

UNIVERSIDAD COMPLUTENSE DE MADRID
FACULTAD DE GEOGRAFÍA E HISTORIA

Máster en Tecnologías de la Información Geográfica



TRABAJO FIN DE MÁSTER

**INTEGRACIÓN DE MODELOS FÍSICOS Y
GEOESTADÍSTICA PARA LA ESTIMACIÓN DE LA
HUMEDAD SUPERFICIAL DE SUELOS AGRARIOS
EN AMBIENTES SEMIÁRIDOS CON SENTINEL-1**

**The combination of physical and geostatistical models
for assessing surface moisture in semiarid agricultural
soils with Sentinel-1.**

Estudiante: Álvaro Arroyo Segovia

Tutor: Adrián Fernández Sánchez

Madrid, enero de 2026

RESUMEN: La humedad superficial es uno de los factores más importantes a nivel ecológico y de mayor variabilidad espacio-temporal. La estimación de la humedad del suelo en zonas semiáridas presenta dificultades por esa variabilidad, por la amplitud de los cambios día-noche y por la escasez de mediciones *in situ*. La medición desde sensores aerotransportados también contiene limitaciones dadas las interferencias de la nubosidad y vegetación.

Los sensores Synthetic Aperture Radar (SAR), como Sentinel-1, superan estas restricciones al operar en la parte del Espectro Electromagnético correspondiente a las microondas y ofrecer alta resolución, permitiendo la aplicación de modelos semiempíricos inversos que estiman la humedad (Hallikainen para la constante dieléctrica y Dubois para la retrodispersión).

El presente estudio propone una metodología integrada en el municipio de Villaconejos (Madrid) durante el periodo 2015-2025. Se calibró inicialmente en una parcela piloto próxima a Balcón del Tajo utilizando mediciones de campo y datos edáficos de la plataforma SoilGrids (arena y arcilla). A partir de la retrodispersión VV de Sentinel-1, se invierte el modelo combinado Hallikainen-Dubois mediante una iteración de valores de humedad volumétrica ($0,02-0,45 \text{ m}^3/\text{m}^3$) y rugosidad superficial ($0,85-2 \text{ cm}$), seleccionando la pareja de valores que minimiza la diferencia con la señal observada. La metodología se interpola al municipio de Villaconejos mediante el modelo geoestadístico Empirical Bayesian Kriging Regression Prediction (EBK-RP), incorporando covariables topográficas (MDT, pendiente, orientación), hidrológicas (TWI) y vegetales (NDVI).

Los resultados incluyen mapas anuales y estacionales de humedad volumétrica superficial ($0-5 \text{ cm}$) a 10 m y a 2 m , tras realizar un downscaling geoestadístico de resolución espacial. También, análisis de variaciones entre períodos húmedos y secos y patrones espaciales asociados al uso del suelo y la topografía. La metodología desarrollada permite obtener estimaciones continuas y detalladas de humedad del suelo de forma operativa y de bajo coste, constituyendo una herramienta útil para la gestión del agua y la monitorización agroambiental en regiones semiáridas.

PALABRAS CLAVE: Humedad del suelo; Synthetic Aperture Radar; Sentinel-1; Hallikainen; Dubois; EBK Regression Prediction; Desescalado; Geoestadística.

ABSTRACT: Surface moisture is one of the most important ecological factors and one of those with the greatest spatio-temporal variability. Estimating soil moisture in semi-arid areas is challenging due to this variability, the wide range of day-night changes, and the scarcity of *in situ* measurements. Measurements from airborne sensors also have limitations due to interference from cloud cover and vegetation.

Synthetic Aperture Radar (SAR) sensors, such as Sentinel-1, overcome these constraints by operating in the microwave portion of the electromagnetic spectrum and providing high spatial resolution, which allows the application of inverse semi-empirical models to estimate soil moisture (Hallikainen for the dielectric constant and Dubois for backscatter).

