., polígonos agrícolas no contiguos), la estratificación requiere enfoques multicriterio. La combinación de variables como tipo de suelo, pendiente, evapotranspiración y cultivo permite definir subzonas con dinámicas de COS diferenciadas (Lagacherie & McBratney, 2007). Sin embargo, la desconexión física entre polígonos introduce desafíos:

- **Errores de extrapolación:** Modelos geoestadísticos (p. ej., Kriging) asumen estacionariedad espacial, premisa que se viola en áreas discontinuas, generando incertidumbres en los semivariogramas (Goovaerts, 1999).
- **Limitaciones logísticas:** La necesidad de muestrear cada polígono independientemente aumenta los costos, especialmente si se prioriza un mínimo de 1 muestra por clase minoritaria (Brus, 2019).

Herramientas de Sistemas de Información Geográfica (SIG) permiten optimizar la distribución de puntos mediante algoritmos de distancia mínima, pero persisten riesgos de sesgo si las zonas de transición entre polígonos no se capturan adecuadamente (de Gruijter et al., 2015).



3.3. Errores y Limitaciones en la Estratificación Espacial

- **Subestimación de la variabilidad:** Estratificar solo por clases dominantes (p. ej., 82.8% del área en un *cluster*) puede omitir "puntos calientes" de COS en zonas minoritarias, afectando la precisión de inventarios (McBratney et al., 2003).
- **Resolución vs. recursos:** Mallas densas (<30 m) reducen errores de interpolación, pero son inviables en áreas extensas. Estudios sugieren que un error muestral <10% requiere ≥ 15 muestras por estrato, criterio difícil de cumplir en estratos pequeños (Wendt & Hauser, 2013).
- **Limitaciones de las herramientas SIG:** La dependencia de datos geoespaciales (p. ej., NDVI, pendiente, evapotranspiración) está sujeta a errores de resolución espacial y temporal.

3.4. Herramientas para Mitigar Incertidumbres

- **Semivariogramas direccionales:** Útiles para diagnosticar anisotropías en áreas heterogéneas, identificando direcciones de mayor continuidad espacial (Oliver & Webster, 2014).
- **Muestreo adaptativo:** Ajustar la densidad de muestras en campañas sucesivas basándose en resultados preliminares, focalizando zonas con alta varianza residual (Brus, 2019).
- **Validación cruzada espacial:** Comparar predicciones de Kriging con muestras de verificación independientes para cuantificar sesgos locales (Minasny & McBratney, 2016).

4. Objetivos

La evaluación del potencial de captura de carbono en sistemas agrícolas mediterráneos se basa en un enfoque metodológico integral, estructurado en cuatro etapas clave. Primero, se realiza una estratificación de parcelas considerando variables críticas como pendiente, tipo de suelo, manejo agrícola, clima y cultivos. Luego, se aplica un muestreo estratificado aleatorio con submuestras para garantizar precisión. Posteriormente, se analiza el carbono total, carbonatos, nitrógeno y materia orgánica del suelo, utilizando métodos estandarizados, con el fin de evaluar la efectividad de la Agricultura Regenerativa mediante el Índice de Calidad del Suelo (SQI). Finalmente, se establece una línea base de carbono para medir las capturas futuras y validar la adicionalidad de los proyectos. Este enfoque metodológico está alineado con los objetivos listados a continuación, que guiarán la implementación y análisis de los proyectos en el contexto mediterráneo.

- a) **Estratificación de parcelas:** Delimitar unidades de muestreo representativas considerando variables clave para la captura de carbono (pendiente, tipo de suelo, manejo agrícola, clima y cultivo).
- b) **Muestreo estratificado aleatorio:** Recolectar muestras compuestas por tres submuestras para garantizar precisión y representatividad de los datos.
- c) **Análisis de parámetros edáficos:** Cuantificar carbono total (orgánico/inorgánico), carbonatos, nitrógeno total y materia orgánica mediante métodos estandarizados, evaluando el impacto de la Agricultura Regenerativa por medio del índice de calidad del suelo.
- d) **Línea base de carbono:** Establecer un punto de referencia inicial para medir futuras capturas (*Carbon Removals*) y validar la adicionalidad de los proyectos.



5. Metodología

5.1. Materiales y Programas para la Recolección y Manipulación de Datos

La ejecución del estudio requirió la integración de herramientas técnicas, equipos especializados y plataformas digitales para garantizar la precisión y trazabilidad de los datos. A continuación, se detallan los materiales y programas clave utilizados en cada fase del proceso:

Recolección de datos en campo

- **Equipos de muestreo:** Barrena manual de acero inoxidable para extracción de muestras a 30 cm de profundidad, GPS con margen de error <7 m) para georreferenciación, y kits de almacenamiento de muestras.
- **Diseño espacial:** Utilización de QGIS (versión 3.28) con complementos como *Random Points Within Polygons* y *Intersection* para generar mallas de muestreo estratificadas y asignar puntos aleatorios en polígonos SIGPAC.

Procesamiento geoestadístico y modelado

- **Software especializado:**
 - *RStudio* (paquetes *gstat*, *caret*, y *e1071*) para interpolación espacial (modelos SVM. Juntamente con *FactoMineR* (en R) para análisis de componentes principales (PCA) en el cálculo del Índice de Calidad del Suelo (SQI).
 - *Smart-Map* (plugin de QGIS) para semivariogramas y validación cruzada de modelos.
- **Bases de datos auxiliares:**
 - Mapas de suelo de Andalucía (1:400.000) y Aragón (SIGPAC), integrados con capas raster de evapotranspiración y pendiente.
 - Datos de la densidad aparente para Europa del ESDAC JRC (Panagos et. al. 2024)
 - Datos climáticos históricos de la Agencia Estatal de Meteorología (AEMET) para correlación con variabilidad de COS.

Esta infraestructura metodológica, combinando técnicas clásicas y tecnologías emergentes, permitió abordar la complejidad de los sistemas mediterráneos, desde la escala de parcela hasta la regional, asegurando robustez científica y aplicabilidad práctica.



5.2. Metodología de Muestreo

Se empleó un muestreo compuesto por sitio, con tres submuestras por punto (Figura 1 A y B) que representan una unidad de análisis. Las muestras fueron extraídas con **barrena manual** a una profundidad uniforme de **30 cm**.

- Cada punto fue georreferenciado con GPS.
- Las submuestras fueron homogeneizadas en campo para formar una muestra compuesta por punto.



Figura 1A-B - Tipología de muestreo (submuestras por punto) - Agricultor 10

5.3. Diseño muestral para áreas continuas en el Agricultor 10- Castillo de Canena (Jaén, Andalucía):

Metodología de Estratificación

La estratificación del área de estudio en Jaén se basó en la integración de variables edáficas (tipo de suelo) y topográficas (pendiente) y de evapotranspiración, siguiendo un enfoque jerárquico. Los estratos se definieron considerando:

Pendiente del terreno:

Clasificada según el *Soil Survey Manual* (FAO, 2006) en:

- Casi nivel (0–3°).
- Suavemente inclinado (4–8°).
- Muy inclinado (9–16°).
- Moderadamente empinado (17–30°).

Tipo de suelo:

Se utilizó el *Mapa de Suelos de Andalucía (1:400.000)*, priorizando asociaciones de unidades edáficas predominantes en la zona:

- Cambisoles cálcicos y vérticos.
- Regosoles calcáreos.
- Litosoles y Fluvisoles calcáreos.
- Vertisoles crómicos y pélicos.
- Rendsinas (en combinación con otras unidades).

Rango de evapotranspiración:

Dentro del polígono seleccionado se encontraban los intervalos y evapotranspiración correspondientes a: **700–800 mm** y **800–900 mm**.



Estratos Definidos

La combinación de estos criterios generó 21 estratos iniciales (Tabla 1), posteriormente simplificados a 17 mediante la agrupación de categorías afines (e.g., pendientes "casi nivel" y "suavemente inclinado" en contextos similares). A continuación, se detallan los estratos empleados:

Tabla 1 - Parámetros usados para la estratificación - Agricultor 10-Castillo de Canena

Estr. Id	Pendiente	Tipo de suelo (asociaciones dominantes)	Altitud (m)
1	Casi nivel	Cambisoles cálcicos y Regosoles calcáreos con Litosoles, Fluvisoles calcáreos y Cambisoles vérticos	800–900
2	Casi nivel	Cambisoles cálcicos, Regosoles calcáreos y Litosoles con Rendsinas	800–900
3	Casi nivel	Regosoles calcáreos y Litosoles con Cambisoles cálcicos	700–800
...
20	Suavemente inclinado	Vertisoles crómicos y Cambisoles vérticos con Cambisoles cálcicos, Regosoles calcáreos y Vertisoles pélicos	700–800
21	Suavemente inclinado	Vertisoles crómicos y Cambisoles vérticos con Cambisoles cálcicos, Regosoles calcáreos y Vertisoles pélicos	800–900

Generación de Puntos de Muestreo

Se aplicó un **muestreo aleatorio estratificado** con:

- **Distribución proporcional:** Asignación de puntos por estrato según su área relativa.
- **Distancia mínima:** 500 m entre puntos (**94 muestras totales**). Como se puede observar en el mapa de diseño muestral (Figura 2):




Figura 2. Diseño muestral en Agricultor 10 en la Comunidad Autónoma de Andalucía (Jaén)

5.4. Diseño muestral para áreas discontinuas en fincas situadas en la zona central de Aragón:

Muestreo estratificado:

En este caso al tratarse de diferentes fincas situadas en la parte central de la Comunidad Autónoma de Aragón, se implementó un diseño estratificado basado en la heterogeneidad del terreno, asegurando una asignación proporcional de muestras según el tamaño de los estratos (Manly & Navarro Alberto, 2025).

Este enfoque optimiza la precisión al reducir la varianza intraestrato, siguiendo recomendaciones de asignación óptima (Cochran, 1977). Se identificaron las siguientes clases de suelo y sus áreas totales (en m²), sobreponiendo los polígonos del SIGPAC de los agricultores seleccionados con el mapa de suelos de Aragón:

- **SOLOCHAK GLEICO:** 14.283,187 m²
- **RENDZINA-LITOSOL:** 26.239,740 m²



- **XEROSOL CÁLCICO:** 307.319,848 m²
- **REGOSOL CALCÁREO – YERMOSOL CÁLCICO:** 332.576,129 m²
- **SUELO NO CLASIFICADO:** 434.459,184 m²
- **YERMOSOL GIPSÍCO – REGOSOL CALCÁREO:** 612.403,041 m²
- **SOLONCHAK ORTICO (FASE ALCALINA):** 827.132,467 m²
- **CAMBISOL CÁLCICO:** 1.034.154,348 m²
- **FLUVISOL CALCÁREO:** 5.396.619,145 m²
- **CAMBISOL CÁLCICO (FASE LÍTICA):** 5.727.096,107 m²
- **XEROSOL CÁLCICO – REGOSOL CALCÁREO:** 6.161.847,140 m²
- **Área Total:** 20.874.130 m².

Intersección espacial:

Mediante herramientas de geoprocésamiento QGIS, se interceptaron capas de uso de suelo y evapotranspiración del SIGPAC. Esto permitió asignar valores de evapotranspiración a cada clase de suelo, integrando su variabilidad espacial en el diseño de muestreo.

Agrupamiento por Área y Variabilidad

Para optimizar el muestreo, las clases se agruparon en tres según la Tabla 2

Tabla 2. Agrupación de clústeres según el área y la variabilidad espacial en la zona central de Aragón

Clúster	Clases Incluidas	Área (m ²)	Proporción
Alta Prioridad	Xerosol cálcico-Regosol calcáreo; Cambisol cálcico (Fase Lítica); Fluvisol Calcáreo	17.285.562	82,8%
Variabilidad Media	Solonchak ortico; Yermosol gipsíco-Regosol calcáreo; Gamsisol Cálculo	2.473.690	11,8%
Baja Variabilidad	Regosol calcáreo-Yermosol cálcico; Xerosol cálcico; Rendzina-Litosol; Solonchak gleico	1.114.878	5,4%

Asignación de Muestras

Las muestras se distribuyeron proporcionalmente al área de cada *clúster*, con ajustes para garantizar ≥ 20 muestras por clase (Tabla 3):

Tabla 3. Distribución muestral por clúster con ajuste mínimo por clase en la zona central de Aragón

Clúster	Muestras Proporcionales	Muestras Ajustadas	Justificación
Alta Prioridad	389 (82,8% de 370)	306	Densidad alta para capturar heterogeneidad espacial.



Variabilidad Media	56 (11,8% de 370)	44	Muestreo moderado para equilibrio entre recursos y representatividad.
Baja Variabilidad	25 (5,4% de 370)	20	Mínimo muestreo por áreas reducidas y baja variabilidad.

Muestreo aleatorio:

Se generaron puntos mediante la herramienta "*Puntos Aleatorios Dentro de Polígonos*" en QGIS, ajustando la densidad según la variabilidad de cada clúster.

Intersección espacial:

Se utilizó la herramienta "*Intersección*" en QGIS para combinar capas de suelo estratificadas y evapotranspiración, asignando valores ráster de evapotranspiración anual a cada punto garantizando la variabilidad de evapotranspiración sobre todos los clústeres.

Resultado final de la estratificación

Finalmente, el número de muestras fue de 370 distribuidas tal y como se puede observar en la Figura 3..




Figura 3. Diseño muestral en la zona central de la Comunidad Autónoma de Aragón



5.5. Metodología para el Cálculo del índice de calidad del suelo (SQI)

El **Índice de Calidad del Suelo** (SQI, por sus siglas en inglés) es una herramienta integral para evaluar la salud del suelo en sistemas agrícolas mediterráneos. En este informe detalla una metodología adaptada, basada en protocolos estandarizados y estudios previos que aplican análisis multivariados como PCA (Análisis de Componentes Principales) en suelos de clima mediterráneo (Triantafyllidis et al., 2019). El enfoque combina técnicas estadísticas multivariadas y normalización relativa para asegurar la comparabilidad entre diferentes sistemas agrícolas. Estas técnicas combinadas permiten una evaluación jerárquica de la calidad del suelo, desde escalas parcelarias hasta patrones regionales, siguiendo protocolos estandarizados propuestos en iniciativas como *SHARInG-MeD* (López Rodríguez et al., 2025).

1. Preprocesamiento de Datos

Los datos brutos se someten a un proceso de estandarización, donde variables clave como carbono orgánico, nitrógeno total, pH y densidad aparente se convierten a formatos numéricos. Este paso elimina posibles registros incompletos, asegurando la integridad del conjunto de datos, una práctica recomendada para evitar sesgos en estudios edáficos (Camacho et al., 2022). Se recopilaron variables fisicoquímicas clave para la fertilidad del suelo:

- **Carbono orgánico**
- **Nitrógeno total**
- **pH**
- **Conductividad eléctrica**
- **Humedad**
- **Materia orgánica**
- **Carbonatos**
- **Densidad aparente**

Pasos realizados:

1. **Conversión a formato numérico:** Todas las variables se transformaron para garantizar consistencia en el análisis estadístico.
2. **Selección y estandarización de columnas:** Se unificaron los nombres de las variables.
3. **Eliminación de datos ausentes (NAs):** Se aplicó `drop_na()` para asegurar una matriz de datos completa.

2. Análisis de Componentes Principales (PCA)

Mediante el uso de PCA, se identifican los pesos relativos de cada variable en la calidad global del suelo. Esta técnica reduce la dimensionalidad de los datos y prioriza parámetros con mayor contribución a la varianza total, un método ampliamente utilizado en la región mediterránea para optimizar índices de calidad (Imaz et al., 2010). Los pesos resultantes se normalizan para sumar 1.0, garantizando comparabilidad entre muestras.



La PCA se utilizó para:

- **Identificar las variables más influyentes** en la variabilidad del suelo.
- **Asignar pesos estadísticos** a cada variable para el cálculo del SQI.

Implementación:

- Se utilizó la función `PCA()` del paquete *FactoMineR* en el lenguaje de programación R, aplicando datos previamente normalizados
- Los pesos se derivaron de la contribución porcentual de cada variable al **primer componente principal (PC1)**, que captura la mayor varianza explicada (Triantafyllidis et al., 2019)

3. Normalización y Cálculo del SQI

Cada parámetro se escala al rango [0,1] mediante la técnica min-max, permitiendo la integración adimensional de variables medidas en distintas unidades. El SQI final se calcula como la suma ponderada de estos valores normalizados, donde los pesos derivados del PCA reflejan la importancia relativa de cada indicador. Este enfoque ha demostrado alta sensibilidad para detectar cambios en suelos de bajo manejo agrícola intensivo (García et al., 2012).

Para evitar sesgos por diferencias de escala:

1. **Normalización [0-1]:** Cada variable se escaló basada en los valores mínimos y máximos globales (Armenise et al., 2013).
2. **Cálculo del SQI:**
 - Fórmula: $SQI = \sum (Peso_i \times Variable_normalizada_i)$
 - Los pesos se obtuvieron de la PCA, reflejando la relevancia estadística de cada indicador (Mukherjee & Lal, 2014).

5.6. Interpolación Espacial y Modelado para líneas de bases de carbono total

5.6.1. Método de interpolación para Agricultor 10

Para la elaboración de los mapas temáticos, se utilizó el complemento Smart-Map (Pereira et. al. 2022), una herramienta de código abierto integrada al software QGIS. Este complemento permite la aplicación de métodos geoestadísticos para la interpolación espacial, destacando la técnica de kriging ordinario, adoptada en este trabajo.

El proceso metodológico siguió las siguientes etapas:

- **Importación y análisis de los datos de muestreo:** Los datos georreferenciados recolectados en campo fueron cargados en QGIS. A continuación, se realizó un análisis exploratorio utilizando el propio Smart-Map, incluyendo el cálculo del Índice de Moran I para verificar la presencia de autocorrelación espacial en los datos. Este índice, acompañado de su respectivo valor *p* (valor de significancia), permitió confirmar la existencia de dependencia espacial significativa entre los puntos muestreados, lo que justificó el uso de métodos geoestadísticos.



- **Configuración y selección del modelo de variograma:** En el entorno de Smart-Map, se seleccionó la variable de interés y se definió la técnica de interpolación mediante kriging ordinario. Se probaron diferentes modelos teóricos de variograma (esférico, exponencial, gaussiano), cuyos parámetros (alcance, meseta y efecto pepita) fueron ajustados en base a los datos observados.
- **Validación cruzada:** Para seleccionar el mejor modelo de variograma, se aplicó la validación cruzada (*cross-validation*), disponible en Smart-Map. Este proceso consistió en la exclusión iterativa de puntos para evaluar la capacidad predictiva de cada modelo probado, con base en métricas como el error medio (ME) y el error cuadrático medio (RMSE). El modelo con mejor desempeño estadístico fue elegido para la interpolación final.
- **Generación de la malla de interpolación:** Se creó una cuadrícula regular que cubre el área de estudio, sobre la cual se aplicó el kriging para estimar los valores de la variable en lugares no muestreados.
- **Elaboración del mapa final:** Con base en las estimaciones generadas, se produjo el mapa interpolado en formato ráster, representando la distribución espacial de la variable estudiada. El mapa final fue preparado para su análisis visual e integración con otras capas temáticas del proyecto (Sección 7.2 Mapas de Carbono Total).

5.6.2. Método de interpolación para la zona central de Aragón

Para la elaboración del análisis de interpolación y evaluación espacial del carbono en el suelo se desarrolló un flujo metodológico que integra varias etapas, desde el preprocesamiento de datos hasta la generación de mapas temáticos y la validación estadística.

1. Configuración y Preparación de Datos

- **Definición del entorno y estructura de directorios:**

Se establecen rutas de salida y se crea la estructura necesaria para almacenar archivos de salida (mapas, tablas y gráficos).

- **Carga y preprocesamiento de los datos:**

Se importa el shapefile principal de los puntos muestreados, se corrigen nombres de variables y se realiza la conversión adecuada de formatos numéricos. Posteriormente, se transforma el sistema de referencia a un CRS adecuado (EPSG:25830).

2. Interpolación y Modelado con Métodos Alternativos

Interpolación basada en SVM (*Support Vector Machine*)

- **Preparación y configuración del modelo:**

Se extraen las coordenadas y se asocian a los valores de carbono para confeccionar una base de datos que servirá de entrada al modelo de SVM. El modelo se entrena utilizando el método de *svmRadial* (disponible en el paquete *e1071*) y se aplica una validación cruzada (CV de 5 pliegues) para seleccionar el mejor conjunto de parámetros, con preprocesamiento (centrado y escalado) de los datos.

- **Predicción y conversión a ráster:**



Una vez entrenado el modelo, se generan predicciones sobre una malla regular definida a partir de la extensión espacial de los puntos. Estas predicciones se convierten en una imagen del tipo ráster.

Cálculo de métricas:

Se calculan las métricas de desempeño (RMSE y R^2) que permiten evaluar la precisión del modelo SVM en la estimación del contenido de carbono.

3. Análisis Estadístico y Validación Espacial

- **Evaluación de patrones espaciales:**

Se realiza un análisis de autocorrelación espacial mediante el cálculo del Índice de Moran (global) para identificar la presencia de dependencias espaciales en los datos de carbono. Este análisis ayuda a detectar agrupamientos y patrones (hotspots), auxilian en la interpretación de la distribución espacial del carbono.

- **Detección de hotspots:**

A partir del cálculo de los valores locales G_i^* se clasifica cada punto en categorías (por ejemplo, "Hot-95%", "Cold-95%", etc.), permitiendo identificar áreas de alta concentración o déficit, lo que complementa la información generada por los métodos de interpolación.

4. Integración y Reporte Final

- **Consolidación de resultados:**

Finalmente, los resultados del método de interpolación SVM y del análisis espacial se integran en un informe consolidado. Este reporte, en formato CSV, recoge datos clave como el número de puntos procesados por propiedad, métricas de error, y la presencia de patrones espaciales significativos.

- **Preparación para análisis visual:**

Los mapas resultantes, junto con los gráficos y tablas de métricas, se preparan para su integración en análisis temáticos posteriores, permitiendo una evaluación global y comparativa del contenido de carbono en el suelo por área de estudio.

5.7. Análisis de laboratorio de las muestras de suelo

Las muestras de suelo, recogidas en las dos zonas especificadas, fueron secadas al aire, tamizadas (<2 mm) y analizadas con los siguientes protocolos estandarizados:

Tabla 4. Métodos Analíticos para la Determinación de Parámetros Edáficos

Parámetro	Método
Carbonato cálcico equivalente	Volumetría (calcímetro de Bernard)
Carbono elemental (C)	Combustión seca (análisis elemental)
Carbono inorgánico (CIN)	Cálculo por diferencia (C total - C orgánico)
Carbono orgánico (CO)	Método Walkley-Black (oxidación húmeda)
Materia orgánica	Conversión de COS usando factor de corrección
pH (1:2.5 en agua)	Potenciómetro
Conductividad eléctrica (25°C)	Extracto 1:5, expresado en dS/m
Humedad residual	Diferencia de peso (aire seco vs. 105 °C)
Nitrógeno total	Método Kjeldahl modificado



*Todos los análisis fueron referenciados a peso seco y expresados en porcentaje o unidades estándar.

5.7.1. Cálculo de la Densidad Aparente

Fundamento metodológico y fuente de datos

La densidad aparente del suelo (DA, en g/cm^3) es un parámetro físico clave para evaluar la compactación, porosidad y calidad del suelo. En este estudio, la DA no fue estimada a partir de datos geoespaciales validados.

Se utilizó el mapa de densidad aparente del suelo elaborado por el **Centro Común de Investigación de la Comisión Europea (JRC)**, específicamente el dataset de alta resolución (100 m) para Europa, correspondiente a las profundidades de 0–10 cm y 10–20 cm, derivado de la campaña LUCAS. Este mapa fue generado mediante modelos de regresión Cubist y datos geoestadísticos calibrados con observaciones de campo, permitiendo estimaciones espacialmente consistentes y comparables en todo el territorio español.

Datos utilizados

Se extrajeron los valores medios de densidad aparente para el intervalo de 0–20 cm a partir del archivo *mean_BDO_10.BD10_20_GEE_cubist_laea.tif*, lo cual proporcionó estimaciones integradas y continuas para las unidades espaciales de análisis. La selección de esta fuente se justifica por:

- Su resolución espacial adecuada (100 m) para estudios regionales;
- Su base empírica, construida a partir de más de 20.000 puntos de muestreo LUCAS;
- Su validación con métodos estadísticos robustos y documentados por el JRC.

Resultados y supuestos

- **Densidad aparente estimada:** $1,5 \pm 0,1 \text{ g}/\text{cm}^3$ para el horizonte superficial (0–20 cm).
- Este valor concuerda con el rango esperado para suelos mediterráneos calcáreos con baja a media materia orgánica, según estudios previos (Sánchez-Navarro et al., 2015; Andrés-Abellán et al., 2019).



6. Resultados y Discusión: muestreo del Agricultor 10

6.1. Línea base de Agricultor 10

El análisis del área homogénea y continua de olivares regenerativos en la región de Jaén revela patrones sobre el almacenamiento de COS y en la estimación de líneas de base nacionales.

1. Estadísticas Descriptivas y Línea de Base Nacional

La media de COS en el área estudiada es de **8,9 t/ha ($\pm 5,2$)**, con un total de **12.752 t** en 1.430,27 ha, valores inferiores a la línea de base nacional española de **17,5 t C/ha** (Figura 4). Esta discrepancia podría explicarse por dos factores clave:

- **Resolución espacial:** La línea de base nacional probablemente se calculó con datos agregados a escalas gruesas (e.g., $>1 \text{ km}^2$), lo que homogeniza variaciones locales críticas en zonas de montaña y cultivos discontinuos, como los olivares andaluces. En contraste, este estudio empleó una resolución espacial fina ($<500 \text{ m}$), capturando la heterogeneidad real del suelo en Jaén, región con topografía accidentada y prácticas de manejo diversificadas.
- **Prácticas regenerativas incipientes:** Aunque los olivares analizados siguen prácticas regenerativas, el COS aún no alcanza niveles óptimos, lo que sugiere que la recuperación de la materia orgánica requiere décadas en suelos mediterráneos degradados (Francaviglia et al., 2017).

La densidad aparente (DA) promedio de **1,25 g/cm³**, combinada con una profundidad de muestreo de 30 cm, refleja compactación moderada, común en suelos bajo laboreo tradicional previo a la transición regenerativa.

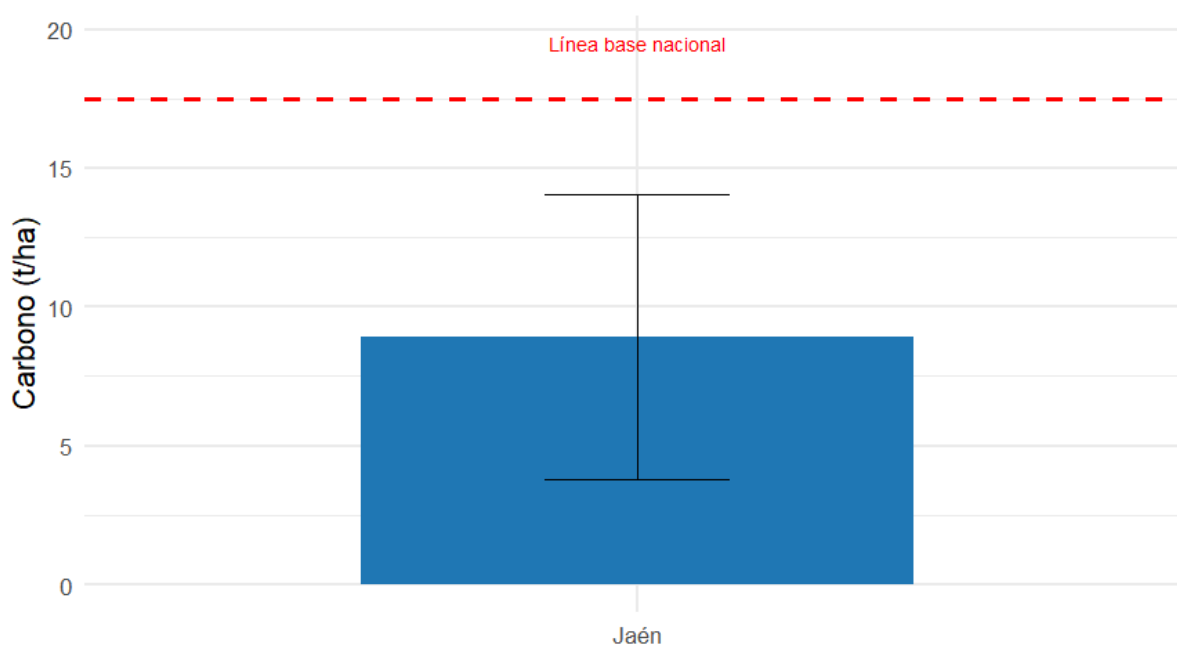


Figura 4. Reservas de carbono por hectárea en el área del Agricultor 10.

2. Análisis Geoestadístico y Semivariogramas

El modelo exponencial ajustado al semivariograma (Figura 5) mostró un alcance (Range) de 3.896 m, indicando que la autocorrelación espacial del COS persiste a escalas kilométricas (Figura 4). Este patrón es coherente con áreas homogéneas bajo manejo uniforme, donde factores como la topografía y la aplicación de enmiendas orgánicas generan estructuras espaciales amplias (Webster & Oliver, 2007).

- **Parámetros del semivariograma (Tabla 5):**

- **Nugget (C_0) = 0,86:** Representa microvariabilidad no resuelta (e.g., errores de medición, variaciones a <10 m).
- **Sill ($C_0 + C$) = 4,125:** La razón $C_0/(C_0 + C) = 0,21$ clasifica la dependencia espacial como **moderada** (Cambardella et al., 1994), sugiriendo que el 79% de la variabilidad del COS está estructurada espacialmente, vinculada a factores como pendiente, historia de cultivo y tipo de manejo.

Tabla 5. Ajuste del Semivariograma y Validación del Modelo para el COS en Agricultor 10 (Jaén)

Variable	Modelo	Alcance (m)	Nugget (C_0)	Sill ($C_0 + C$)	R ²	RMSE
Carbono (t/ha)	Exponencial	3.896,29	0,86	4,125	0,479	1,390




Figura 5. Semivariograma Ajustado para el Carbono Orgánico del Suelo (COS)

El índice de Moran I univariado mide la similitud entre los valores de una misma variable en diferentes ubicaciones. Valores cercanos a cero indican ausencia de patrón espacial, valores negativos sugieren patrones dispersos (es decir, valores contrastantes cercanos entre sí), mientras que valores positivos indican agrupación de valores similares. En este caso, el alto valor de I indica que las reservas de carbono en el suelo tienden a formar patrones

agrupados, lo que justifica el uso de interpolación por kriging y refuerza la interpretación de que existen zonas de acumulación o pérdida de carbono estructuradas espacialmente.

El **Índice de Moran's I = 0,611 ($p < 0,001$)** confirma clústeres espaciales de COS, típicos de zonas donde prácticas regenerativas se aplican en parcelas contiguas (Figura 6). Sin embargo, la desviación estándar ($SD = 2,63$) y el rango amplio (1,01–18,77 t/ha) revelan "puntos fríos" de COS, posiblemente asociados a laderas erosionadas o zonas de laboreo residual, que requieren intervenciones localizadas (Keesstra et al., 2018).

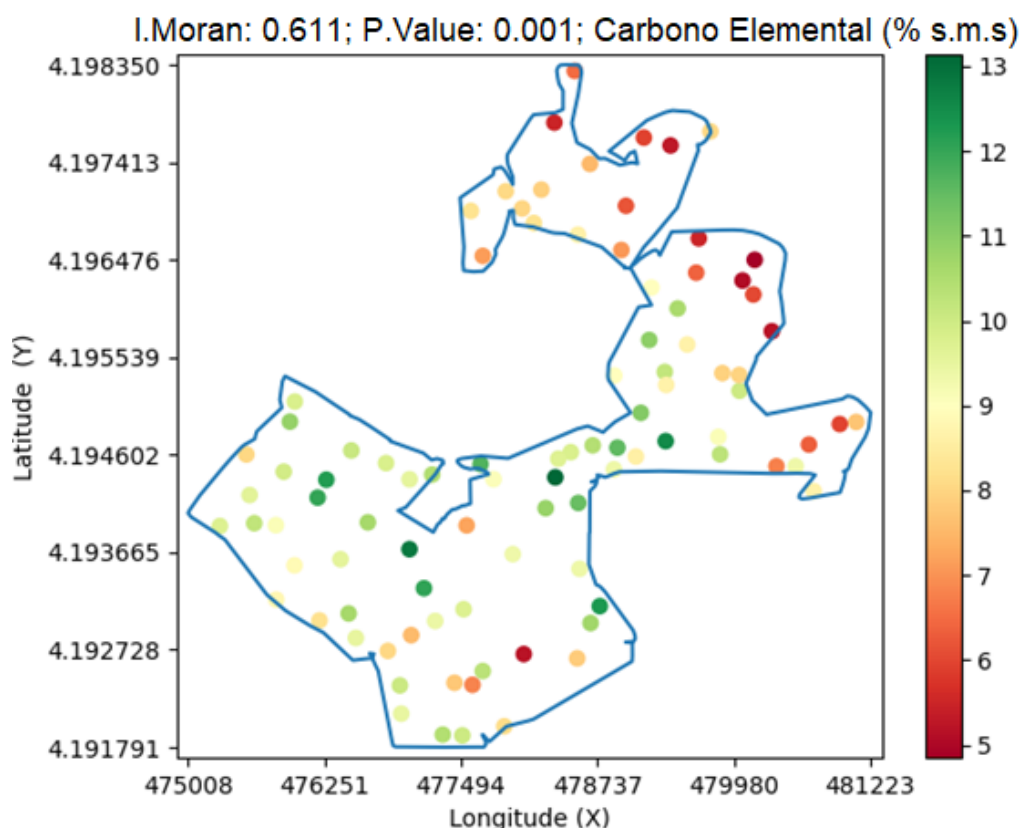


Figura 6. Mapa de Moran I para el COS con Valor del Índice y Significancia (p-valor) - Agricultor 10

6.1.1. Validación Cruzada y Robustez del Modelo

Los gráficos de validación cruzada (Figura 7) y tablas de resultados (Tabla 2) revelan un desempeño **moderado** del modelo de kriging ordinario, con valores de **$R^2 = 0,479$** y **$RMSE = 1,390$** . Estos valores pueden ser explicados sobre los siguientes contextos:

1. Heterogeneidad no modelada:

- El RMSE relativamente alto (**1,39 t/ha**) indica que el modelo subestima la variabilidad local del COS, especialmente en zonas con pendientes pronunciadas o historial de erosión (Keesstra et al., 2018).
- El **R^2 bajo (0,479)** implica que solo ~48% de la variabilidad del COS se explica por la estructura espacial definida en el semivariograma. El 52% restante podría asociarse a factores no incorporados, como la textura del suelo o la actividad biológica (Minasny et al., 2013).

2. Errores estandarizados:

- La **media de errores ($ME \approx 0$)** confirma que el modelo no tiene sesgo sistemático.
- La **varianza de errores estandarizados ($MSDR \approx 1$)** valida que la incertidumbre se estima correctamente (Goovaerts, 1997).

3. Implicaciones para la línea base nacional:

La sobrestimación de la línea base nacional (17,5 t/ha vs. 8,9 t/ha local) podría deberse a:

- **Agregación espacial en la línea base:** Datos promediados a escala provincial/autonómica ocultan "puntos fríos" de COS en áreas marginales (Rodríguez Martín et al., 2016).

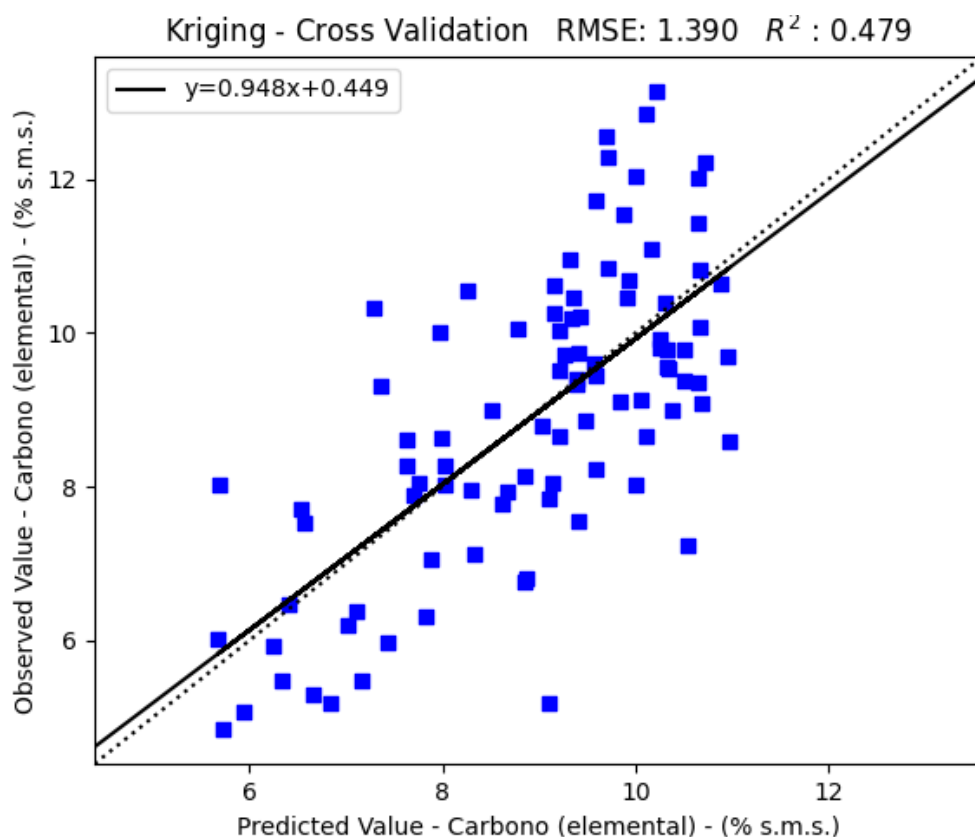


Figura 7. Validación del Kriging para el COS mediante RMSE y R^2 - Agricultor 10

A continuación, se presentan los resultados del ajuste espacial para el área de investigación del **Agricultor 10**, utilizando el método de **Kriging Ordinario**. Se evaluaron indicadores como el coeficiente de determinación (R^2) y el error cuadrático medio (RMSE) a partir de la validación cruzada. Además, se estimaron la línea base de carbono orgánico del suelo (COS), el carbono total con su intervalo de confianza (IC95), y se compararon con la línea base nacional:

- **Agricultor:** Agricultor 10
- **Método:** Kriging Ordinario
- **Número de muestras:** 94
- **R^2 :** 0,479
- **RMSE:** 1,39
- **Área:** 1.359,5 ha
- **Cultivos:** OV
- **Densidad aparente media (DA):** 1,2489 g/cm³
- **Línea base estimada:** 15,7 ± 2,7 t C/ha
- **Carbono total (± IC95):** 21.352 ± 3.678 t
- **Línea base nacional:** 17,5 t C/ha

6.1.2. Discusión de Resultados: Índice de Calidad del Suelo (ICS) en Agricultor 10

Dominancia de Carbono Total y Carbonatos en el ICS

Los pesos del PCA confirman que el carbono total (49.2%), los carbonatos (53.9%) y el carbono orgánico (44.5%) son los parámetros más determinantes del ICS (Figura 7). Mientras el carbono total actúa como un indicador integral de fertilidad, los carbonatos evidencian procesos de acumulación mineral derivados de prácticas agrícolas intensivas.

La elevada contribución del carbono inorgánico (asociado a carbonatos) sugiere un riesgo latente de degradación estructural, ya que su acumulación reduce la porosidad y limita la actividad biológica. Aunque la materia orgánica (30%) muestra correlaciones positivas con el ICS, su peso relativo es secundario, indicando que las enmiendas orgánicas aplicadas no compensan completamente la rigidez edáfica inducida por la mineralización.