This study proposes an integrated methodology applied in the municipality of Villacañeros (Madrid) during the period 2015–2025. It was initially calibrated on a pilot plot near Balcón del Tajo using field measurements and soil data from the SoilGrids platform (sand and clay content). Based on Sentinel-1 VV backscatter, the combined Hallikainen–Dubois model is inverted through an iteration of volumetric soil moisture values ($0.02\text{--}0.45\text{ m}^3/\text{m}^3$) and surface roughness ($0.85\text{--}2\text{ cm}$), selecting the pair of values that minimizes the difference with the observed signal. The methodology is then interpolated to the municipality of Villacañeros using the geostatistical model Empirical Bayesian Kriging Regression Prediction (EBK-RP), incorporating topographic covariates (DEM, slope, aspect), hydrological variables (TWI), and vegetation indices (NDVI).

The results include annual and seasonal maps of surface volumetric soil moisture ($0\text{--}5\text{ cm}$) at 10 m and 2 m resolution, following a geostatistical downscaling of spatial resolution. They also include analyses of variations between wet and dry periods and spatial patterns associated with land use and topography. The developed methodology enables the generation of continuous and detailed soil moisture estimates in an operational and low-cost manner, constituting a useful tool for water management and agro-environmental monitoring in semi-arid regions.

KEY WORDS: Soil moisture; Radar images; Sentinel-1; Hallikainen model; Dubois model; EBK Regression Prediction; downscaling.

Agradecimientos

Quiero agradecer este trabajo a mi familia y pareja por la paciencia que han tenido conmigo durante todos estos meses, y por su comprensión en los momentos más arduos y delicados que he tenido.

Por supuesto, también quiero agradecer este trabajo a mi tutor Adrián, por el esfuerzo y tiempo que ha tenido que dedicar para poder comprender mis propuestas e ideas, que ni yo mismo soy capaz de plasmar muchas veces.

En definitiva, gracias a todos aquellos que me han apoyado y entendido en este año difícil de compaginar.

Índice

| | | |
|--------|--|----|
| 1. | Introducción | 9 |
| 1.1. | La humedad del suelo y su papel en los procesos ambientales | 9 |
| 1.2. | Problemática: dificultades para medir la humedad del suelo | 9 |
| 1.3. | La teledetección como alternativa para la estimación de la humedad del suelo ... | 9 |
| 1.4. | Teledetección radar (SAR) para la estimación de la humedad del suelo | 10 |
| 1.5. | Justificación del estudio y área de estudio | 11 |
| 1.6. | Alcance y enfoque del estudio | 11 |
| 1.7. | Objetivos del estudio..... | 11 |
| 1.8. | Hipótesis de trabajo | 12 |
| 2. | Marco teórico..... | 12 |
| 2.1. | Humedad superficial del suelo: definición, importancia y dinámica | 13 |
| 2.2. | Degradación de suelos agrícolas en zonas semiáridas..... | 14 |
| 2.3. | Influencia del cambio climático en la humedad del suelo | 14 |
| 2.4. | Estimación de humedad con sensores remotos | 15 |
| 2.5. | Ventajas del radar SAR para suelos agrícolas | 17 |
| 2.5.1. | Modelo semiempíricos para la estimación de humedad del suelo | 17 |
| 3. | Área de estudio | 19 |
| 3.1. | Localización y delimitación..... | 19 |
| 3.1.1. | Caracterización geológica y edáfica | 21 |
| 3.1.2. | Cobertura vegetal y usos del suelo..... | 22 |
| 3.1.3. | Hidrología | 25 |
| 4. | Materiales y métodos | 25 |
| 4.1. | Fuentes de datos | 26 |
| 4.1.1. | Imágenes Sentinel-1..... | 27 |
| 4.1.2. | SoilGrids | 27 |
| 4.1.3. | Variables explicativas..... | 28 |
| 4.2. | Preprocesamiento de imágenes Sentinel-1 | 29 |
| 4.2.1. | Transformación de decibelios y homogenización de datos | 30 |
| 4.3. | Interpretación de las imágenes | 30 |
| 4.4. | Selección de periodos húmedos y secos..... | 31 |
| 4.5. | Estimación de parámetros físicos | 32 |
| 4.5.1. | Obtención de la constante dieléctrica (Modelo Hallikainen) | 32 |
| 4.5.2. | Aplicación del Modelo de Dubois..... | 33 |
| 4.6. | Análisis espacial entre la humedad superficial y variables explicativas | 35 |

| | | |
|--------|---|----|
| 4.7. | Modelización estadística: regresión OLS..... | 35 |
| 4.8. | Desescalado por técnicas geoestadísticas: Empirical Bayesian Krigging Regression Prediction | 36 |
| 4.9. | Caracterización de las Estimaciones de Humedad, Rugosidad y Retrodispersión | 37 |
| 4.9.1. | Distribución de Humedad por Rugosidad y Período | 37 |
| 4.9.2. | Análisis de Variaciones del Período Seco y Húmedo..... | 37 |
| 4.9.3. | Correlación Retrodispersión vs. Rugosidad Estimada..... | 37 |
| 5. | Resultados | 38 |
| 5.1. | Mapas de humedad superficial (2015-2025)..... | 38 |
| 5.2. | Análisis de la relación espacial entre la humedad superficial y variables explicativas | 40 |
| 5.3. | Evaluación del modelo OLS | 40 |
| 5.4. | Resultados a escala municipal..... | 41 |
| 5.5. | Análisis de variaciones por periodo seco y húmedo | 43 |
| 5.6. | Relación entre retrodispersión, rugosidad y humedad | 44 |
| 6. | Discusión | 45 |
| 6.1. | Posibles mejoras y perspectivas futuras | 51 |
| 6.2. | Limitaciones de los modelos empleados | 53 |
| 7. | Conclusiones..... | 55 |
| 8. | Referencias bibliográficas..... | 57 |
| 9. | Anexos | 66 |
| 9.1. | Imágenes descargadas..... | 66 |
| 9.2. | Datos de permeabilidades en el área de estudio | 67 |
| 9.3. | Datos de precipitación AEMET | 67 |
| 9.4. | Coeficientes del Modelo de Hallikainen | 69 |
| 9.5. | Script VBA para el emparejamiento de retrodispersión observada y estimada | 69 |
| 9.6. | Tabla resultados OLS | 71 |

1. Introducción

1.1. La humedad del suelo y su papel en los procesos ambientales

Los suelos constituyen el soporte fundamental de los procesos ecológicos que regulan el desarrollo de la vegetación y la dinámica faunística. En ellos se integran procesos físicos, químicos y biológicos que condicionan la disponibilidad de recursos como serían el agua y los nutrientes.

Este trabajo se centra en una de las características más importantes a nivel edáfico, la humedad superficial. Dicha humedad es primordial para conocer, prevenir y optimizar el crecimiento de los cultivos y su rentabilidad económica, pero también para monitorear la degradación de los suelos y la desertificación (Álvarez-Mozos et al., 2005; Vicente-Serrano et al., 2015) como consecuencia de las malas prácticas agrarias o el cambio climático. En zonas semiáridas del Mediterráneo, este factor se vuelve muy importante debido al actual calentamiento global, donde las lluvias irregulares, las sequías largas y la erosión, junto a la desertificación, suponen un peligro cada vez mayor para la producción agraria y el cuidado del entorno.

En este contexto, la humedad superficial del suelo funciona como un factor integrador, que refleja las condiciones de infiltración, evaporación, uso del suelo y gestión agronómica. Además, es un elemento crucial para la salud del suelo y las posibilidades de resiliencia a los cambios globales que se están produciendo en el clima y las prácticas tradicionales.

1.2. Problemática: dificultades para medir la humedad del suelo

Históricamente, la evaluación de la humedad del suelo se ha fundamentado en métodos *in situ*, tales como sensores de capacitancia, tensiómetros o métodos de gravimetría. Una tecnología muy utilizada en esta clase de estudios es el TDR (*Time Domain Reflectometry*). Aunque son exactos, no poseen la representatividad espacial y temporal necesaria para describir dinámicas extensas del territorio, ya que, dependen de la toma de muestras manuales y el desplazamiento físico de un técnico en muestreo. En este escenario, la teledetección por satélite emerge como un instrumento esencial para tratar este problema de manera no intrusiva y multiescalar (Álvarez-Mozos et al., 2005; Salgado et al., 2021; Singh et al., 2020). La tecnología de sensores de microondas activos, como el radar, se muestra como una herramienta eficaz para el monitoreo del grado de humedad superficial, en el rango de 0 a 10 cm de profundidad, de los suelos (Salgado, 1998).