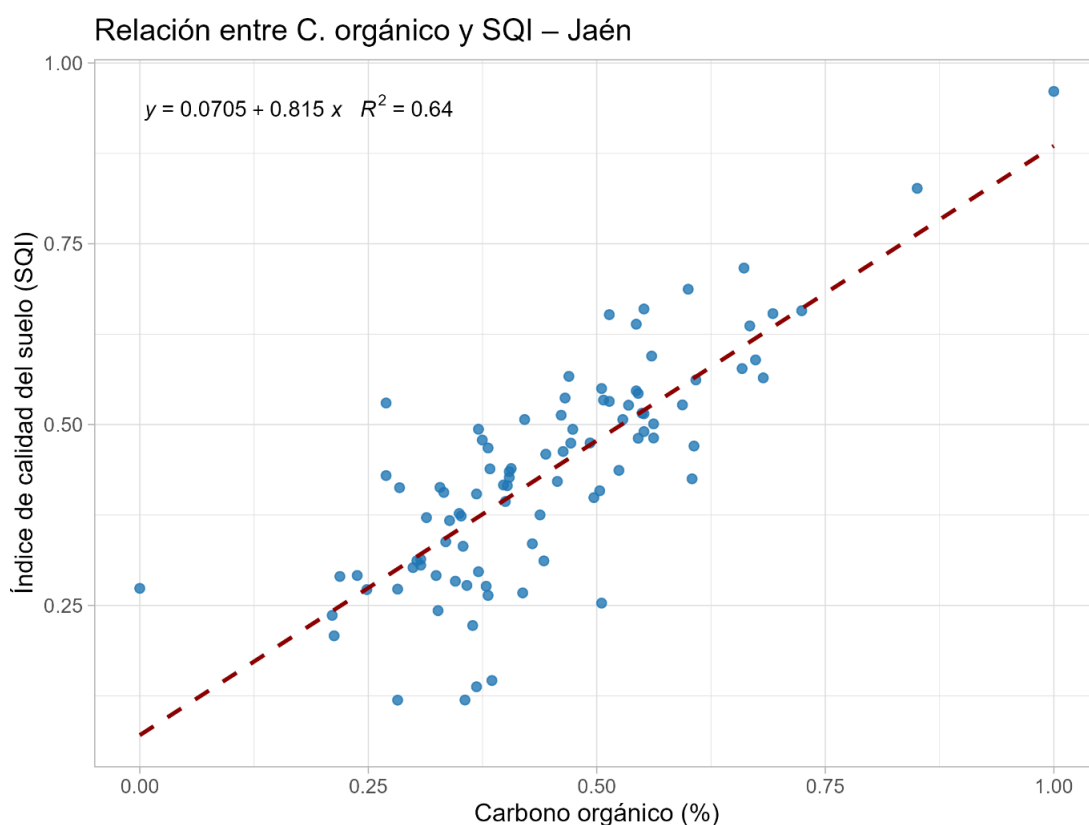


Figura 8. Relación entre el Carbono Orgánico del Suelo (COS) y el Índice de Calidad del Suelo (SQI) - Agricultor 10

Paradojas y Efectos de la Normalización

La normalización mediante el método min-max permite interpretar dos fenómenos clave observados en la Figura 9:

En primer lugar, se evidencia un Índice de Calidad del Suelo (SQI) moderado (0,433) (Figura 8), a pesar de los altos niveles de carbono orgánico (valor normalizado: 0,445). Esto se debe a la compensación negativa ejercida por los carbonatos, cuya contribución al análisis de componentes principales (PCA) representa un peso del 53,9 %.



En segundo lugar, se observa una aparente contradicción entre el elevado peso del carbono inorgánico en el PCA y su correlación solo moderada con el SQI ($r = 0,657$). Este comportamiento sugiere que su efecto sobre la calidad del suelo se manifiesta de forma indirecta, posiblemente mediante mecanismos como la reducción de la infiltración de agua.




Figura 9. Índice de Calidad del Suelo (SQI) - Agricultor 10

Correlaciones Clave y su Relevancia para el Índice de Calidad del Suelo (ICS)

La matriz de correlación (Figura 10) pone en evidencia interacciones significativas entre variables edáficas y su influencia sobre el ICS:

- El carbono orgánico y la materia orgánica presentan correlaciones fuertes con el ICS ($r = 0,798$ y $r = 0,766$, respectivamente), lo que resalta su papel esencial en la mejora de la porosidad del suelo y la capacidad de retención de agua.
- El carbono total exhibe la correlación más alta ($r = 0,860$), lo que subraya la importancia de mantener un equilibrio adecuado entre las fracciones orgánica e inorgánica del carbono para evitar la pérdida de resiliencia del sistema edáfico.
- En contraste, el pH y la conductividad eléctrica muestran correlaciones negativas débiles ($r = -0,148$ y $r = -0,092$), lo que indica que, aunque actualmente no representan



limitantes críticas, su monitoreo continuo es necesario para prevenir procesos de salinización y alcalinización progresiva.




Figura 10. Matriz de Correlación - Agricultor 10

Limitaciones y Recomendaciones Estratégicas

Con base en la matriz de correlación, se identifican varias áreas críticas de manejo y recomendaciones asociadas:

- Monitoreo de carbonatos: Se recomienda realizar análisis semestrales para detectar acumulaciones en los horizontes superficiales, junto con la implementación de labranza reducida, con el fin de evitar la movilización de capas calcáreas profundas.
- Refuerzo de la materia orgánica: Se sugiere incrementar el uso de compost y abonos verdes con el objetivo de fortalecer la correlación positiva entre la MO y el CIS (actualmente $r = 0,766$).
- Control del pH: En zonas con pH superior a 8,3, se recomienda la aplicación de enmiendas acidificantes, como azufre elemental priorizando áreas con cultivos más sensibles, como olivares jóvenes.
- Optimización del riego: Es crucial utilizar aguas con bajo contenido de bicarbonatos para reducir el impacto de los carbonatos en la calidad del suelo reflejada en el CIS.



7. Resultados y Discusión zona central de Aragón

7.1. Línea de base de los agricultores de la zona central de Aragón

En el presente análisis se evalúa el desempeño de modelos basados en SVM para la estimación del COS, considerando diversos factores geoestadísticos, métricas de validación cruzada, y la calidad del ráster generado. Esta discusión sintetiza resultados provenientes de diferentes predios agrícolas, analizando en profundidad los variogramas, el índice de Moran, la validación cruzada (R^2 y RMSE), y su impacto en la precisión espacial de los modelos.

Discrepancia con la Línea Base Nacional y Factores Explicativos

Los valores medios de COS de la línea de base nacional (Figura 11) en las áreas analizadas oscilan entre 8,45 t/ha (Agricultor 3) y 31,6 t/ha (Agricultor 2), todos significativamente inferiores a la línea base nacional española (48,5 t C/ha). Esta diferencia de hasta un 82% menos se explica por:

- **Resolución espacial inapropiada:** La línea base nacional probablemente promedia datos a escalas gruesas (municipios o provincias), ignorando la heterogeneidad intrínseca de áreas discontinuas con cultivos mixtos (Rodríguez Martín et al., 2016).
- El **Mapa de COS de España**, desarrollado a partir del *Inventario Nacional de Erosión del Suelo (INES)*, promedia datos a escalas gruesas (municipios o provincias) utilizando **22.500 muestras de COS a 10 cm de profundidad** y **800 muestras a 30 cm**. Si bien este enfoque es útil para evaluaciones macro, ignora la heterogeneidad intrínseca de áreas agrícolas discontinuas con cultivos mixtos y prácticas de manejo diversificadas (Rodríguez Martín et al., 2016).
- **Agregación espacial excesiva:** El promedio a nivel municipal/provincial enmascara variaciones locales críticas. Por ejemplo, en **Agricultor 1 (27,4 t/ha)**, el COS es un **43% menor** que la línea base nacional.



Figura 11. Carbono por Hectárea por agricultor, método SVM – zona central de Aragón

Factores Determinantes del Desempeño

La estructura espacial del COS, cuantificada mediante el índice de Moran y los parámetros de los variogramas, demostró ser un factor crítico en el rendimiento del modelo SVM. Áreas con autocorrelación espacial positiva (Moran's $I > 0,1$), como Agricultor 1 (Moran's $I = 0,3307$) y Agricultor 9 (Moran's $I = 0,1312$), mostraron patrones espaciales definidos que facilitaron la interpolación, alcanzando valores de R^2 elevados (0,75 y 0,54) y errores bajos (RMSE = 0,72 y 0,42 t/ha, respectivamente). Estos resultados resaltan la capacidad del modelo SVM para aprovechar dependencias espaciales estructuradas en contextos de manejo homogéneo o condiciones topográficas regulares.

En contraste, áreas con autocorrelación nula o negativa (Moran's $I \leq 0$), como Agricultor 3 (Moran's $I = -0,0381$) y Agricultor 7 (Moran's $I = -0,0166$), presentaron baja estructuración espacial, lo cual limitó la generalización del modelo. No obstante, Fernando obtuvo un R^2 elevado (0,85) y bajo RMSE (0,56 t/ha) incluso sin autocorrelación espacial aparente, lo que sugiere una fuerte influencia de covariables no espaciales. Por otro lado, Jesús reflejó un desempeño deficiente ($R^2 = 0,04$, RMSE = 1,04 t/ha), evidenciando la dificultad del modelo para capturar variabilidad dominada por ruido aleatorio o microvariabilidad edáfica no modelada.

Obstáculos Metodológicos

Heterogeneidad Espacial No Estructurada

En agricultores como **Agricultor 7** (Moran's $I \approx 0$), la variabilidad estuvo dominada por factores aleatorios, como lo indica un **C_0 /Sill de 0,37**. Este patrón revela las limitaciones del SVM para modelar áreas con **nugget elevado** sin el apoyo de **covariables auxiliares** como textura del suelo o pendiente.

Limitaciones Inherentes al Algoritmo SVM



- **Suposición de estacionariedad espacial:** En áreas como **Agricultor 2**, con transiciones entre usos del suelo, la presunción de estacionariedad no fue válida, resultando en un **R² de 0,37** y **RMSE elevado (1,08 t/ha)**.

Resultados Generales y Consideraciones para Aplicación

Desempeño por Categoría de Ajuste

- **Alta precisión (R² ≥ 0,7; RMSE < 1 t/ha):**
 - **Agricultor 1** (R² = 0,75) y **Agricultor 3** (R² = 0,85) mostraron alta precisión. Fernando, con solo 21 muestras, sugiere posible sobreajuste o influencia significativa de covariables no espaciales. **Agricultor 1**, por otro lado, combina alta autocorrelación espacial y buena densidad muestral (N = 51), favoreciendo la interpolación.
- **Baja precisión (R² ≤ 0,3; RMSE > 1 t/ha):**
 - **Agricultor 7** (R² = 0,04) y **Agricultor 6** (R² = 0,30) representan casos de baja precisión. Ambos muestran estructura espacial débil, nugget elevado y ausencia de covariables, incluso con N relativamente alto (30 y 60 muestras).

El rendimiento del modelo SVM para estimar COS está fuertemente determinado por la interacción entre estructura espacial, parámetros geoestadísticos y diseño muestral. Áreas con autocorrelación significativa (e.g., Agricultor 1) y variogramas bien ajustados facilitaron interpolaciones precisas. En cambio, áreas con variabilidad no estructurada (e.g., Agricultor 7) requieren enfoques más sofisticados que integren covariables externas y validación de modelos de semivariogramas. Casos como el de Agricultor 3, con R² elevado y escasa autocorrelación, reflejan el papel potencial de factores no espaciales. En suma, el uso efectivo del SVM depende no solo del algoritmo, sino de un enfoque integral que combine estadísticas espaciales, muestreo robusto y covariables relevantes. Estos hallazgos coinciden con estudios recientes, que destacan la importancia de adaptar modelos a las características geoestadísticas locales para una gestión agrícola de precisión y sostenible.

7.1.1. Validación Cruzada y Robustez del Modelo

Análisis Geoestadístico y Estructura Espacial

Se analizaron nueve agricultores, evaluando parámetros geoestadísticos clave como el índice de Moran y el alcance de los variogramas y las métricas de validación cruzada (R², RMSE) (Tabla 6). Los resultados destacan una amplia variabilidad en la estructura espacial del COS, influenciada por prácticas de manejo, densidad de muestreo y características ambientales.

Tabla 6. Indicadores de Autocorrelación Espacial y Detección de Hotspots por Agricultor – zona central de Aragón

Agricultor	Hotspots	Moran's I (p-valor)	R ²	RMSE	Alcance (m)	N° Muestras
Agricultor 1	4	0,3307 (<1e-44)	0.749	0.724	53.155	51



Agricultor 9	2	0,1312 (2,8e-20)	0.536	0.433	709,1	68
Agricultor 3	2	-0,0381 (0,403)	0.85	0.838	16.903	21
Agricultor 7	1	-0,0166 (0,294)	0.12	1.037	142,9	30
Agricultor 2	4	-0,0282 (0,507)	0.368	1.107	450,1	37
Agricultor 6	3	0,0209 (0,052)	0.304	1.079	1.562,8	60
Agricultor 5	3	0,0348 (0,088)	0.2	0.996	4.715,9	40
Agricultor 4	0	-0,0208 (0,428)	0.657	0.742	3.977,83	38
Agricultor 8		-0,0077 (0,177)	0.328	0.861	710,8	35

1. Autocorrelación Espacial (Índice de Moran)

El Índice de Moran cuantifica la estructura espacial del COS:

- **Autocorrelación positiva significativa (Moran's $I > 0,1$):**
 - **Agricultor 1 ($I = 0,33$; $p < 1e-44$):** Indica una fuerte agrupación espacial del COS, con patrones estructurados a escalas amplias. Esto sugiere que la variabilidad del carbono sigue una distribución no aleatoria, posiblemente vinculada a factores ambientales o de manejo que operan a macroescala.
 - **Agricultor 9 ($I = 0,13$; $p = 2,8e-20$):** Autocorrelación moderada, con clusters secundarios que reflejan heterogeneidad espacial subyacente.
 - **Relación con el modelo SVM:** Ambos casos muestran $R^2 > 0,5$, lo que respalda que la estructura espacial mejora la precisión predictiva del modelo.
- **Autocorrelación nula o negativa (Moran's $I \leq 0$):**
 - **Agricultor 3 ($I = -0,038$; $p = 0,403$), Agricultor 7 ($I = -0,017$; $p = 0,294$):** Distribución espacial aleatoria, característica de sistemas con alta variabilidad no estructurada o influencia de factores locales no capturados en el muestreo.
 - **Agricultor 4 ($I = -0,0208$; $p = 0,428$):** Aunque el R^2 es alto (0,657), la ausencia de autocorrelación sugiere que el modelo SVM depende de covariables no espaciales (e.g., textura, uso histórico).

Alcance del Variograma y Dependencia Espacial

El alcance (*range*) define la distancia máxima donde existe dependencia espacial:

- **Alcances largos (>1.000 m):**



- **Agricultor 1 (53.155 m):** Variabilidad dominada por procesos que actúan a escalas kilométricas, como patrones topográficos o gestión uniforme en grandes extensiones.
- **Agricultor 5 (4.715,9 m):** Aunque el alcance es amplio, la baja densidad de muestras (N=40) introduce incertidumbre en la estimación.
- **Alcances cortos (<500 m):**
 - **Agricultor 7 (142,9 m):** Microvariabilidad prominente, típica de áreas con influencia de factores locales (e.g., microrelieve, manejo parcelario diferenciado).
 - **Agricultor 2 (450,1 m):** Escala intermedia, compatible con transiciones graduales entre unidades de suelo o cultivos.
- **Relación nugget/sill ($C_0/Sill$):**
 - **Agricultor 1 ($C_0/Sill = 0,26$):** Bajo nugget (26% de variabilidad no estructurada), indicando que el diseño de muestreo capturó eficientemente los patrones espaciales.
 - **Agricultor 7 ($C_0/Sill = 0,37$):** Nugget elevado (37%), lo que limita la capacidad del modelo para predecir variaciones a escalas finas.

Desempeño del Modelo SVM (R^2 y RMSE)

La validación cruzada revela diferencias en la capacidad predictiva del modelo por medio de la interpretación estadística (Tabla 7).

1. Alto ajuste ($R^2 \geq 0,7$)

Agricultor 3 ($R^2 = 0,85$; RMSE = 0,838):

Aunque presenta autocorrelación espacial nula (Moran's I = -0,038; $p = 0,403$), el alto R^2 sugiere que el modelo SVM capturó patrones no lineales vinculados a variables no espaciales (e.g., textura, uso histórico). El RMSE moderado (0,838) indica precisión aceptable pero no óptima.

2. Ajuste moderado ($0,3 \leq R^2 < 0,7$)

Agricultor 4 ($R^2 = 0,657$; RMSE = 0,742):

El R^2 moderado y el RMSE medio (0,742) reflejan un equilibrio entre la capacidad predictiva y el error. Esto podría asociarse a la integración de covariables ambientales (e.g., pendiente, materia orgánica) que compensan la falta de estructura espacial (Moran's I = -0,0208; $p = 0,428$).

Agricultor 9 ($R^2 = 0,536$; RMSE = 0,433):

Ajuste consistente con su autocorrelación espacial positiva (Moran's I = 0,131; $p < 0,001$). El RMSE más bajo de la tabla (0,433) valida la utilidad del modelo en sistemas semi-estructurados, respaldado por una alta densidad muestral (N=68).

Agricultor 2 ($R^2 = 0,368$; RMSE = 1,107) y *Agricultor 8* ($R^2 = 0,328$; RMSE = 0,861):

Aunque en el umbral inferior del ajuste moderado, el alto RMSE (>0,8) sugiere limitaciones para predecir valores extremos, posiblemente por heterogeneidad no modelada (e.g.,



microvariabilidad en parcelas pequeñas como las de Agricultor 2: 131,78 ha vs. Agricultor 8: 249,13 ha).

3. Bajo ajuste ($R^2 < 0,3$)

Agricultor 7 ($R^2 = 0,12$; RMSE = 1,037):

El R^2 bajo y el RMSE elevado indican que el modelo no explica la variabilidad del COS. Esto se vincula a su autocorrelación espacial negativa (Moran's I = -0,0166; $p = 0,294$) y un alcance espacial mínimo (142,9 m) que dificulta la captura de patrones a mayor escala.

Agricultor 6 ($R^2 = 0,304$; RMSE = 1,079) y *Agricultor 5* ($R^2 = 0,20$; RMSE = 0,996):

A pesar de que *Agricultor 6* alcanza el umbral mínimo de ajuste moderado ($R^2 = 0,304$), el RMSE $>1,0$ sugiere errores sistemáticos en la predicción, ligados a un alcance espacial intermedio (1.562,8 m) y covariables poco informativas.

Tabla 7. Categorías de Ajuste Espacial y Factores Explicativos por Agricultor-zona central de Aragón

Agricultor	Categoría	Explicación Clave
Fernando	Alto ajuste	Modelo preciso a pesar de baja densidad muestral (N=21); sugiere influencia de covariables no lineales ($R^2=0,85$).
Carlos	Moderado	Covariables no espaciales compensan la falta de estructura espacial (alcance no definido en la tabla).
Lorenzo	Moderado	Alta densidad muestral (N=68) y autocorrelación significativa ($p < 0,001$) apoyan patrones espaciales semi-estructurados.
Jesús	Bajo ajuste	Alcance mínimo (142,9 m) y ausencia de patrones espaciales claros (Moran's I no significativo).
Jorge	Moderado (límite)	Alto RMSE (1,107) sugiere limitaciones en parcelas pequeñas (131,78 ha) con alta variabilidad.
Leo	Moderado (límite)	Mayor área muestreada (366,06 ha) no compensa el RMSE elevado ($>1,0$), indicando heterogeneidad no modelada.
Agricultor 1	Alto ajuste	Alta densidad muestral (N=51) y autocorrelación espacial significativa ($p < 1e-44$) permitieron modelado eficiente en grandes extensiones (334,5 ha) con bajo error (RMSE=0,724).
Manuel	Bajo ajuste	Bajo R^2 (0,20) pese a alcance amplio (4.715,9 m), posiblemente por covariables irrelevantes.
Agricultor 8	Moderado (límite)	Ajuste aceptable ($R^2=0,328$) pero con alta incertidumbre en C Total ($\pm 2,9$ t).