1.3. La teledetección como alternativa para la estimación de la humedad del suelo

La teledetección por satélite y los Sistemas de Información Geográfica tienen en conjunto un gran potencial para la investigación tanto científica como humana. Gracias a portales como Sentinel Hub (Sinergise Solutions d.o.o., s.f.), o programas públicos como Landsat, Instituto Geográfico Nacional, o softwares abiertos como QGIS o SNAP, hoy en día es muy sencillo poder realizar análisis de observación de la Tierra en un ordenador de baja capacidad. Es posible integrar tanto la disciplina humanística como la científica dentro de

los objetivos de análisis de las tecnologías de información geográfica. Con ellas es posible mejorar sistemas de riego (Gaznayee et al., 2023) e incluso descubrir antiguos canales de agua de civilizaciones del pasado (Kim, 2023). Respecto a la teledetección, es un campo que ha permitido monitorear cambios en la cobertura terrestre, predecir los posibles daños por inundaciones o dentro del campo de la agricultura de precisión, mejorar la eficacia de los cultivos y su adaptación al cambio climático. Todo ello, a un bajo coste, con mayor precisión y sin tener que trabajar sobre el terreno en la zona de estudio.

La evaluación de la humedad del suelo a través de sensores remotos es una disciplina en constante cambio dentro de la teledetección aplicada. Los últimos avances se han realizado sobre, modelos físicos, semiempíricos y empíricos que posibilitan simular o modificar la correlación entre la retrodispersión radar y las condiciones del suelo. La capacidad de llevar a cabo análisis multitemporales y generar series de humedad históricas mediante imágenes Sentinel-1, facilita el estudio de las condiciones presentes del suelo, de las tendencias de degradación, las modificaciones en los patrones de empleo del suelo y las adaptaciones de los cultivos a las condiciones meteorológicas.

Por eso, la posibilidad de medir la humedad del suelo a gran escala desde satélites, con una cobertura frecuente y completa de la superficie terrestre, es especialmente atractiva para la comunidad científica.

1.4. Teledetección radar (SAR) para la estimación de la humedad del suelo

El satélite Sentinel-1, que forma parte del programa Copernicus (Agencia Espacial Europea [ESA], s.f.), proporciona información de radar en banda C (4-8 GHz, 5 cm) con una resolución espacial de 10 m, y temporal de 6 días (Copernicus SentiWiki, s.f.). Esas características son apropiadas para el monitoreo regular de la humedad superficial del terreno, e incluso en situaciones de nubosidad u oscuridad, lo que supone un beneficio considerable en comparación con los sensores ópticos. La polarización VV (orientación del campo eléctrico de la onda electromagnética, en este caso vertical-vertical) junto con la geometría de adquisición de Sentinel-1 ofrecen datos valiosos para la caracterización geométrica y dieléctrica del terreno, factores que están entre otros, directamente vinculados con la humedad del suelo (Buah et al., 2020; El Hajj et al., 2017).

La precisión de las estimaciones de Sentinel 1, considerando su amplia variabilidad espacial y temporal, resulta fundamental para estudios y tareas ambientales y/o agrícolas, contribuyendo, entre otras aplicaciones, al monitoreo del estado hídrico de suelos en producción agrícola (Salgado et al., 2021).

Las posibilidades que ofrecen los sensores remotos como Sentinel-1 para estimar la humedad superficial a partir de imágenes satelitales resulta de gran utilidad, ya que permiten obtener información distribuida espacialmente y con una cierta regularidad. La teledetección posibilita el seguimiento del rendimiento sobre áreas de gran tamaño y durante periodos de tiempo regulares.

Este trabajo parte de la necesidad de desarrollar una metodología validable y repetible para estimar la humedad superficial del suelo en paisajes agrícolas mediterráneos a partir de imágenes Sentinel-1, como las de Ma et al. (2021) o Graldi et al. (2023) en sus artículos.

1.5. Justificación del estudio y área de estudio

Al considerar las particularidades edafológicas del sureste de la Comunidad de Madrid, la erosión y los procesos de desertificación están siendo más notables que en otras regiones de la península ibérica (Salgado, 1998). Es por ello por lo que el área de estudio se centra en el municipio de Villacanejos, donde predominan los olivares, cultivos de secano, matorrales y zonas de suelo desnudo a la vez de unas prácticas agrarias cuestionables desde el punto de vista de la conservación del suelo.