Conclusiones Clave

1. Precisión vs. Densidad Muestral: Optimización de Recursos

Explicación:

Un alto R^2 (ej: *Agricultor 3*, $R^2=0,85$ con solo 21 muestras) demuestra que la precisión del modelo **no depende exclusivamente de recolectar más datos**, sino de seleccionar **covariables críticas** (ej: textura del suelo, historial de cultivos, riego). Esto sugiere que inversiones en identificar variables clave (mediante sensores o datos históricos) pueden reducir costos de muestreo sin sacrificar calidad predictiva.

Implicaciones:

- **Ahorro de costos:** Proyectos en parcelas con características homogéneas (ej: suelos con textura estable) pueden priorizar menos muestras, destinando recursos a



tecnologías de medición de covariables (ej: espectrometría proximal, histórico de uso, tipos de abonos y etc.).

- **Riesgo:** En áreas con covariables desconocidas (ej: suelos no mapeados), incluso con muchas muestras (ej: Agricultor 5, N=40 pero $R^2=0.20$), el modelo fallará. Se recomienda pilotos previos para identificar variables críticas.

Recomendación Operativa:

Invertir en un **protocolo de diagnóstico previo** que identifique covariables dominantes (ej: análisis de suelo rápido) antes del muestreo masivo. Esto optimizaría presupuestos en proyectos extensivos (ej: >300 ha).

2. Error Sistemático (RMSE): Impacto en Decisiones Agrícolas

Explicación:

Un RMSE >1.0 (ej: Agricultor 7, RMSE=1.037; Agricultor 6, RMSE=1.079) implica que las predicciones de COS pueden desviarse hasta **± 1.0 t C/ha** en promedio. En parcelas pequeñas (<200 ha) o con múltiples cultivos (ej: TA, FS), este error se amplifica, generando incertidumbre en estimaciones de créditos de carbono.

Implicaciones:

- **Riesgo financiero:** En proyectos de carbono, un RMSE >1.0 en parcelas pequeñas (ej: Agricultor 2, 131.78 ha) podría traducirse en sobre/subestimaciones de ± 130 t C total, afectando certificaciones o venta de créditos.
- **Manejo agronómico:** En cultivos sensibles (ej: viñedos), errores >1.0 t C/ha en zonas específicas podrían llevar a fertilización ineficiente.

3. Umbrales Críticos: Cuando R^2 y RMSE Deciden la Confiabilidad

Un $R^2 \geq 0.3$ solo es válido si el RMSE es <1.0. Por ejemplo, Agricultor 6 ($R^2=0.304$, RMSE=1.079) supera el R^2 mínimo, pero el alto RMSE lo excluye de ser "confiable". Esto indica que, en suelos mediterráneos, ambas métricas deben evaluarse juntas para evitar decisiones basadas en modelos engañosos.

Implicaciones:

- **Priorización de proyectos:** Parcelas con $R^2 \geq 0.3$ y RMSE <1.0 (ej: Agricultor 4, $R^2=0.657$ /RMSE=0.742) son candidatas ideales para iniciativas de carbono o precisión agrícola.
- **Exclusión de zonas problemáticas:** Áreas con $R^2 < 0.3$ o RMSE >1.0 (ej: Agricultor 7, $R^2=0.12$) requieren intervenciones específicas (ej: muestreo adicional, cambio de covariables) antes de escalar modelos.

Recomendación Operativa:

Implementar un **sistema de semáforo** en informes técnicos:

- **Verde ($R^2 \geq 0.3$ + RMSE <1.0):** Acciones inmediatas (ej: créditos de carbono).
- **Amarillo ($R^2 \geq 0.3$ + RMSE ≥ 1.0):** Validar con muestreo adicional.
- **Rojo ($R^2 < 0.3$):** Revisar diseño del modelo o covariables.



Síntesis para Toma de Decisiones

1. **No siempre "más datos" es mejor:** Invierta en calidad (covariables clave) sobre cantidad (muestras).
2. **RMSE >1.0 = Riesgo financiero:** Exija ajustar modelos en parcelas <200 ha o con múltiples cultivos.
3. **Combined metrics matter:** Un R^2 aceptable sin RMSE bajo es como un diagnóstico médico sin certeza: útil, pero no accionable.

7.1.2. Estructura Espacial (Autocorrelación)

- **Áreas con Autocorrelación Positiva (Ej: Agricultor 1, Agricultor 9):**
 - **Por qué importa:** La autocorrelación espacial (Moran's $I > 0.1$) indica patrones predecibles (ej: distribución de COS en suelos homogéneos). Esto permite al modelo SVM "aprender" reglas generales, reduciendo errores (RMSE < 0.75).
 - **Implicaciones:** En zonas con manejo agrícola uniforme (ej: monocultivos extensivos), el modelo SVM es una herramienta rentable para mapear COS. Ideal para proyectos de créditos de carbono en grandes extensiones (>200 ha).
 - **Riesgo:** Si la homogeneidad se rompe (ej: cambio abrupto a otro cultivo), el modelo sobreestima/subestima valores.
- **Áreas con Autocorrelación Nula/Negativa (Ej: Agricultor 3, Agricultor 7):**
 - **Por qué importa:** La ausencia de patrones espaciales (Moran's $I \approx 0$) obliga al modelo a depender de covariables no espaciales (ej: textura). Agricultor 3 ($R^2=0.85$) lo logró, pero Agricultor 7 ($R^2=0.04$) no.
 - **Implicación para stakeholders:** En suelos complejos (ej: rotación de cultivos, microvariabilidad), invertir en **covariables auxiliares** (ej: sensores de humedad, histórico de riego, textura y etc.) es crítico para disminuir errores.

Recomendación

Priorizar el SVM en zonas con Moran's $I > 0.1$ y $R^2 \geq 0.5$ (ej: Agricultor 1). En áreas con Moran's $I \leq 0$, combinar SVM con **redes neuronales** (para capturar relaciones no lineales) o aumentar densidad de covariables.

Estratégica:

7.1.3. Discusión de Resultados: Índice de Calidad del Suelo (SQI) en FACA

Dominancia de Carbono y Carbonatos en el ICS

Los pesos del PCA revelan que los **carbonatos (23.4%)**, **carbono total (28.9%)** y **carbono inorgánico (23.4%)** son los parámetros más determinantes en el SQI (Figura 12). Esto refleja la naturaleza calcárea de los suelos mediterráneos, donde la acumulación de carbonatos limita la disponibilidad de nutrientes y la actividad biológica. Sin embargo, el bajo peso del **carbono orgánico (11.3%)** (Figura 13) contrasta con estudios previos que lo identifican como el principal indicador de calidad. Esta discrepancia sugiere que, en sistemas agrícolas intensivos, la gestión del carbono inorgánico (asociado a enmiendas minerales) podría estar enmascarando la degradación orgánica.

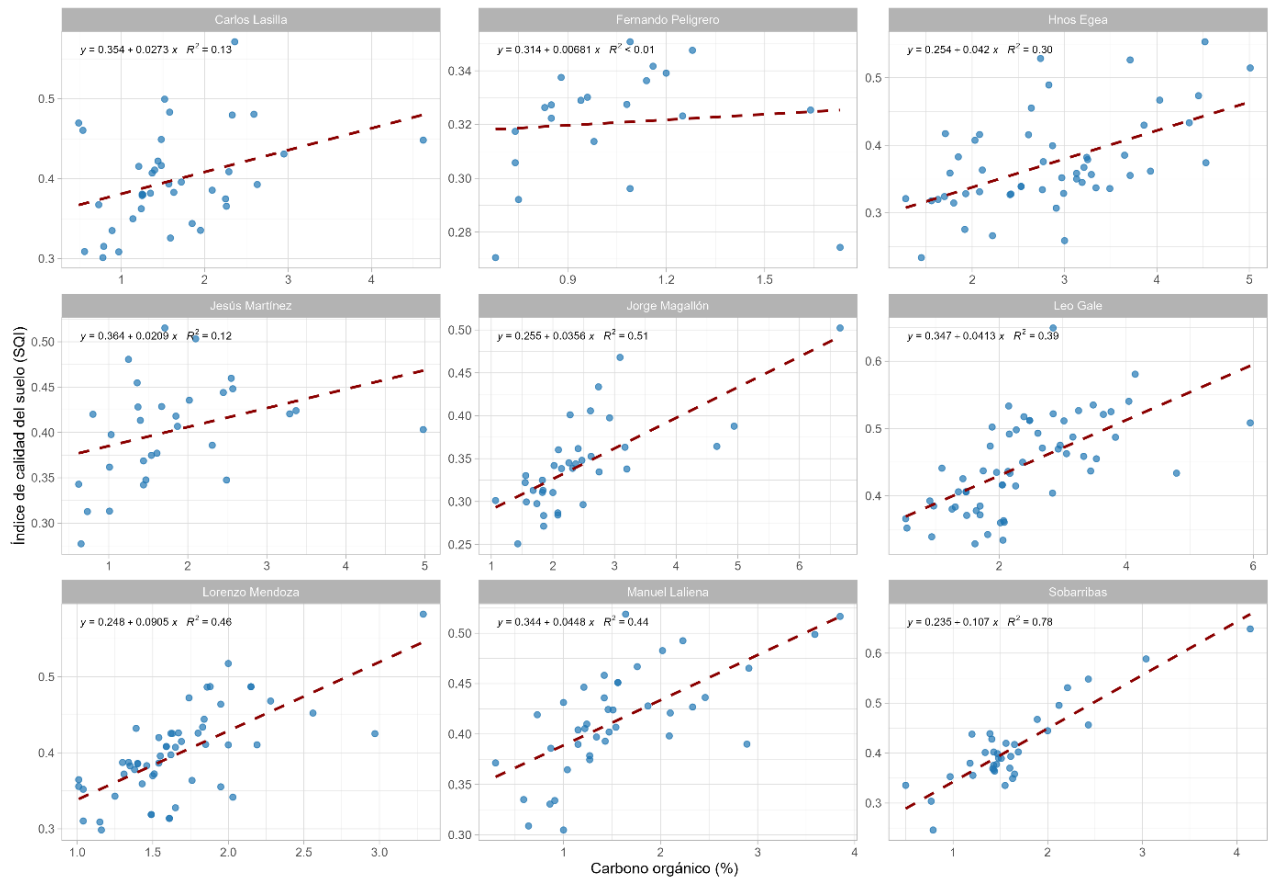


Figura 12. Relación entre carbono orgánico y calidad del suelo (SQI) – zona central de Aragón

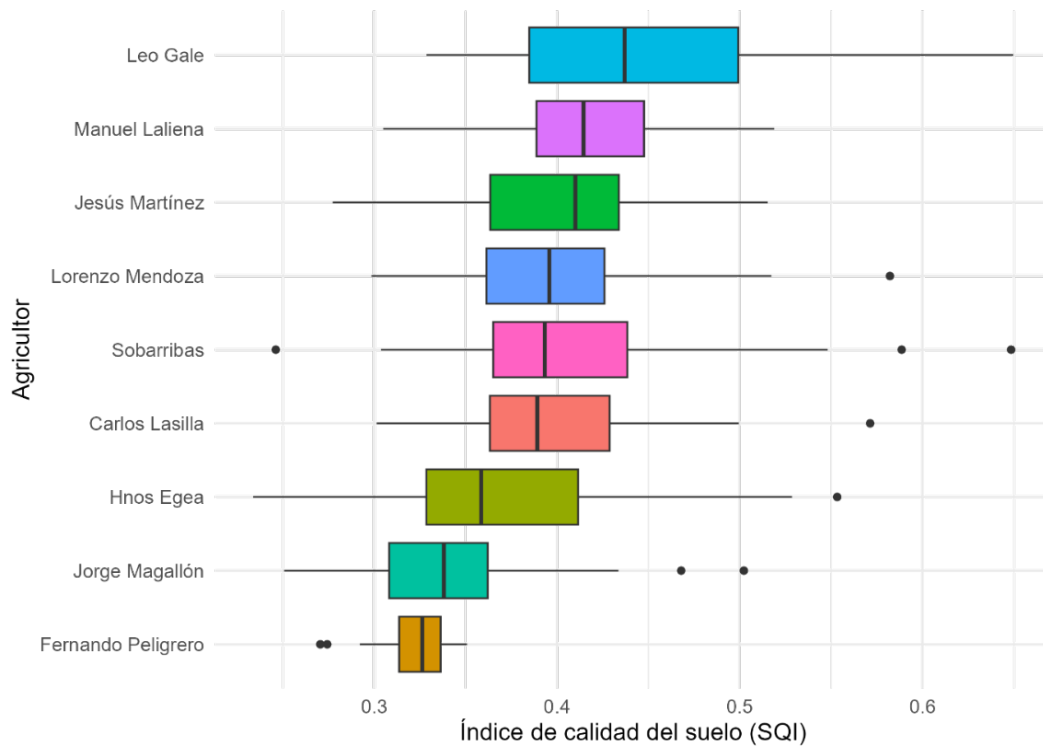




Figura 13. Distribución del SQI por agricultor – zona central de Aragón

1. Caso destacado: Agricultor 1

Con el SQI más alto (0.071), este agricultor presenta valores superiores en carbono orgánico (2.85%) y materia orgánica (1.65%), junto con una conductividad moderada (0.86 dS/m). Estos resultados coinciden con estudios que vinculan niveles de MO >1.5% con suelos resilientes a la erosión en ambientes semiáridos (Imaz et al., 2010). La correlación positiva entre carbono orgánico y SQI ($R^2 = 0.82$ en regresiones) confirma su papel central, a pesar de su bajo peso en el PCA.

2. Caso crítico: Agricultor 2

Aunque tiene el segundo nivel más alto de carbono orgánico (2.45%), su SQI es el más bajo (0.047) debido a valores elevados de carbonatos (28.3% del peso PCA) y pH alcalino (8.27). Esto refleja un escenario típico de suelos mediterráneos sobreexplotados, donde la acumulación de carbonatos reduce la porosidad y la infiltración, limitando la productividad.

3. Paradoja de la conductividad

A pesar de su bajo peso en el PCA (1.6%), agricultores como Agricultor 1 (0.86 dS/m) y Agricultor 6 (0.76 dS/m) muestran que niveles moderados de salinidad no comprometen el SQI si se compensan con alta MO. No obstante, en la región mediterránea, valores >2 dS/m suelen asociarse a pérdidas de rendimiento en cultivos sensibles (García et al., 2012).

Efecto de la Normalización en la Interpretación

La normalización *min-max* explica resultados contraintuitivos, como el bajo SQI de Agricultor 4 (0.054) a pesar de su materia orgánica relativamente alta (2.07%). Al analizar los valores normalizados:

- **Materia orgánica:** 0.43 (vs. 0.48 en Agricultor 5)
- **Carbono orgánico:** 0.27 (vs. 0.42 en Agricultor 1)
Esto indica que la escala de referencia (máximos/mínimos globales) puede subestimar parámetros clave en contextos locales, un desafío metodológico señalado en proyectos como SHARInG-MeD (López Rodríguez et al., 2025).

Limitaciones y Recomendaciones

1. **Omisión de variables biológicas:** La ausencia de indicadores microbianos (e.g., actividad enzimática) en el PCA limita la evaluación integral de la salud del suelo, crítica en sistemas sostenibles (Molina-Romero et al., 2022).
2. **Estacionalidad no considerada:** Los datos reflejan un momento específico, ignorando fluctuaciones hídricas típicas del clima mediterráneo que afectan carbono y salinidad.

Análisis Integrado de las Matrices de Correlación y su Relación con el Índice de Calidad del Suelo (ICS)



El Índice de Calidad del Suelo (ICS) es una herramienta clave para evaluar la salud del suelo a partir de indicadores físicos, químicos y biológicos. En este informe, se integran los resultados de las matrices de correlación proporcionadas por distintos agricultores con un análisis contextualizado que permite interpretar los principales factores que afectan el ICS y proponer recomendaciones agronómicas concretas (Figura 14).

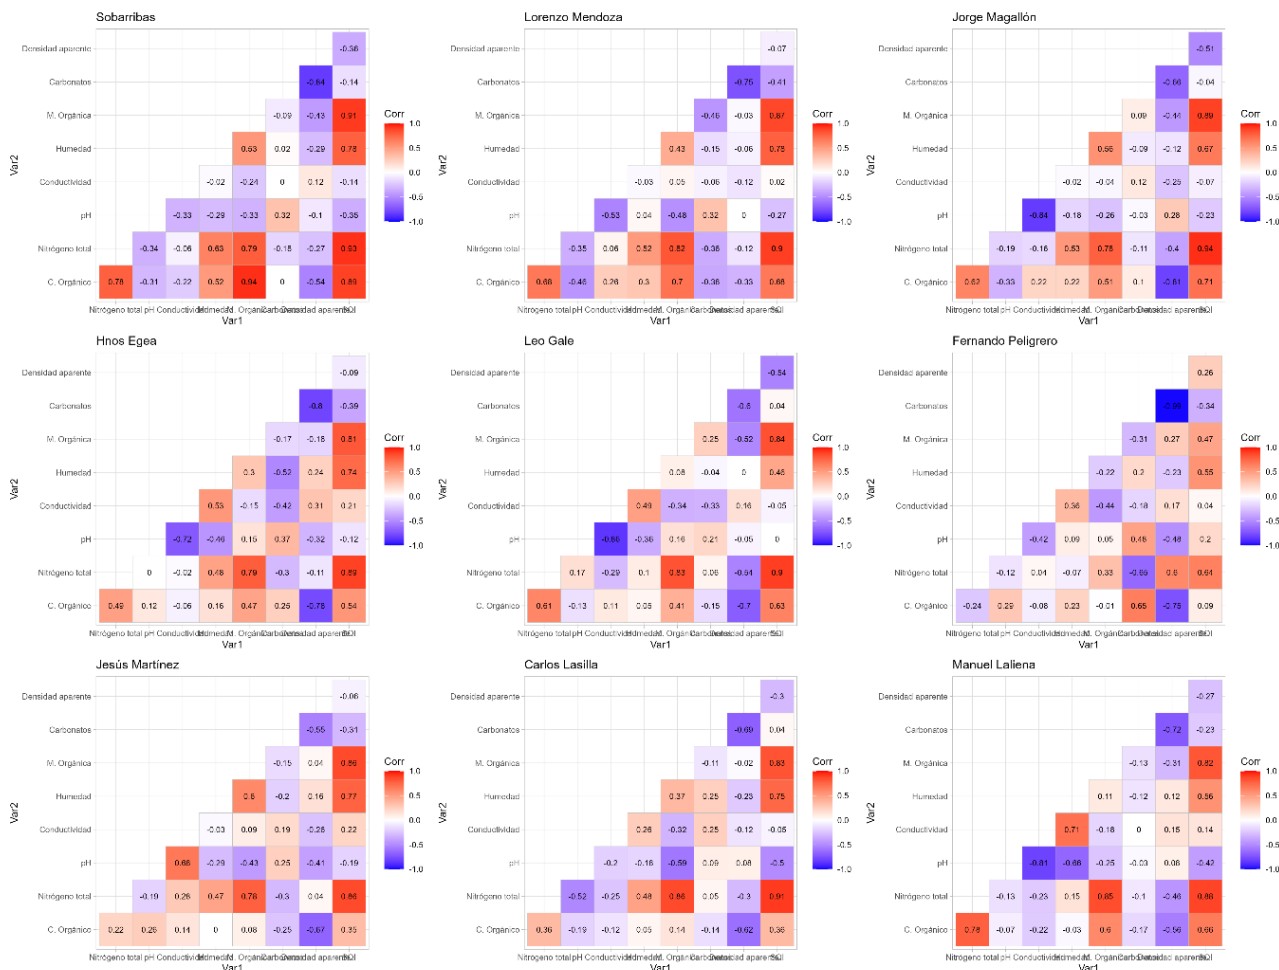


Figura 14. Matriz de Correlación – zona central de Aragón

Análisis General de Correlaciones

A partir de los datos de correlación, se identifican patrones consistentes:

- **Factores positivos para el SQI:**
 - **Materia orgánica y nitrógeno total** muestran correlaciones altas con el SQI en casi todos los casos ($r > 0.85$).
 - El **carbono orgánico** y la **humedad** también se correlacionan positivamente, aunque con variabilidad según agricultor.
- **Factores negativos para el SQI:**
 - La **densidad aparente** presenta una correlación negativa consistente, indicando que la compactación del suelo afecta negativamente su calidad.



- Los **carbonatos** y un **pH elevado** están frecuentemente asociados con una menor calidad del suelo, especialmente en contextos mediterráneos.