Este estudio busca contribuir a la comprensión de cómo los usos y prácticas agrarias influyen en las dinámicas de evapotranspiración y en los procesos de erosión del suelo en entornos agrícolas semiáridos. La estimación de la humedad superficial del suelo mediante técnicas de teledetección resulta especialmente adecuada en este tipo de contextos, ya que la escasa cobertura vegetal y la elevada variabilidad espacial y temporal de la humedad favorecen una respuesta más directa de la señal remota frente a las condiciones del suelo. En este contexto, el municipio de Villacanejos (Comunidad de Madrid) ofrece un escenario especialmente adecuado para aplicar y evaluar estas metodologías, debido al predominio de cultivos de secano, olivares y áreas de suelo desnudo, así como a su marcada susceptibilidad a procesos de degradación.

Los resultados de este trabajo pueden aportar información útil para orientar estrategias de conservación del suelo y promover una gestión agraria más sostenible alineadas con los objetivos del Pacto Verde Europeo o la Estrategia Nacional de Lucha contra la Desertificación (Comisión Europea, 2019; Ministerio para la Transición Ecológica y el Reto Demográfico, 2025).

1.6. Alcance y enfoque del estudio

La metodología y las tareas secundarias propuestas se basan en un flujo de trabajo integrador que combina elementos de distintas metodologías habitualmente empleadas de forma independiente. Este enfoque incluye tanto el uso e inversión de modelos semiempíricos para la estimación de la humedad superficial del suelo como la aplicación de técnicas geoestadísticas orientadas al incremento de la resolución espacial de las estimaciones obtenidas.

1.7. Objetivos del estudio

El objetivo principal de este estudio es desarrollar e implementar una metodología basada en teledetección radar, utilizando imágenes Sentinel-1 para estimar, de forma multitemporal, la humedad superficial del suelo.

El análisis se centra en terrenos yermos o desnudos, principalmente situados en el municipio de Villacanejos (Comunidad de Madrid) y sus alrededores.

La metodología combina el uso de modelos semiempíricos y procesamientos SIG, con el fin de evaluar su aplicabilidad en entornos agrícolas afectados por procesos de sequía y degradación del suelo.

Además, se plantean varios objetivos secundarios, entre los que destacan:

- Evaluar la sensibilidad de la rugosidad superficial del suelo en la estimación de humedad radar.
- Emplear modelos semiempíricos para estimar la humedad superficial a partir de la retrodispersión radar.
- Realizar análisis multitemporales de la humedad para años secos y húmedos (2015, 2017, 2019, 2021, 2023, 2025) para observar tendencias de degradación.
- Correlacionar la multitemporalidad con patrones de origen climático.
- Realizar métodos de incremento de la resolución espacial en base a variables físico-ambientales (desescalado por interpolación).

1.8. Hipótesis de trabajo

Las principales hipótesis con las que se ha trabajado en este TFM han sido:

- La retrodispersión radar con polarización VV de imágenes Sentinel-1 puede estimarse adecuadamente mediante modelos semiempíricos e inversos para estimar la humedad superficial en suelos agrícolas semiáridos.
- La incorporación de variables auxiliares como la rugosidad del terreno mejora significativamente la precisión de los modelos de estimación.
- El análisis multitemporal permite identificar patrones de sequía, recuperación y degradación edáfica a nivel de parcela.
- Los modelos geoestadísticos pueden ayudar a reducir la resolución de los productos de estimación de la humedad del suelo.

2. Marco teórico

En el contexto de los sistemas agrícolas en regiones semiáridas, la disponibilidad de agua en el suelo, y en concreto en la zona de desarrollo radicular de los cultivos, que es la capa superficial del suelo donde las raíces extraen la mayor parte del agua y nutrientes, es fundamental para el pronóstico de rendimientos (Salgado, 1998). Constituye uno de los factores más limitantes para la producción agronómica, el desarrollo de la vegetación natural y la estabilidad ecológica del territorio. La humedad superficial del suelo (HS), indicadora principalmente del agua en estado líquido en la zona no saturada, juega un rol decisivo en el ciclo hidrológico, participando activamente en los flujos del Carbono, que representan el intercambio de CO₂ y otros compuestos de carbono entre el suelo y la atmósfera (Salgado et al., 2021). Su evaluación es crucial no solo para la agricultura de precisión y la gestión de recursos hídricos, sino también para el estudio de procesos de degradación del suelo, desertificación y vulnerabilidad frente al cambio climático.