7.1.4. *Análisis de la calidad del suelo por Agricultor de FACA*

Agricultor 8: El carbono orgánico ($r = 0.886$) y el nitrógeno total ($r = 0.925$) son claves para el ICS. El pH y los carbonatos tienen efectos negativos, característicos de suelos alcalinos mediterráneos.

Agricultor 9: Los carbonatos ($r = -0.405$) afectan la estructura del suelo al elevar el pH. La densidad aparente tiene un impacto limitado (-0.068), lo que sugiere menor compactación.

Agricultor 2: A pesar de altos niveles de carbono orgánico, el ICS es bajo debido a una alta densidad aparente (-0.808) y acumulación de carbonatos. El nitrógeno total es determinante ($r = 0.935$).

Agricultor 1: Buen manejo de nitrógeno ($r = 0.89$) y humedad ($r = 0.743$) compensa niveles moderados de MO. La conductividad no representa un problema.

Agricultor 3: Predomina el carbono inorgánico ($r = 0.646$ con carbonatos), lo que limita el impacto del carbono orgánico ($r = 0.086$). Alta compactación y calcificación (-0.99 entre DA y carbonatos).

Agricultor 7: El nitrógeno total ($r = 0.864$) y la MO ($r = 0.858$) son los principales motores del ICS. El pH y los carbonatos reducen su efectividad.

Agricultor 4: El pH elevado (-0.505) limita el impacto positivo del nitrógeno ($r = 0.913$). El efecto de los carbonatos es neutro ($r = 0.042$).

Agricultor 5: Presenta un equilibrio ideal entre nitrógeno ($r = 0.877$) y MO ($r = 0.819$), con baja conductividad y buena disponibilidad hídrica.

Agricultor 6: La densidad aparente (-0.543) es la principal limitante. Aunque hay buen contenido de carbono orgánico (2.37%), su impacto es menor al esperado ($r = 0.628$) por la compactación.

Recomendaciones Estratégicas

- **Optimizar la fertilización nitrogenada:** Especialmente en Agricultor 7 y Agricultor 4, donde el nitrógeno mitiga limitaciones de pH y salinidad.
- **Reducir la compactación del suelo:** Agricultor 2 y Agricultor 3 deben adoptar prácticas como labranza reducida, siembra directa y uso de cultivos de cobertura.
- **Monitorear la salinidad y el pH:** En suelos con alta conductividad o pH (como los de Lorenzo y Leo), evitar el uso de aguas ricas en sales y aplicar enmiendas correctivas.



8. Mapas finales de % de Carbono

8.1. Guía para la interpretación de los mapas y tabla final

Los mapas a continuación representan la variación espacial del **porcentaje de carbono en el suelo**, estimado a partir de puntos de muestreo y extrapolado al resto del área.

1. Título

- Indica que se trata de un “Mapa de Distribución de Carbono (%)”.

2. Escala de colores

- Utiliza un **gradiente de tonos** para mostrar variaciones en el porcentaje de carbono.
- Los colores más oscuros representan áreas con menor contenido de carbono; los más claros, con mayor contenido.

3. Leyenda

- Explica el significado de los colores y muestra el rango de porcentaje de carbono representado.

4. Puntos de muestreo

- Señalados con un marcador (por ejemplo, un punto o un círculo), indican las ubicaciones donde se recolectaron muestras de suelo.

5. Área de estudio

- Delimitada con un contorno o polígono de color (por ejemplo, rojo), define la extensión sobre la cual se realizó el análisis.

6. Método de interpolación

- Se menciona la técnica estadística o de aprendizaje automático empleada (por ejemplo, Máquinas de Vectores de Soporte o kriging) para generar la superficie continua de carbono a partir de puntos aislados.
- Incluye una breve nota sobre la confiabilidad (por ejemplo, mediante indicadores de ajuste o validación cruzada).

7. Datos adicionales

- Espacio reservado para información complementaria, como el total de muestras, la superficie total o referencias de línea de base, sin entrar en cifras específicas.

La **tabla final en la sección 8.1.11** resume los principales resultados del análisis de carbono en el suelo para distintas explotaciones agrícolas. Cada fila corresponde a un agricultor participante, y las columnas muestran los valores clave obtenidos en su parcela.

Descripción de las columnas principales:

- **Agricultor:** Nombre del responsable o propietario del terreno evaluado.
- **Método:** Técnica usada para estimar la distribución del carbono (por ejemplo, SVM o kriging).



- **Nº muestras:** Cantidad de muestras de suelo recolectadas.
- **Moran's I (p-valor):** Medida de autocorrelación espacial; indica si los valores de carbono están agrupados o dispersos.
- **Alcance (m):** Distancia máxima a la que se detecta relación espacial entre las muestras.
- **R² y RMSE:** Indicadores estadísticos que reflejan la precisión del modelo.
- **Área (ha):** Superficie total analizada en hectáreas.
- **Cultivos:** Principales cultivos presentes en la parcela.
- **Densidad aparente (DA):** Valor medio de la densidad del suelo, necesario para calcular el carbono.
- **Línea base estimada:** Estimación de carbono por hectárea para esa parcela.
- **Carbono total (± IC95):** Cantidad total estimada de carbono con su intervalo de confianza.
- **Línea base nacional:** Valor de referencia nacional de carbono en suelos, para comparación.

¿Qué se puede entender con esta tabla?


Esta información permite comparar:


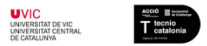



- Qué parcelas tienen más o menos carbono en el suelo.
- Qué tan preciso fue el modelo en cada caso.
- Cuánto se diferencia cada caso respecto al promedio nacional.



8.1.1. Agricultor 5

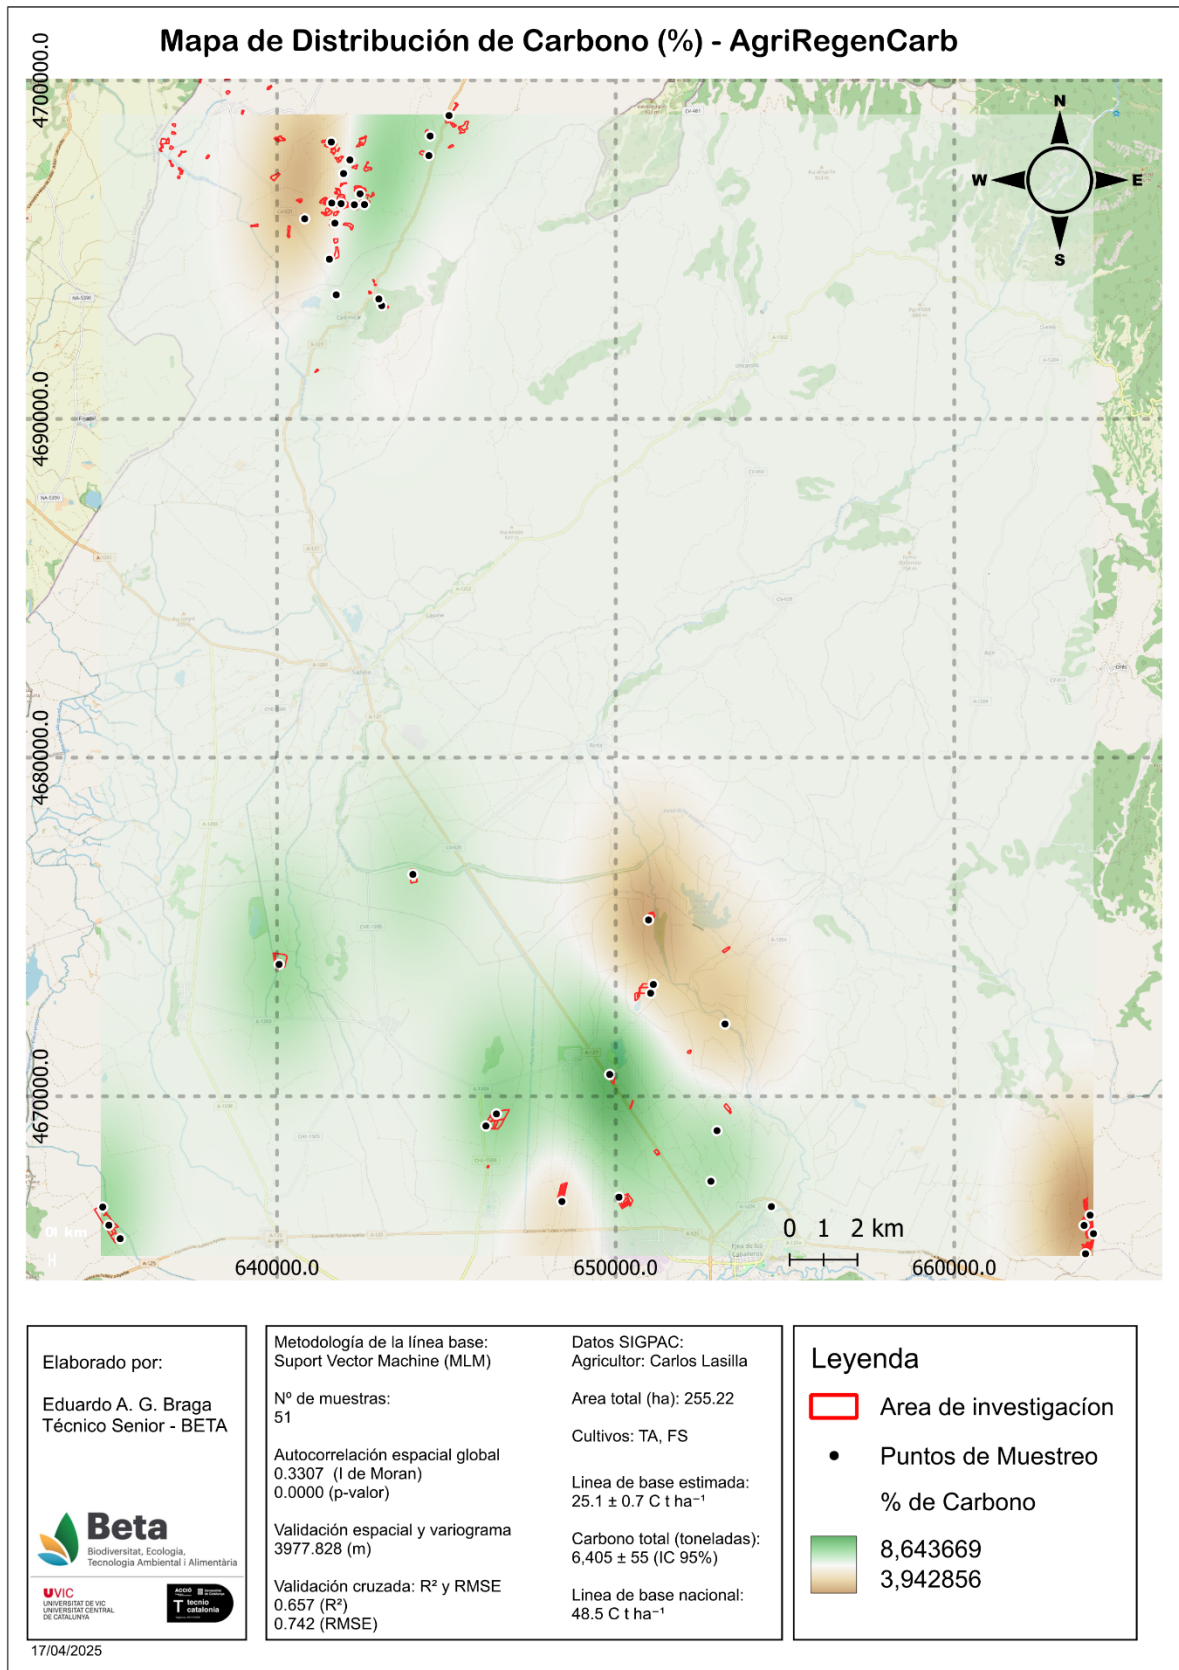
Mapa de Distribución de Carbono (%) - AgriRegenCarb



<p>Elaborado por:</p> <p>Eduardo A. G. Braga Técnico Senior - BETA</p>   <p>17/04/2025</p>	<p>Metodología de la línea base: Support Vector Machine (MLM)</p> <p>Nº de muestras: 40</p> <p>Autocorrelación espacial global 0.0348 (I de Moran) 0.0879 (p-valor)</p> <p>Validación espacial y variograma 4715.9 (m)</p> <p>Validación cruzada: R² y RMSE 0.200 (R²) 0.996 (RMSE)</p>	<p>Datos SIGPAC: Agricultor: Manuel Laliena</p> <p>Area total (ha): 197.47</p> <p>Cultivos: TA, OV, FS</p> <p>Línea de base estimada: 25.0 ± 0.8 C t ha⁻¹</p> <p>Carbono total (toneladas): 4,937 ± 257 (IC 95%)</p> <p>Línea de base nacional: 48.5 C t ha⁻¹</p>	<p>Leyenda</p> <p> Area de investigación</p> <p> Puntos de Muestreo</p> <p>% de Carbono</p> <p> 6,532663 5,770289</p>
--	---	---	---




8.1.2. Agricultor 4





8.1.3. Agricultor 3

Mapa de Distribución de Carbono (%) - AgriRegenCarb



Elaborado por:

Eduardo A. G. Braga
Técnico Senior - BETA



17/04/2025

Metodología de la línea base:
Support Vector Machine (MLM)

Nº de muestras:
21

Autocorrelación espacial global
-0.0381 (I de Moran)
0.4031 (p-valor)

Validación espacial y variograma
16903.5 (m)

Validación cruzada: R² y RMSE
0.850 (R²)
0.838 (RMSE)

Datos SIGPAC:
Agricultor: Fernando Peligro

Area total (ha): 158.31

Cultivos: VI, TA
Línea de base estimada:
9.2 ± 1.6 C t ha⁻¹

Carbono total (toneladas):
1,457 ± 88 (IC 95%)

Línea de base nacional:
48.5 C t ha⁻¹

Leyenda

Area de investigación

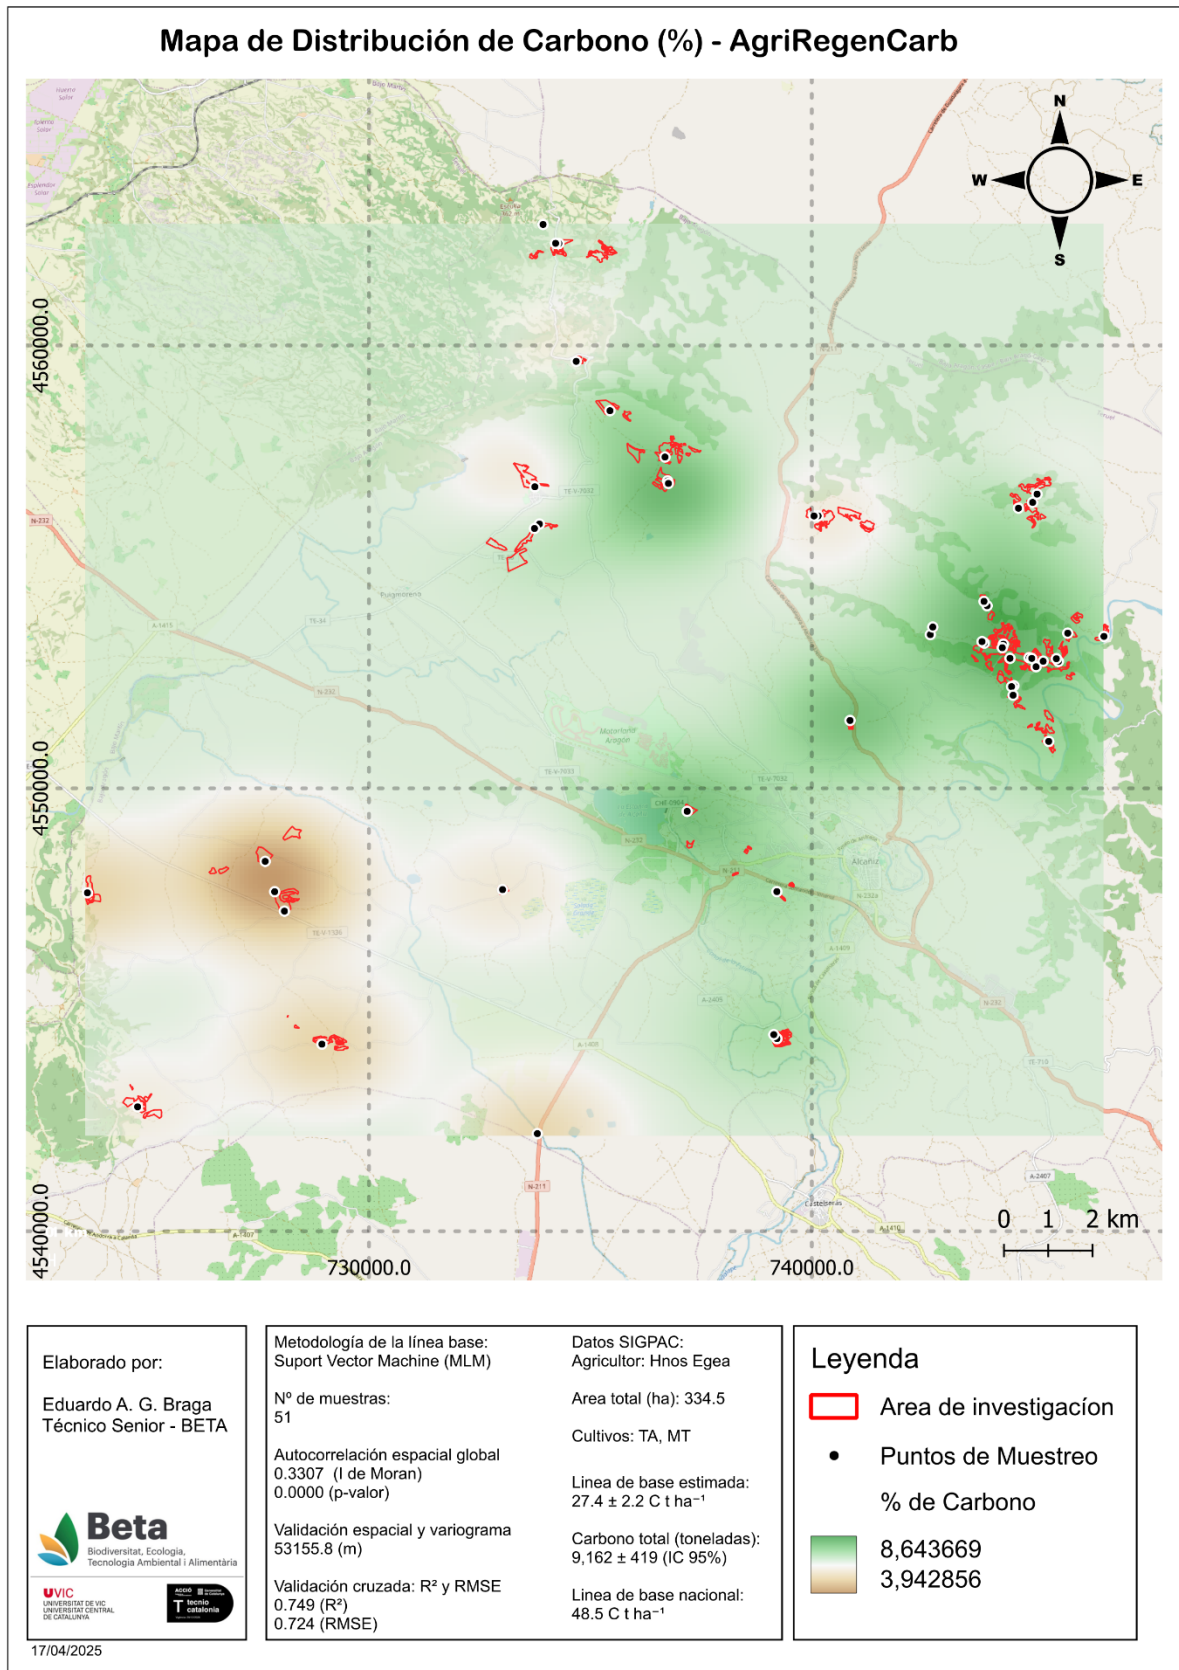
Puntos de Muestreo

% de Carbono

3,799053
 0,991663

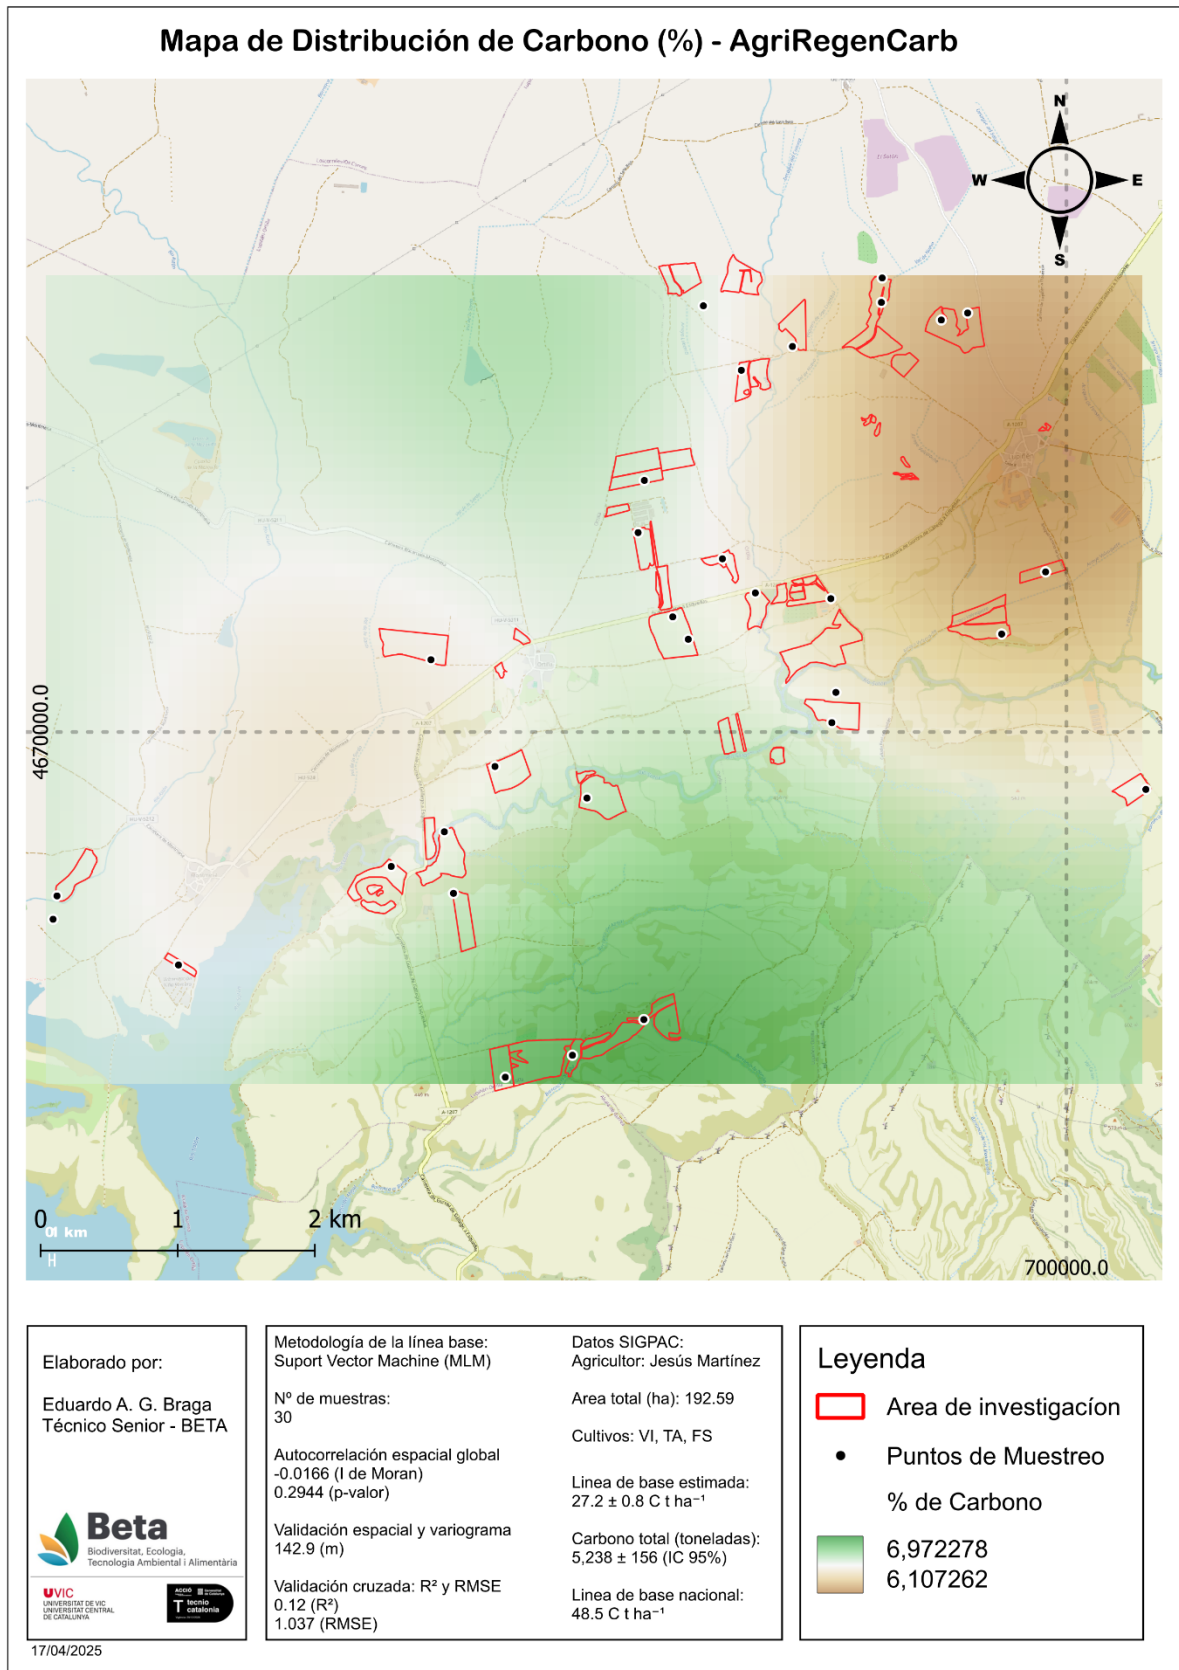


8.1.4. Agricultor 1



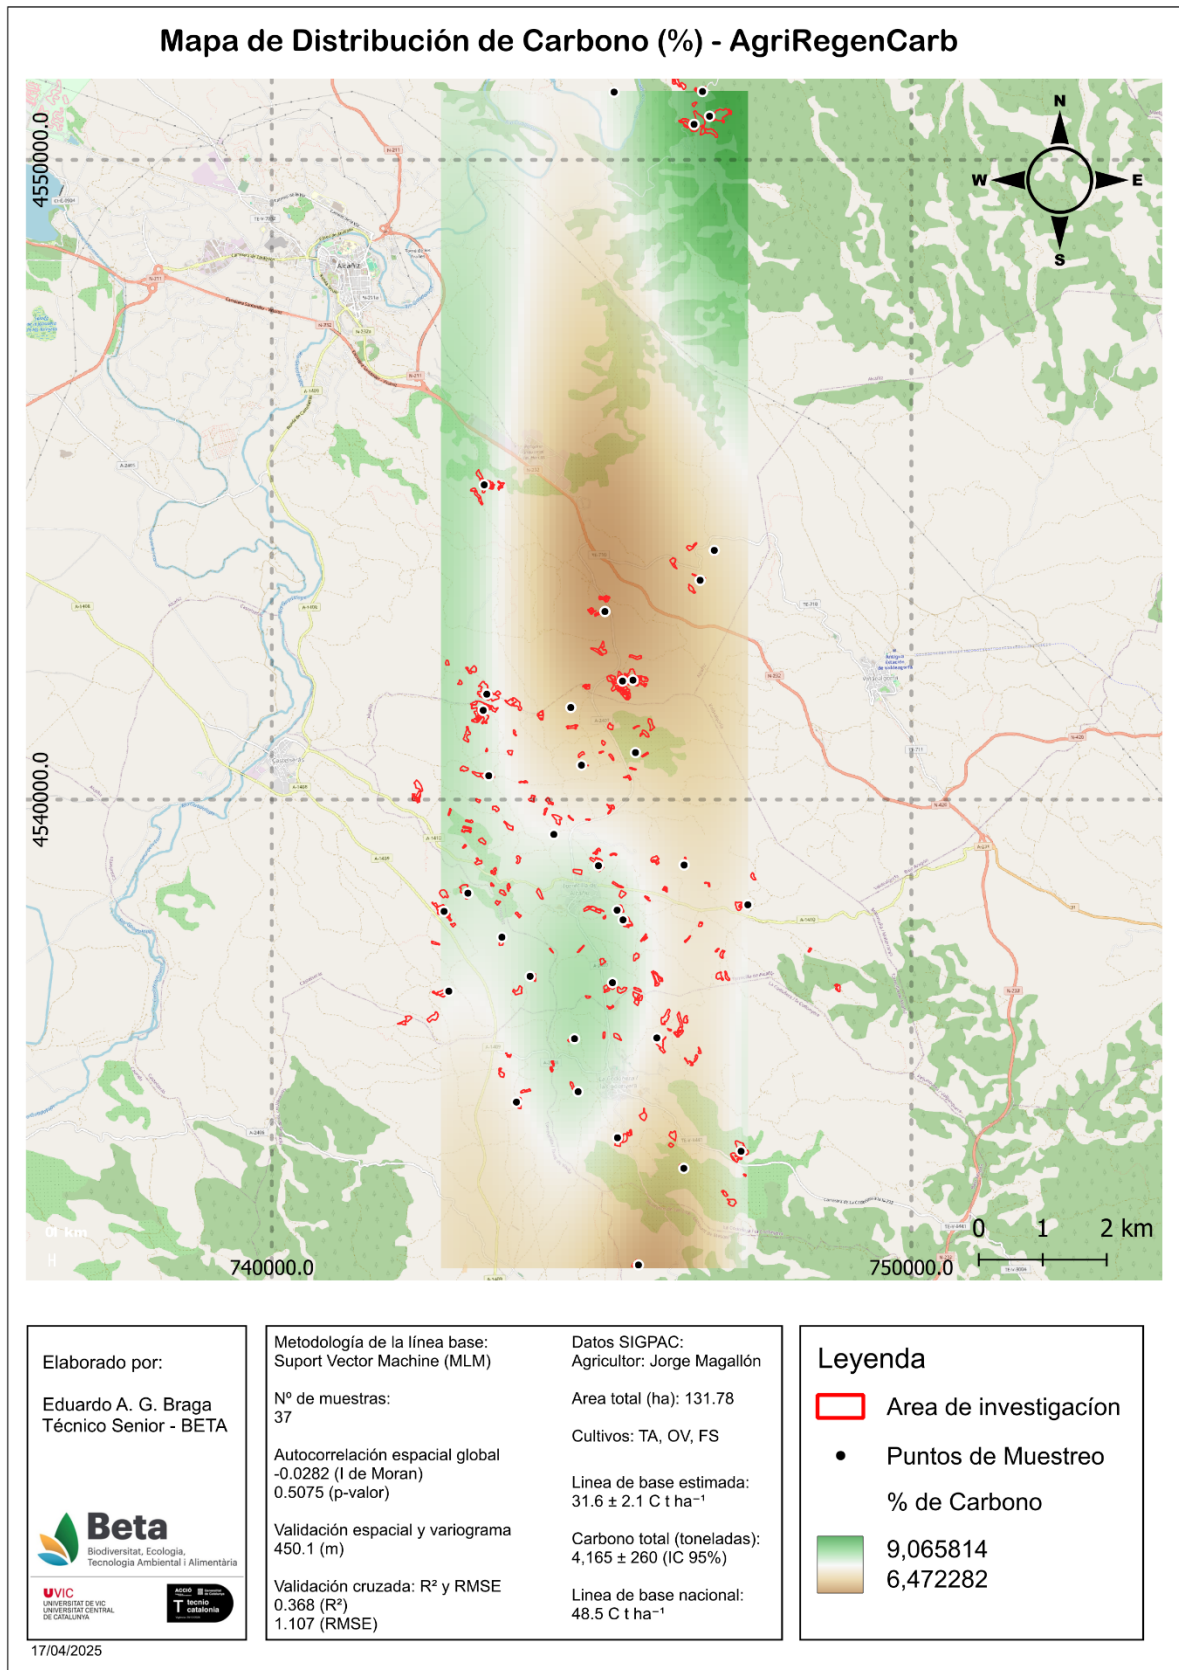


8.1.5. Agricultor 7





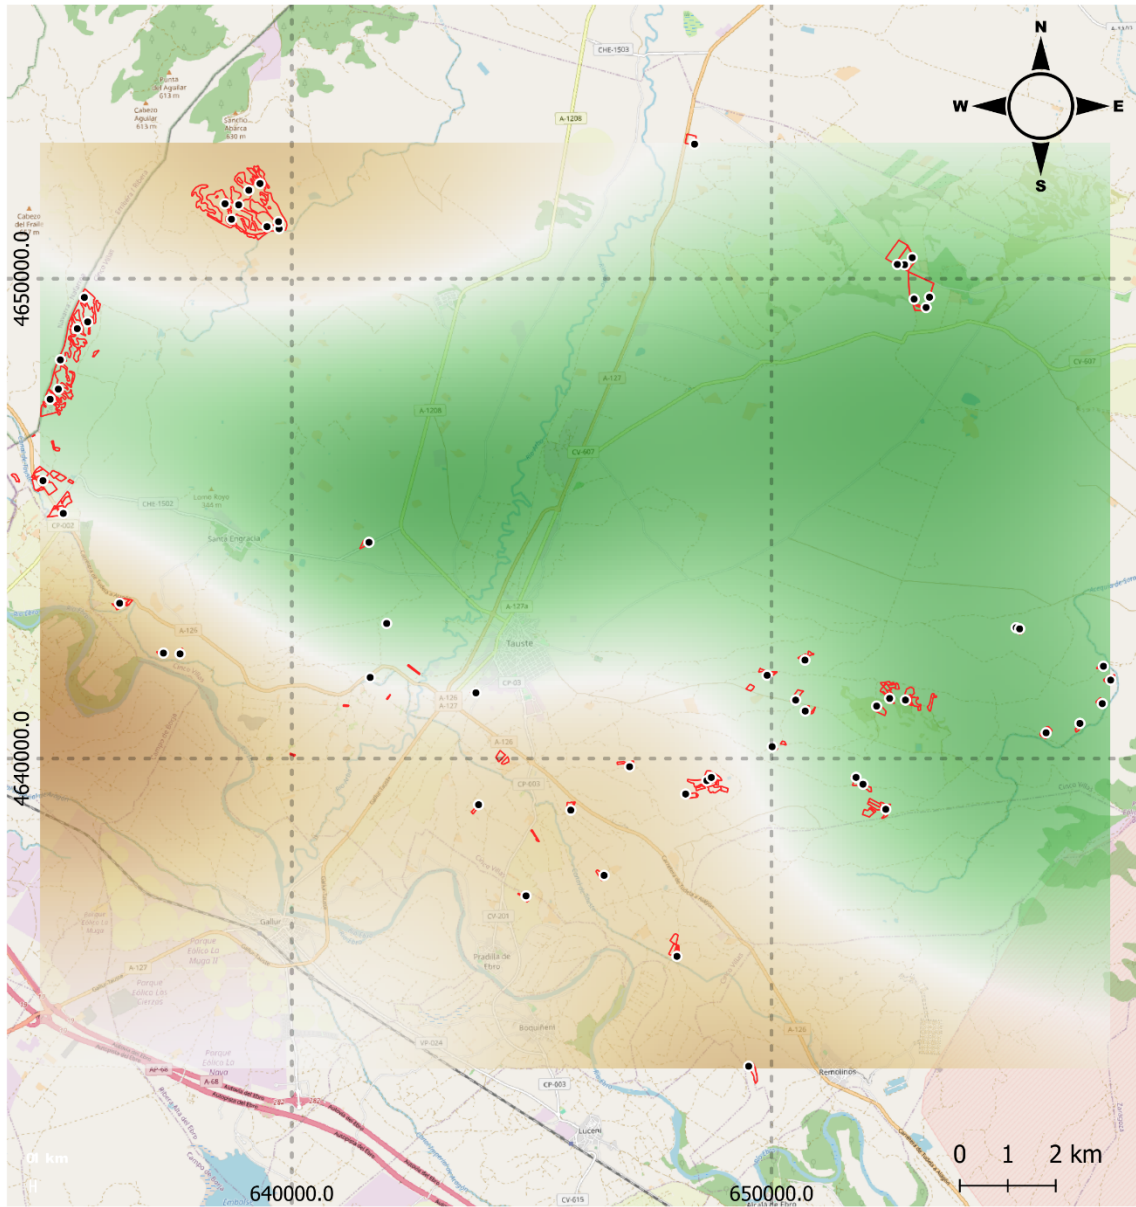
8.1.6. Agricultor 2





8.1.7. Agricultor 6

Mapa de Distribución de Carbono (%) - AgriRegenCarb



Elaborado por:

Eduardo A. G. Braga
Técnico Senior - BETA



17/04/2025

Metodología de la línea base:
Support Vector Machine (MLM)

Nº de muestras:
60

Autocorrelación espacial global
0.0209 (I de Moran)
0.0523 (p-valor)

Validación espacial y variograma
1562.8 (m)

Validación cruzada: R² y RMSE
0.304 (R²)
1.079 (RMSE)

Datos SIGPAC:
Agricultor: Leo Gale

Area total (ha): 366.06

Cultivos: TA, PS, MT

Línea de base estimada:
27.2 ± 2.1 C t ha⁻¹

Carbono total (toneladas):
9,952 ± 411 (IC 95%)