El presente marco teórico se orienta a contextualizar conceptual y metodológicamente la estimación de la humedad del suelo mediante técnicas de teledetección radar, especialmente

a través de los sensores Sentinel-1, y con el apoyo de modelos semiempíricos que permiten vincular la retrodispersión radar con los parámetros dieléctricos y geométricos del terreno (Salgado et al., 2021).

2.1. Humedad superficial del suelo: definición, importancia y dinámica

La humedad del suelo es la cantidad de agua que queda atrapada entre los espacios o poros del material edáfico o sedimentario (*imagen 2*). Esta agua se mantiene ahí gracias a la atracción entre las partículas de suelo y el agua (*imagen 3*), y a la unión del agua con los minerales y la materia orgánica (Porta Casanellas et al., 2019). Es posible medirla de dos maneras: como cantidad de agua en un volumen de suelo (contenido volumétrico, en m^3/m^3) o como cantidad de agua en relación con el peso del suelo (contenido gravimétrico, en kg/kg) (Hillel, 2004). En teledetección, normalmente se usa la medida volumétrica.

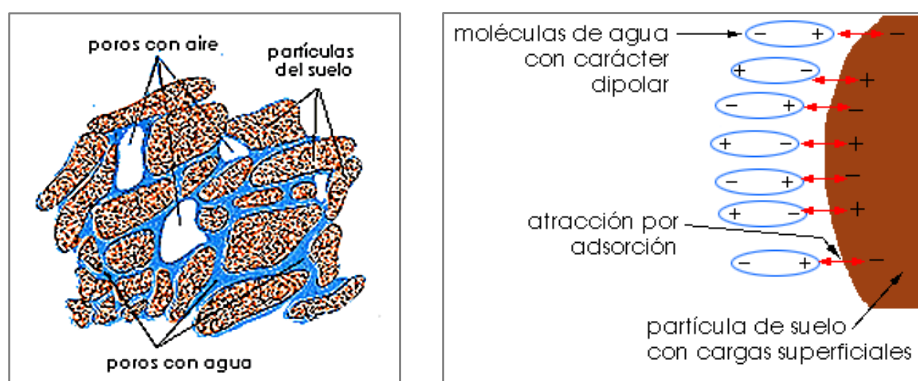


Imagen 1 y 2. Circulación de la fase líquida del suelo. Fuente: *Introducción a la Edafología*, por C. Dorronsoro, s.f. (<http://edafologia.ugr.es/introeda/tema00/progr.htm>).

Desde el punto de vista físico, se distingue entre distintas capas de humedad (Entekhabi, D., et al, 2010):

- **Humedad superficial:** comprendida entre los primeros 0–5 cm del suelo. Esta capa es la más afectada por la evaporación, precipitación reciente y dinámica superficial.
- **Humedad radicular:** entre 5–100 cm, donde se desarrolla el sistema radicular de la mayoría de los cultivos.
- **Humedad profunda:** por debajo del metro de profundidad, relacionada con reservas freáticas o de largo plazo.

Este estudio se enfoca en la humedad de la capa superficial del suelo, ya que es la parte más fácil de medir con sensores remotos y la que más rápido refleja los cambios recientes del clima. Además, sirve como un indicador a corto plazo del balance de agua en el suelo, lo que influye directamente en la germinación, el desarrollo de las raíces, la transpiración y el aprovechamiento del agua por los cultivos (Jackson et al., 1996).

La dinámica de la humedad superficial del suelo está influida por múltiples factores:

- Tipo y textura del suelo (proporciones de arena, limo y arcilla).
- Materia orgánica y capacidad de campo.
- Cobertura vegetal y transpiración.
- Evaporación directa.

- Precipitaciones, riego y escorrentía.
- Topografía (pendiente y orientación).
- Compactación o encostramiento del suelo.

2.2. Degradación de suelos agrícolas en zonas semiáridas

Según la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO, 2015), la degradación del suelo se define como la pérdida parcial o total de su capacidad productiva, biológica y funcional, como resultado de procesos físicos, químicos o biológicos, ya sea por causas naturales o antrópicas. En las regiones semiáridas, donde las precipitaciones son escasas, irregulares y estacionalmente concentradas, el suelo está particularmente expuesto a procesos de erosión hídrica, compactación, salinización, pérdida de materia orgánica y disminución de su capacidad de retención hídrica (FAO, 2015).

Diversos estudios como los de García-Ruiz et al. (2013) o Ferreira et al. (2022) han mostrado que, en el sur de Europa, especialmente en zonas mediterráneas y semiáridas, los suelos se están deteriorando rápidamente. Entre las causas principales están el avance de la agricultura intensiva, el abandono de tierras agrícolas, la sobreexplotación de los acuíferos y el aumento de fenómenos climáticos extremos. En la Comunidad de Madrid, y en particular en la Comarca de Las Vegas donde se sitúa el municipio de Villacañete, este deterioro se traduce en la pérdida de suelos fértiles, menor capacidad de infiltración del agua, aparición de costras y cárcavas en la superficie del suelo y una reducción de la humedad disponible para cultivos tradicionales como el olivo, los cereales de secano o la vid (Cruz Maceín & Benito Barba, 2014).

Cuando el suelo se degrada físicamente, pierde su estructura, sus poros y su capacidad para absorber agua. Eso hace que el agua de lluvia o de riego no se infiltre bien y genere escorrentía por la superficie (Hillel, 2004). Como resultado, se aprovecha menos el agua disponible y los cultivos se vuelven más vulnerables durante las sequías.

2.3. Influencia del cambio climático en la humedad del suelo

El informe del Panel Intergubernamental del Cambio Climático (IPCC, 2021) indica que el cambio climático actual está generando transformaciones significativas en los ciclos hidrológicos globales, regionales y locales. Entre los impactos más evidentes en regiones mediterráneas y semiáridas se encuentran el aumento de las temperaturas medias, pero también la reducción de las precipitaciones y la intensificación de eventos extremos de tipo sequías, olas de calor y lluvias torrenciales (IPCC, 2021).

Estos cambios afectan directamente a la humedad del suelo, de hecho, investigaciones en sistemas agrícolas mediterráneos han demostrado que la cantidad de agua en la capa superficial del suelo se encuentra por debajo de su capacidad durante gran parte del año (Jiménez-de-Santiago et al., 2019), y que en situaciones con menores lluvias y más días secos, la humedad del suelo presenta disminuciones marcadas, lo que limita la disponibilidad de agua para los cultivos en momentos clave de su desarrollo (Mimeau et al., 2021).

Por otro lado, el incremento de lluvias de carácter torrencial, sumado a esas aridificaciones y alteraciones de biomasa, puede incrementar la erosión del suelo y llegar a perderse los

primeros niveles edáficos que son muy importantes en la infiltración del agua (Zhao et al., 2024). Aun así, algunos autores han debatido que las precipitaciones extremas reduzcan la humedad del suelo, pues esta podría ser parte de la recarga de acuíferos y de los primeros niveles edáficos (Huang et al., 2024).

En la Península Ibérica, las proyecciones indican que para finales del siglo XXI el contenido de humedad del suelo podría reducirse entre un 10 % y un 30 % bajo escenarios de emisiones intermedias y altas, como el RCP 4.5 y el RCP 8.5 (IPCC, 2021). Esta reducción de humedad supondría una mayor frecuencia e intensidad de la sequía agrícola, lo que afecta sobre todo a cultivos de secano como los cereales y el olivar, muy comunes en la Comarca de Las Vegas, donde se sitúa el municipio de Villacanejos (IPCC, 2021; Cruz Maceín & Benito Barba, 2014).

El cambio climático también está modificando el calendario de la humedad del suelo. El periodo húmedo se acorta y la fecha en la que el suelo agota su agua llega antes, lo que provoca un desfase entre cuándo hay agua disponible y cuándo los cultivos más la necesitan.

2.4. Estimación de humedad con sensores remotos

La humedad superficial del suelo presenta una elevada variabilidad espacial, incluso a escalas reducidas, condicionada por factores como la textura del suelo, la rugosidad superficial, la topografía y las condiciones meteorológicas recientes. Esta heterogeneidad provoca que las mediciones locales de humedad no siempre sean representativas de áreas más extensas. En teledetección radar, la estimación de la humedad del suelo se apoya en modelos de dispersión electromagnética, tanto empíricos como semiempíricos y físicos, entre los que destacan los modelos de Oh (Oh et al., 1992; Oh, 2004), Dubois (Dubois et al., 1995) y Shi (Shi et al., 1997), así como el modelo de Ecuación Integral (IEM) (Fung et al., 1992) y su versión mejorada, el MEI (Chen et al., 2015). No obstante, la aplicación de estos modelos en grandes áreas resulta compleja, ya que asumen condiciones relativamente homogéneas.