Línea de base nacional:
48.5 C t ha⁻¹

Leyenda

Area de investigación

Puntos de Muestreo

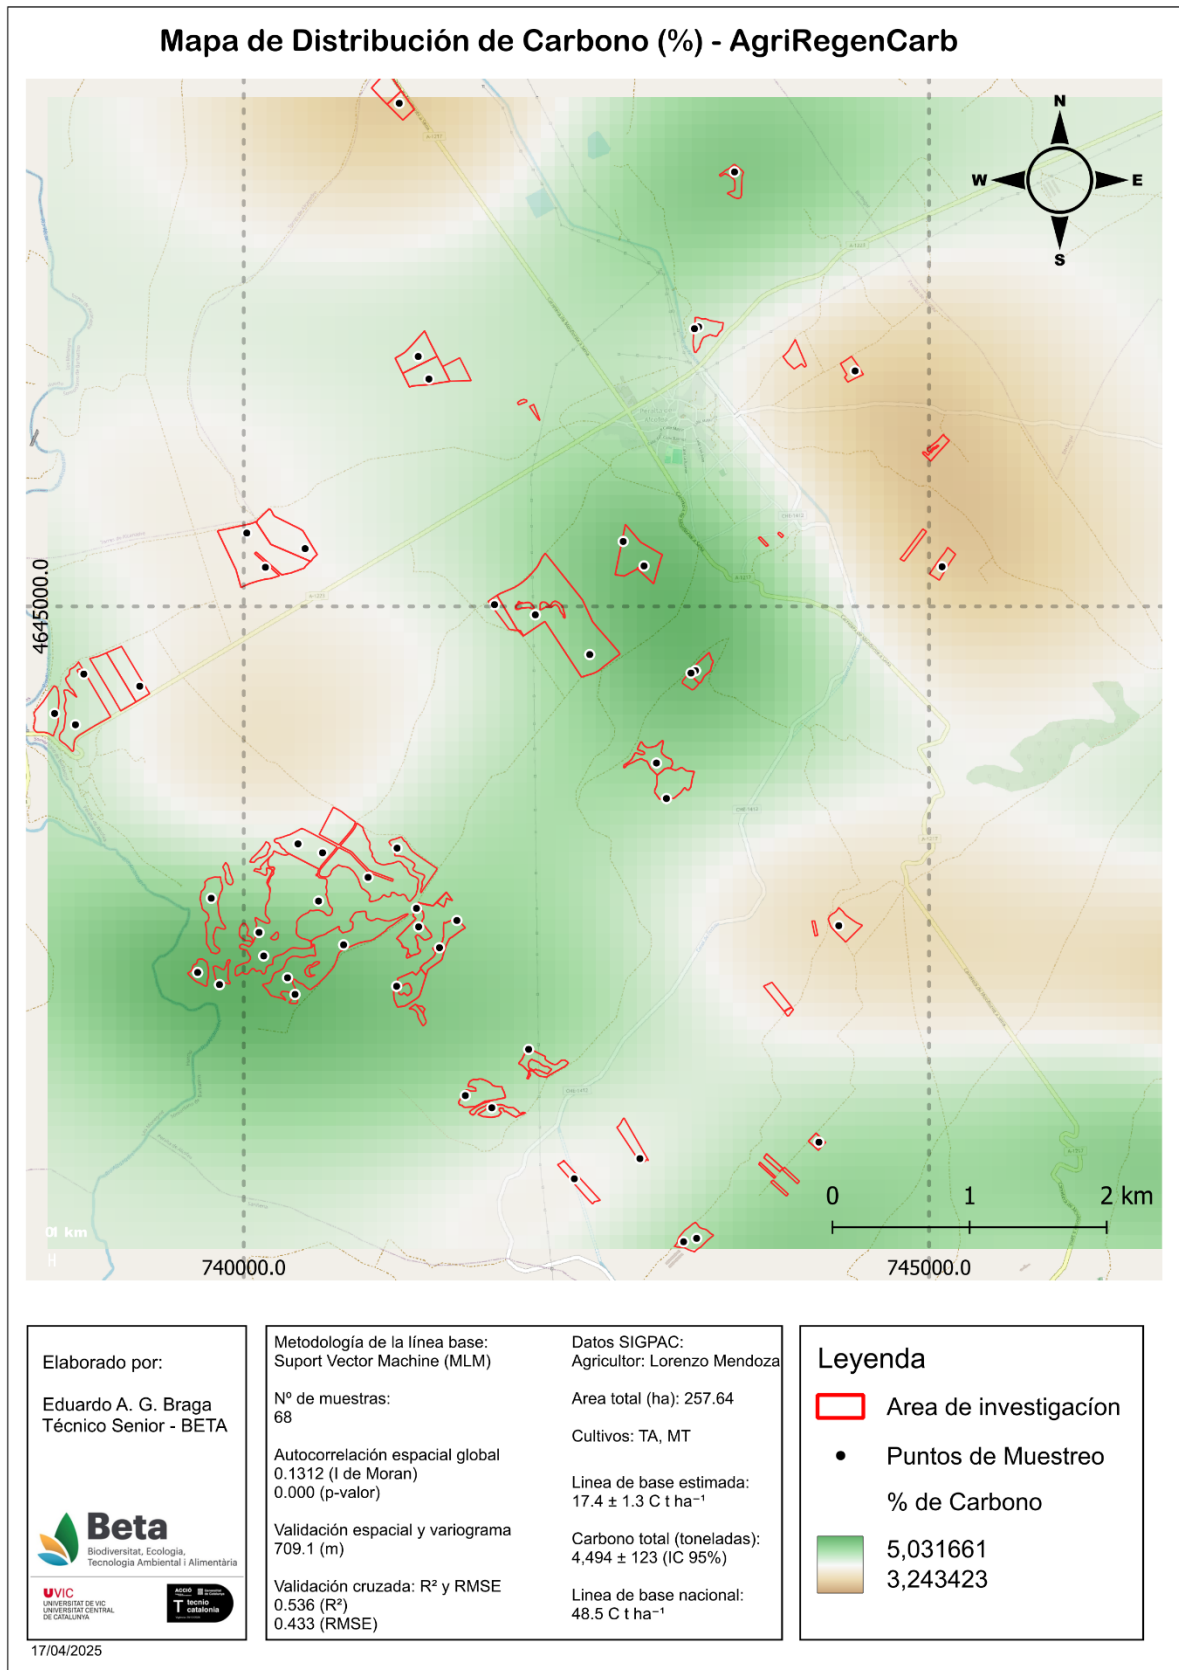
% de Carbono

7,755231

5,64878

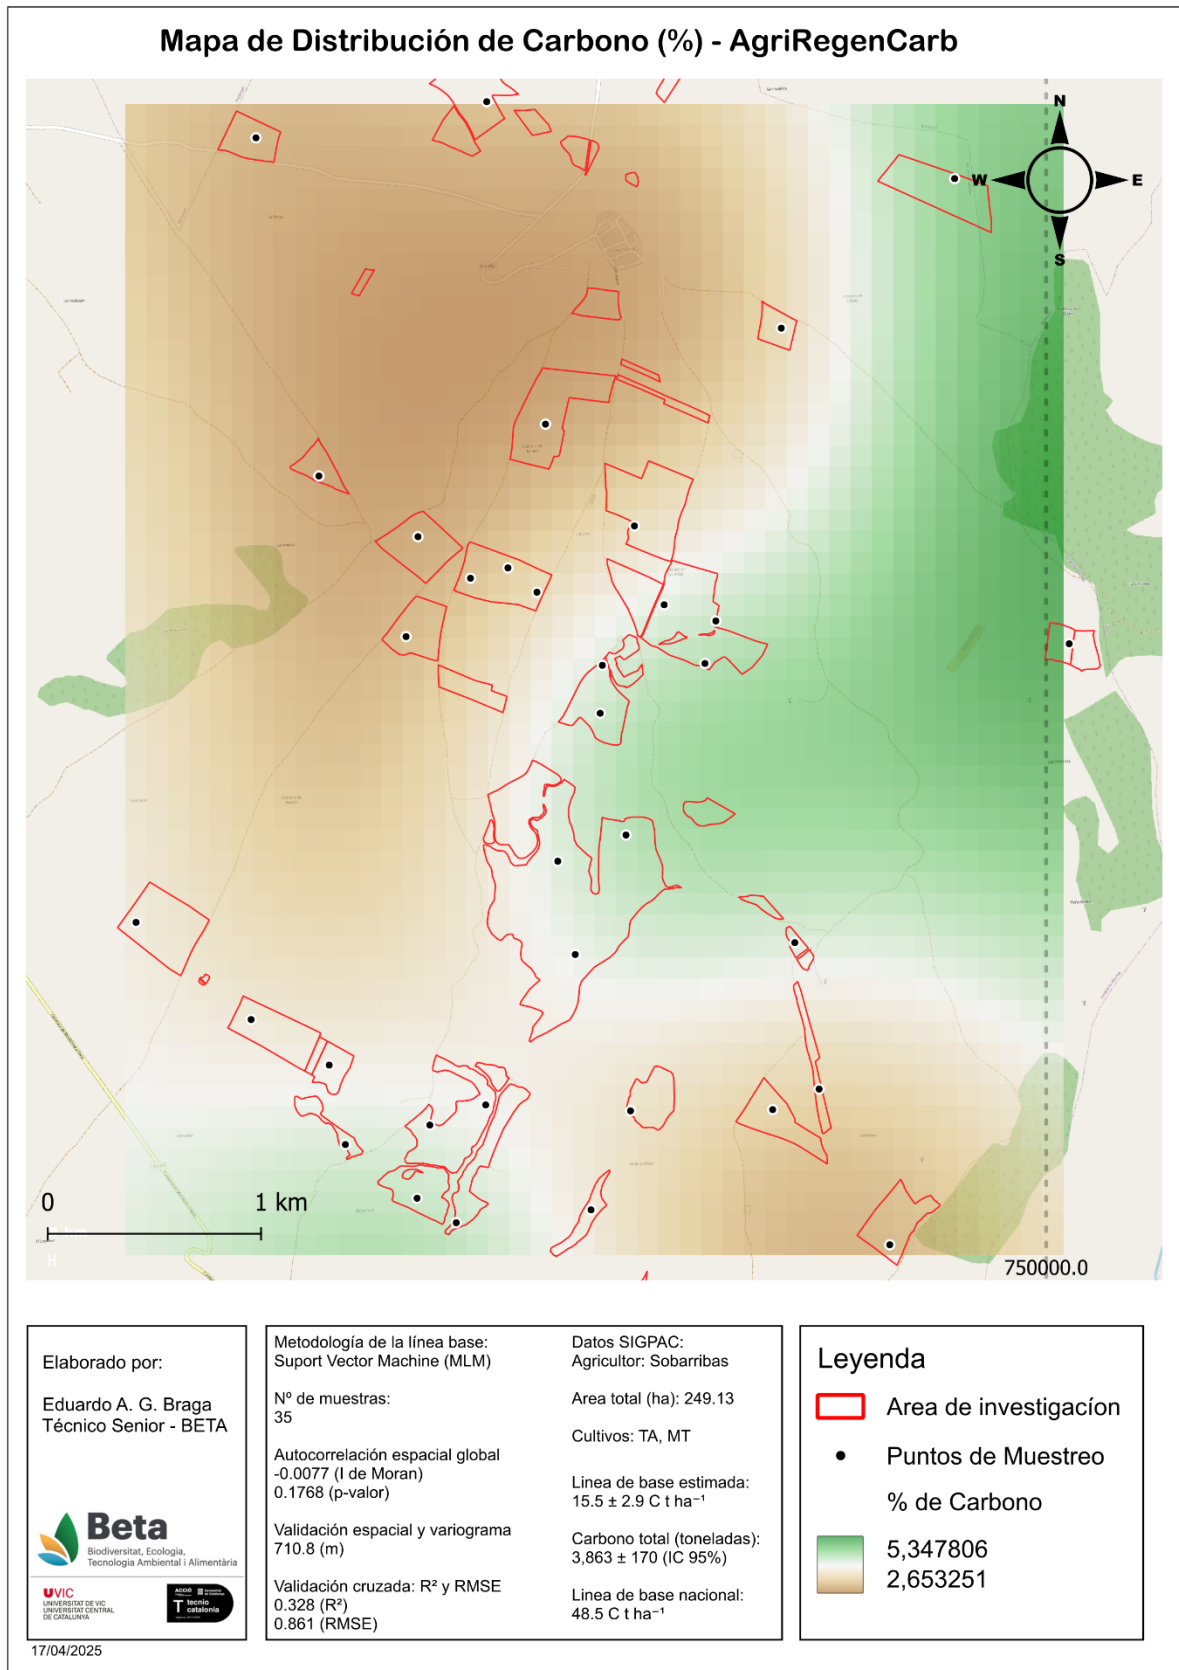


8.1.8. Agricultor 9



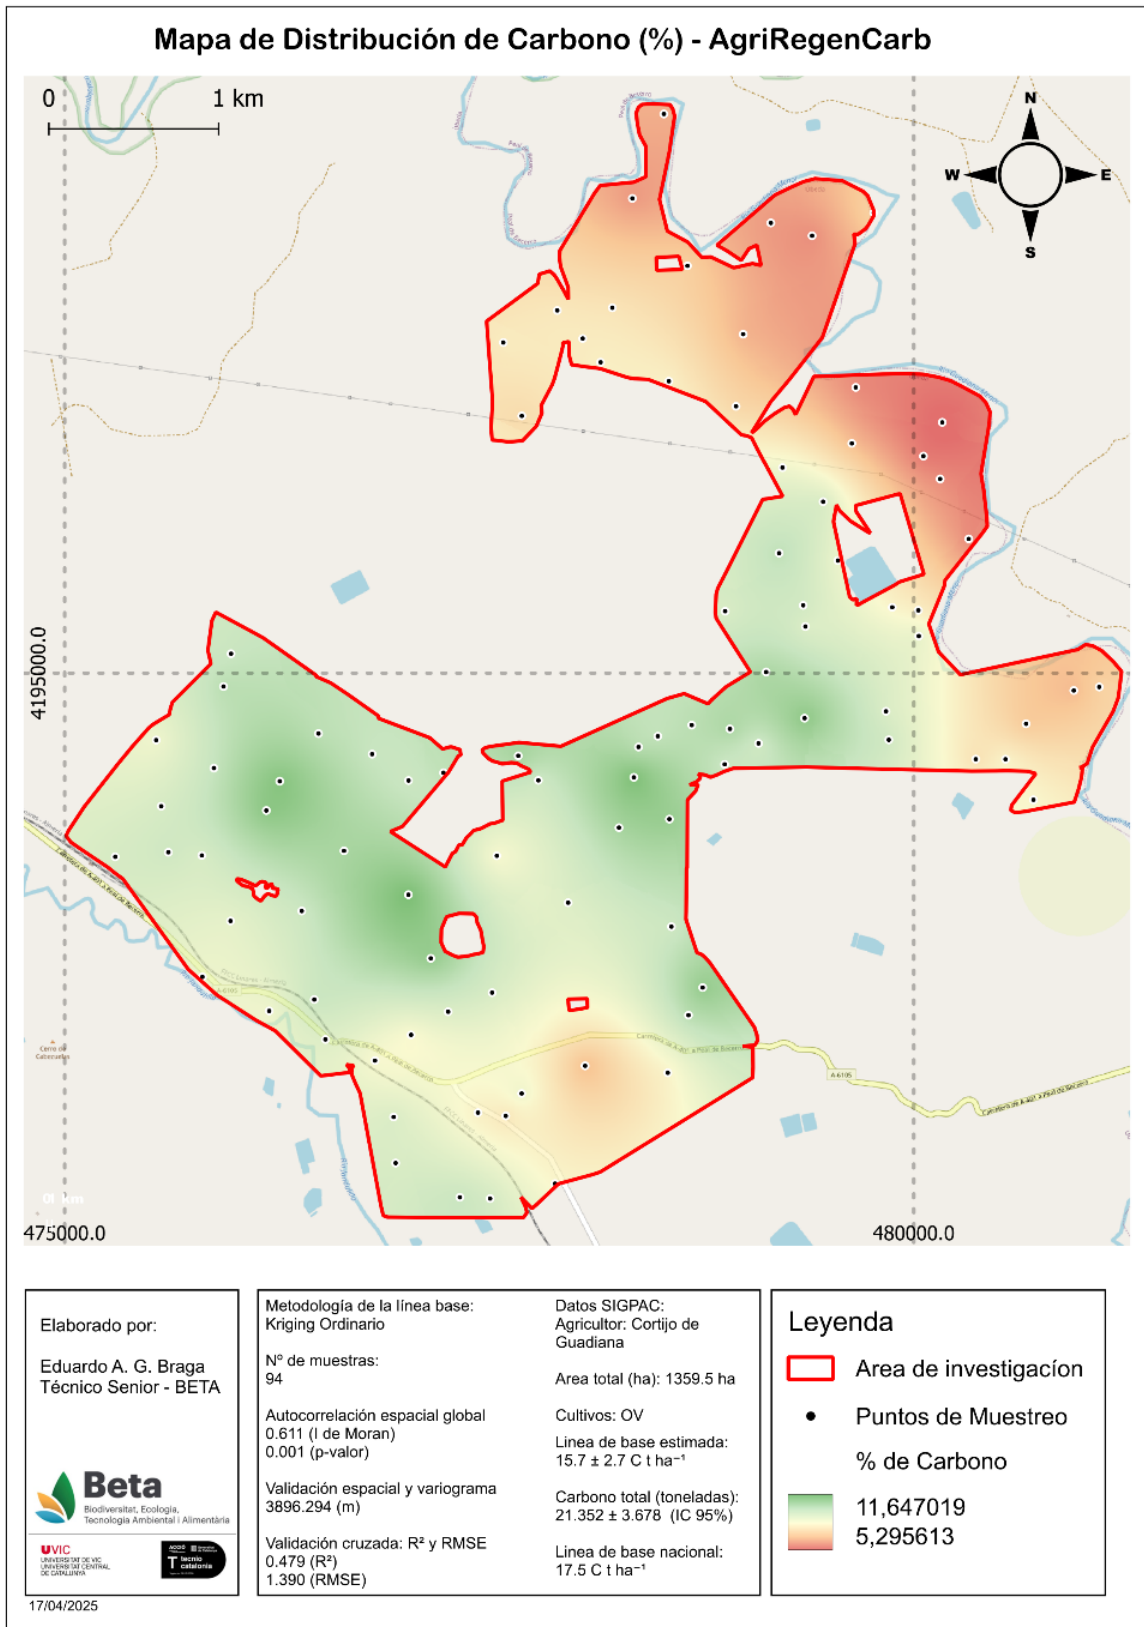


8.1.9. Agricultor 8





8.1.10. Agricultor 10-Castillo de Canena



8.1.11. Resumen de Parámetros de Modelado y Resultados de Carbono por Agricultor

Agricultor	Método	Nº muestras	Moran's I (p-valor)	Alcance (m)	R ²	RMSE	Área (ha)	Cultivos	DA media (g/cm ³)	Línea base estimada (t C/ha)	C Total ± IC95 (t)	Línea base nacional (t C/ha)
Agricultor 5	SVM (MLM)	40	0.0348 (0.0879)	4715.9	0.2	0.996	197.47	TA, OV, FS	1.3123	25.0 ± 0.8	4,937 ± 257	48.5
Agricultor 4	SVM (MLM)	38	-0.0208 (0.4283)	—	0.657	0.742	255.22	TA, FS	1.3545	25.1 ± 0.7	6,405 ± 55	48.5
Agricultor 3	SVM (MLM)	21	-0.0381 (0.4031)	16903.5	0.85	0.838	158.31	VI, TA	1.3627	9.2 ± 1.6	1,457 ± 88	48.5
Agricultor 1	SVM (MLM)	51	0.3307 (<1e-44)	53155.8	0.749	0.724	334.5	TA, MT	1.38	27.4 ± 2.2	9,162 ± 419	48.5
Agricultor 7	SVM (MLM)	30	-0.0166 (0.2944)	142.9	0.12	1.037	192.59	VI, TA, FS	1.3853	27.2 ± 0.8	5,238 ± 156	48.5
Agricultor 2	SVM (MLM)	37	-0.0282 (0.5075)	450.1	0.368	1.107	131.78	TA, OV, FS	1.3153	31.6 ± 2.1	4,165 ± 260	48.5
Agricultor 6	SVM (MLM)	60	0.0209 (0.0523)	1562.8	0.304	1.079	366.06	TA, PS, MT	1.357	27.2 ± 2.1	9,952 ± 411	48.5
Agricultor 9	SVM (MLM)	68	0.1312 (2.8e-20)	709.1	0.536	0.433	257.64	TA, MT	1.3748	17.4 ± 1.3	4,494 ± 123	48.5
Agricultor 8	SVM (MLM)	35	-0.0077 (0.1768)	710.8	0.328	0.861	249.13	TA, MT	1.3675	15.5 ± 2.9	3,863 ± 170	48.5
Agricultor 10	Kriging Ordinario	94	0.611 (0.001)	3896.294	0.479	1.39	1359.5	OV	1.2489	15.7 ± 2.7	21,352 ± 3,678	17.5



9. Conclusión

La agricultura regenerativa de carbono se presenta como una solución prometedora para restaurar la salud de los suelos mediterráneos y contribuir a la lucha contra el cambio climático. Sin embargo, su éxito depende de enfoques adaptados a las particularidades de cada territorio y de políticas que reconozcan las realidades locales. Estos son los mensajes clave:

Hallazgos Clave

1. Potencial de la Agricultura Regenerativa:

- Mejora la calidad del suelo al aumentar el carbono orgánico, lo que favorece cultivos más resilientes y productivos.
- En zonas homogéneas (como los olivares de Jaén), métodos avanzados de mapeo permiten identificar áreas prioritarias para intervención.
- En áreas fragmentadas (como Aragón), técnicas flexibles integradas con tecnología moderna ofrecen resultados precisos, aunque requieren mayor inversión inicial.

2. Desafíos en la Certificación de Carbono:

- Las estimaciones nacionales de carbono en suelos suelen ser poco precisas para proyectos cuando comparadas con valores nacionales de referencia.
- Suelos alcalinos (comunes en zonas mediterráneas) pueden poseer menor capacidad de almacenar carbono, un factor crítico que debe considerarse en los proyectos.

3. Resultados por Agricultor:

- Áreas como del de *Agricultor 1* (Aragón) demuestran que es posible alcanzar niveles altos de carbono en el suelo (27.4 t/ha), aunque no llega a superar la línea base nacional (48.5 t/ha).
- En contraste, áreas como de *Agricultor 7* muestran resultados variables, lo que subraya la necesidad de análisis personalizados (textura, histórico de riego, fertilización, etc).

Recomendaciones para Acción

1. Invertir en Métodos Adaptados:

- Utilizar tecnologías de mapeo de alta resolución para diseñar estrategias específicas según el tipo de suelo, pendiente y cultivo.
- Insertar variables para el refinamiento del modelo, como el tipo de cobertura, el historial de riego y la textura del suelo, especialmente en zonas con clústeres de alta variabilidad. Estas variables pueden ayudar a mejorar la precisión del modelo y a explicar mejor las diferencias espaciales observadas en el contenido de carbono.

2. Fortalecer las Políticas Públicas:

- Actualizar las líneas de base nacionales con datos locales para evitar sobrestimar o subestimar el potencial de captura de carbono.



3. Promover la Transparencia:

- Garantizar que cada crédito de carbono certificado se base en mediciones rigurosas y verificables, evitando "créditos fantasma".

La implementación exitosa demanda superar limitaciones metodológicas, innovar en técnicas de monitoreo y modelización, y fortalecer marcos normativos que contemplen la complejidad edáfica, climática y socioeconómica de los sistemas mediterráneos. La transformación del potencial teórico en beneficios verificables exige la adopción de metodologías de alta resolución espacial, el fortalecimiento de la colaboración transdisciplinaria entre actores científicos y agrícolas, y la formulación de políticas públicas que promuevan la heterogeneidad territorial como valor estratégico.

Cada crédito de carbono emitido debe sustentarse en evidencias cuantificables de mejora en la calidad del suelo, garantizando integridad ambiental y confianza en los mercados de carbono. No obstante, la regeneración no debe circunscribirse exclusivamente al secuestro de carbono. La restauración de la biodiversidad, el fortalecimiento de la equidad rural y la construcción de paisajes resilientes son dimensiones igualmente esenciales para alcanzar un modelo agroalimentario justo, sostenible y adaptativo frente a los desafíos del cambio climático.



10. Referencias

Álvarez Lamata, E. (2005). *Los incendios forestales y las condiciones meteorológicas en Aragón*. Recuperado de <https://scispace.com/papers/los-incendios-forestales-y-las-condiciones-meteorologicas-en-1s9079788b>.

Alves, S., Correia dos Santos, M. M., & Trancoso, M. A. (2009). Evaluation of measurement uncertainties for the determination of total metal content in soils by atomic absorption spectrometry. *Accreditation and Quality Assurance*, 14, 87–93. <https://doi.org/10.1007/s00769-008-0484-5>.

Andrés-Abellán, M., Wic-Baena, C., López-Serrano, F., García-Morote, F. A., Martínez-García, E., Picazo, M. I., Rubio, E., Moreno-Ortego, J. L., Bastida-López, F., & Garcia-Izquierdo, C. (2019). A soil-quality index for soil from Mediterranean forests. *European Journal of Soil Science*, 70(5), 1001–1011.

Argyraki, A., & Petrakaki, N. (2017). Heterogeneity in heavy metal concentrations in the soil of a firing range area at Kesariani, Athens, Greece. *Bulletin of the Geological Society of Greece*, 43, 2319–2326. <https://doi.org/10.12681/bgsq.16065>.

Armenise, E., Redmile-Gordon, M., Stellacci, A. M., Ciccacese, A., & Rubino, P. (2013). Developing a soil quality index to compare soil fitness for agricultural use under different managements in the Mediterranean environment. *Soil & Tillage Research*, 130, 91–98.

Blagodatskaya, E., & Kuzyakov, Y. (2008). Mechanisms of real and apparent priming effects and their dependence on soil microbial biomass and community structure: Critical review. *Biology and Fertility of Soils*, 45(2), 115–131. <https://doi.org/10.1007/s00374-008-0334-y>.

Brus, D. J. (2019). Sampling for digital soil mapping: A tutorial supported by R scripts. *Geoderma*, 338, 464–480. <https://doi.org/10.1016/j.geoderma.2018.07.036>.

Buczko, U., Kuchenbuch, R. O., Übelhör, W., & Nätscher, L. (2012). Assessment of sampling and analytical uncertainty of trace element contents in arable field soils. *Environmental Monitoring and Assessment*, 184, 4517–4538. <https://doi.org/10.1007/s10661-011-2282-5> [SpringerLink](#).

Cai, A., Han, T., Ren, T., Sanderman, J., Rui, Y., Wang, B., . . . Li, Y. (2022). Declines in soil carbon storage under no tillage can be alleviated in the long run. *Geoderma*, 425, 116028. <https://doi.org/10.1016/j.geoderma.2022.116028>.

Camacho, A., Mora, C., Picazo, A., Rochera, C., Camacho-Santamans, A., Morant, D., Roca-Pérez, L., Ramos-Miras, J. J., Rodríguez-Martín, J. A., & Boluda, R. (2022). *Effects of soil quality on the microbial community structure of poorly evolved Mediterranean soils*. *Toxics*, 10(1), 14. <https://doi.org/10.3390/toxics10010014>

Cambardella, C. A., Moorman, T. B., Novak, J. M., Parkin, T. B., Karlen, D. L., Turco, R. F., & Konopka, A. E. (1994). Field-scale variability of soil properties in central Iowa soils. *Soil Science Society of America Journal*, 58(5), 1501–1511. <https://doi.org/10.2136/sssaj1994.03615995005800050033x>.



Casas-Castillo, M. del C., et al. (2022). *A Simple Scaling Analysis of Rainfall in Andalusia (Spain) under Different Precipitation Regimes*. *Water*, 14(8), 1303. <https://doi.org/10.3390/w14081303>.

Chen, S., Martin, M. P., Saby, N. P. A., Walter, C., Angers, D. A., & Arrouays, D. (2018). Fine resolution map of top- and subsoil carbon sequestration potential in France. *Science of The Total Environment*, 630, 389–400. <https://doi.org/10.1016/j.scitotenv.2018.02.209>.

Cochran, W.G. (1977). *Sampling Techniques*. Eds. John Wiley & Sons, pp. 442. New York, Chichester, Brisbane, Toronto, Singapore. [ark:/13960/s2bjc52h1mj](https://doi.org/10.1002/9781118133211.ch11).

Confederación Hidrográfica del Guadalquivir (CHG). (2022). *Informe de la Demanda y Disponibilidad de Recursos Hídricos en la Cuenca del Guadalquivir*. Disponible en: www.chguadalquivir.es.

Crowther, T. W., van den Hoogen, J., Wan, J., Mayes, M. A., Keiser, A. D., Mo, L., ... & Maynard, D. S. (2019). The global soil community and its influence on biogeochemistry. *Science*, 365(6455), eaav0550. <https://doi.org/10.1126/science.aav0550>.

de Gruijter, J. J., McBratney, A. B., Minasny, B., Wheeler, I., Malone, B. P., & Stockmann, U. (2015). Farm-scale soil carbon auditing. *Geoderma*, 263, 142-152. <https://doi.org/10.1016/j.geoderma.2015.11.010>.

del Valle Melendo, J. (2017). *Tendencias climáticas en la zona central de la provincia de Huesca durante los últimos 30 años*. *Geographica*, (67), 69–88. https://doi.org/10.26754/OJS_GEOPH/GEOPH.1990271867.

Eagle, A. J., & Olander, L. P. (2012). Greenhouse gas mitigation with agricultural land management activities in the United States—A side-by-side comparison of biophysical potential. *Advances in Agronomy*, 115, 79–179. <https://doi.org/10.1016/B978-0-12-394276-0.00003-2>.

Einax, J. W., & Kraft, J. (2002). Small-scale variability of metals in soil and composite sampling. *Environmental Science and Pollution Research*, 9, 257–261. <https://doi.org/10.1007/BF02987581>.

Evangelou, E., & Giourga, C. (2024). *Identification of soil quality factors and indicators in Mediterranean agro-ecosystems*. *Sustainability*, 16(23), 10717. <https://doi.org/10.3390/su162310717>

Evangelou, E., Tsadilas, C., & Giourga, C. (2020). Seasonal variation of soil microbial biomass carbon and nitrogen as affected by land use in a Mediterranean agroecosystem. *Communications in Soil Science and Plant Analysis*, 52(3), 222–234. <https://doi.org/10.1080/00103624.2020.1861408>.

FAO. (2006). *Guía para la descripción de perfiles de suelo* (4.ª ed.). Organización de las Naciones Unidas para la Agricultura y la Alimentación. <http://www.fao.org/publications/card/en/c/0f070cdd-1b6d-53fa-add1-5c972fb299d2/>.

FAO. (2019). *Measuring and modelling soil carbon stocks and stock changes in livestock production systems – Guidelines for assessment (Version 1)*. Food and Agriculture Organization of the United Nations.



Fontaine, S., Bardoux, G., Abbadie, L., & Mariotti, A. (2004). Carbon input to soil may decrease soil carbon content. *Ecology Letters*, 7(4), 314–320. <https://doi.org/10.1111/j.1461-0248.2004.00579.x>.

Francaviglia, R., Renzi, G., Doro, L., Parras-Alcántara, L., Lozano-García, B., & Ledda, L. (2017). Soil sampling approaches in Mediterranean agro-ecosystems. Influence on soil organic carbon stocks. *Catena*, 158, 113–120. <https://doi.org/10.1016/j.catena.2017.06.014>.

García, Y., Ramírez, W., & Sánchez, S. (2012). *Indicadores de la calidad de los suelos: una nueva manera de evaluar este recurso*. *Pastos y Forrajes*, 35(2), 1–15.

Goovaerts, P. (1999). *Geostatistics for natural resources evaluation*. Oxford University Press.

García, Y., Ramírez, W., & Sánchez, S. (2012). *Indicadores de la calidad de los suelos: una nueva manera de evaluar este recurso*. *Pastos y Forrajes*, 35(2), 1–15.

Guenet, B., Leloup, J., Raynaud, X., Bardoux, G., & Abbadie, L. (2010). Negative priming effect on mineralization in a soil free of vegetation for 80 years. *European Journal of Soil Science*, 61(3), 384–390. <https://doi.org/10.1111/j.1365-2389.2010.01234.x>.

Guo, Y., Liu, T., Shi, Z., & Wang, L. (2020). Digital soil mapping of organic carbon and its spatial distribution uncertainty in field scale. *EGU General Assembly 2020*. <https://doi.org/10.5194/egusphere-egu2020-2073>.

Hong, Z. (2008). Spatial variability and sampling strategy of forest soil in different scales. *Journal of Subtropical Resources and Environment*.

Imaz, M. J., Virto, I., Bescansa, P., Enrique, A., Fernandez-Ugalde, O., & Karlen, D. L. (2010). *Soil quality indicator response to tillage and residue management on semi-arid Mediterranean cropland*. *Soil and Tillage Research*, 107(2), 17–25. <https://doi.org/10.1016/j.still.2010.02.003>.

Jordán Vidal, M. M. (2023). *Criteria for assessing the environmental quality of soils in a Mediterranean region for different land use*. *Soil Systems*, 7(3), 75. <https://doi.org/10.3390/soilsystems7030075>

Keesstra, S., et al. (2018). Soil-related sustainable development goals: Four concepts to make land degradation neutrality and restoration work. *Land*, 7(4), 133. <https://doi.org/10.3390/land7040133>.

Kim, G. (2013). Quantification of uncertainty associated with soil sampling and its reduction approaches. *Journal of the Society of Groundwater and Environment*, 18(1), 94–101. <https://doi.org/10.7857/JSGE.2013.18.1.094>.

Lagacherie, P., & McBratney, A. B. (2007). Spatial soil information systems and spatial soil inference systems: Perspectives for digital soil mapping. In P. Lagacherie, A. B. McBratney, & M. Voltz (Eds.), *Digital soil mapping: An introductory perspective* (pp. 3–22).



Lal, R. (2004). Carbon sequestration in dryland ecosystems. *Environmental Management*, 33(4), 528–544. <https://doi.org/10.1007/s00267-003-9110-9>.

Li, H., Gao, Y., Yan, J., & Li, J. (2014). Spatial heterogeneity of soil respiration in a subalpine meadow at different sampling scales. *Huan Jing Ke Xue*, 35(11), 4313–4320.

Liu, Z. et al. (2020). Reactividad del carbono inorgánico en regiones áridas. *Environmental Science & Technology*, 54(15), 9345-9353.

López Rodríguez, M. M., Robledo Mahón, T., Purswani, J., Pozo, C., Calvo, C., Saia, S., & Aranda, E. (2025). *Salud del suelo y agricultura resiliente en el Mediterráneo: La Universidad de Granada participa en el proyecto SHARInG-MeD*. Interempresas. <https://www.interempresas.net/A590821>

López, M. L., Marco, R., Piñas, S., & López, M. S. (2015). *Mapa de isobioclimas de Aragón*. Recuperado de <https://scispace.com/papers/mapa-de-isobioclimas-de-aragon-lrbuhw314k>.

Ma, J.-G. (2009). Evaluation of uncertainty for measurement result of ⁹⁰Sr in environmental soil samples. *Journal of Radioanalytical and Nuclear Chemistry*, 280, 405–409. <https://doi.org/10.1007/s10967-009-7362-3>.

Manly, B.F.J. & Navarro Alberto, J.A. (2025). *Introduction to Ecological Sampling*. CRC Press.

Martin, M. P., Dimassi, B., Dobarco, M. R., Guenet, B., Arrouays, D., Angers, D. A., . . . Pellerin, S. (2021). Feasibility of the 4 per 1000 aspirational target for soil carbon: A case study for France. *Global Change Biology*. <https://doi.org/10.1111/gcb.15547>.

McBratney, A. B., Mendonça Santos, M. L., & 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).

Meurer, K. H. E., Haddaway, N. R., Bolinder, M. A., & Kätterer, T. (2018). Tillage intensity affects total SOC stocks in boreo-temperate regions only in the topsoil—A systematic review using an ESM approach. *Earth-Science Reviews*, 177, 613–622. <https://doi.org/10.1016/j.earscirev.2017.12.015>.

Minasny, B., Malone, B. P., & McBratney, A. B. (2013). Digital soil mapping of soil carbon. *Advances in Agronomy*, 118, 1-47. <https://doi.org/10.1016/B978-0-12-405942-9.00001-3>.

Minasny, B., & McBratney, A. B. (2016). Digital soil mapping: A brief history and some lessons. *Geoderma*, 264, 301-311. <https://doi.org/10.1016/j.geoderma.2015.07.017>.

Mukherjee, A., & Lal, R. (2014). Comparison of Soil Quality Index Using Three Methods. *PLoS ONE*, 9(8), e105981.

Nelson, D. W., & Sommers, L. E. (1996). Total carbon, organic carbon, and organic matter. In D. L. Sparks (Ed.), *Methods of Soil Analysis. Part 3—Chemical Methods* (pp. 961–1010). Madison, WI: Soil Science Society of America.



Oldfield, E. E., Eagle, A. J., Rubin, R. L., Rudek, J., Sanderman, J., & Gordon, D. R. (2021). Agricultural soil carbon credits: Making sense of protocols for carbon sequestration and net greenhouse gas removals. *Environmental Defense Fund*. <https://www.edf.org/sites/default/files/content/agricultural-soil-carbon-credits-protocol-synthesis.pdf>.

Oliver, M. A., & Webster, R. (2014). A tutorial guide to geostatistics: Computing and modelling variograms and kriging. *Catena*, *113*, 56-69. <https://doi.org/10.1016/j.catena.2013.09.006>.

Panagos, P., De Rosa, D., Liakos, L., Labouyrie, M., Borrelli, P., Ballabio, C., 2024. [Soil bulk density assessment in Europe](#). *Agriculture, Ecosystems & Environment* **364**: 108907. <https://doi.org/10.1016/j.agee.2024.108907>

Pastor, M., Humanes, M. D., & Orgaz, F. (2007). *Productivity and evapotranspiration of irrigated olive orchards in Andalusia (Spain)*. *Agricultural Water Management*, *87*(3), 233-243. <https://doi.org/10.1016/j.agwat.2006.06.013>.

Paul, E. et al. (2001). Modelado del tiempo de residencia en horizontes profundos. *Soil Biology & Biochemistry*, *33*(7), 901-914.

Pereira, G. W., Valente, D. S. M., Queiroz, D. M. d., Coelho, A. L. d. F., Costa, M. M., & Grift, T. (2022). Smart-Map: An open-source QGIS plugin for digital mapping using machine learning techniques and ordinary kriging. *Agronomy*, *12*(6), 1350. <https://doi.org/10.3390/agronomy12061350>

Poepflau, C., & Don, A. (2015). Carbon sequestration in agricultural soils via cultivation of cover crops - A meta-analysis. *Agriculture, Ecosystems & Environment*, *200*, 33-41. <https://doi.org/10.1016/j.agee.2014.10.024>.

Robinson, N. J., Benke, K. K., & Norng, S. (2015). Identification and interpretation of sources of uncertainty in soils change in a global systems-based modelling process. *Soil Research*, *53*, 592-604. <https://doi.org/10.1071/SR14239>.

Rodríguez Martín, J. A., et al. (2016). Assessment of the soil organic carbon stock in Spain. *Geoderma*, *264*, 117-125.

Sánchez-Navarro, A., Gil-Vázquez, J. M., Delgado-Iniesta, M. J., Marín-Sanleandro, P., Blanco-Bernardeau, A., & Ortiz-Silla, R. (2015). Establishing an index and identification of limiting parameters for characterizing soil quality in Mediterranean ecosystems. *Catena*, *131*, 35-45.

Sanderman, J., Hengl, T., & Fiske, G. J. (2017). Soil carbon debt of 12,000 years of human land use. *Proceedings of the National Academy of Sciences*, *114*(36), 9575-9580. <https://doi.org/10.1073/pnas.1706103114>.

Schiedung, H., Bornemann, L., & Welp, G. (2017). Seasonal variability of soil organic carbon fractions under arable land. *Pedosphere*, *27*(2), 380-386. [https://doi.org/10.1016/S1002-0160\(17\)60326-6](https://doi.org/10.1016/S1002-0160(17)60326-6).



Serrano-Notivolí, R., Saz, M. Á., Longares, L. A., & de Luis, M. (2024). *SiCLIMA: High-resolution hydroclimate and temperature dataset for Aragón (Northeast Spain)*. *Data in Brief*. <https://doi.org/10.1016/j.dib.2024.110876>.

Sykes, A. J., Macleod, M., Eory, V., Rees, R. M., Payen, F., Myrgiotis, V., . . . Smith, P. (2020). Characterising the biophysical, economic and social impacts of soil carbon sequestration as a greenhouse gas removal technology. *Global Change Biology*, 26(3), 1085–1108. <https://doi.org/10.1111/gcb.14844>.

Taylor, P. D., Ramsey, M. H., & Potts, P. J. (2005). Spatial contaminant heterogeneity: Quantification with scale of measurement at contrasting sites. *Journal of Environmental Monitoring*, 7(12), 1364–1370. <https://doi.org/10.1039/b509565g>.

Triantafyllidis, V., Kontogeorgos, A., Kosma, C., & Patakas, A. (2019). An assessment of the soil quality index in a Mediterranean agro ecosystem. *Emirates Journal of Food and Agriculture*. <https://doi.org/10.9755/ejfa.2018.v30.i12.1886>.

Tocados-Franco, E., Berbel, J., & Expósito, A. (2023). *Water policy implications of perennial expansion in the Guadalquivir River Basin (southern Spain)*. *Agricultural Water Management*, 108286. <https://doi.org/10.1016/j.agwat.2023.108286>.

Wendt, J. W., & Hauser, S. (2013). An equivalent soil mass procedure for monitoring soil organic carbon in multiple soil layers. *European Journal of Soil Science*, 64(1), 58–65. <https://doi.org/10.1111/ejss.12002>.

Xiong, X., Lyu, M., Deng, C., Li, X., Lu, Y., Lin, W., Jiang, Y., & Xie, J. (2022). Carbon and nitrogen availability drives seasonal variation in soil microbial communities along an elevation gradient. *Forests*, 13(10), Article 1657. <https://doi.org/10.3390/f13101657>.

Zou, X. M., Ruan, H. H., Fu, Y., Yang, X. D., & Sha, L. Q. (2005). Estimating soil labile organic carbon and potential turnover rates using a sequential fumigation–incubation procedure. *Soil Biology & Biochemistry*, 37(10), 1923–1928. <https://doi.org/10.1016/j.soilbio.2005.02.028>.