En las últimas décadas, la observación remota de la humedad del suelo ha avanzado notablemente gracias al desarrollo de sensores activos y pasivos instalados en satélites y otras plataformas aéreas como los UAV (Unmanned Aerial Vehicle) o los HAPS (High Altitudes Pseudo Satellite). A diferencia del muestreo en campo, que ofrece gran precisión, pero poca cobertura espacial y temporal, los sensores remotos permiten generar mapas continuos, actualizados y multitemporales de la humedad del suelo.

La medida directa de humedad superficial mediante sensores instalados en campo (como sondas TDR-Time-Domain Reflectometry, FDR-Frequency Domain Reflectometry o tensiómetros) es limitada por:

- Su alta dependencia logística y necesidad de mantenimiento.
- La escasa cobertura espacial (puntos aislados que no representan áreas extensas).
- La dificultad para capturar dinámicas temporales si no se dispone de estaciones automáticas.

- Los altos costes económicos en el caso de redes densas de sensores.

Por ello, la observación indirecta a través de teledetección, especialmente de tipo radar, permite complementar e incluso sustituir en parte estas observaciones cuando se trata de cubrir grandes extensiones como cuencas hidrográficas o zonas agrícolas regionales.

Esto se debe a que el Radar de Apertura Sintética (SAR) es un sistema de observación activa, independiente de las condiciones atmosféricas y de la iluminación solar, lo que permite la generación de series temporales consistentes. A diferencia de los sensores ópticos, la señal de microondas interactúa directamente con la constante dieléctrica del suelo, que aumenta significativamente con el contenido de humedad debido a las propiedades del agua (Solorza, 2013). Esta característica confiere al coeficiente de retrodispersión una elevada sensibilidad a la humedad superficial, lo que explica la superioridad del SAR frente a los sensores ópticos, los cuales solo reflejan condiciones indirectas como la vegetación o los usos del suelo, tal y como han demostrado diversos estudios (Ulaby et al., 1982; Álvarez-Mozos et al., 2006).

El gráfico 1, muestra la relación positiva entre las dos variables que definen el contenido de humedad en el suelo, la constante dieléctrica y la humedad volumétrica, en diversas frecuencias y distintos tipos de composición granulométrica del suelo (Solorza, 2013).

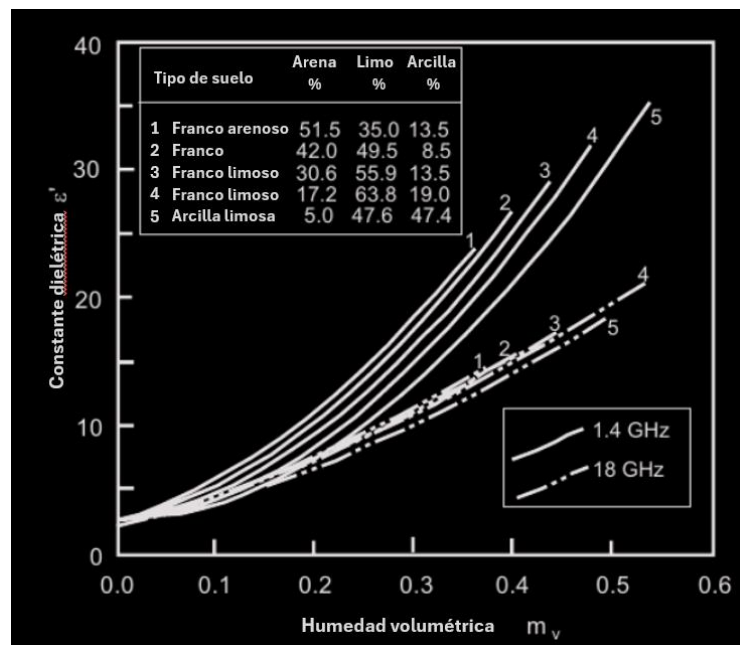


Gráfico 1. Relación entre la constante dieléctrica y el contenido de humedad del suelo (Solorza, 2013).

El patrón de dispersión de una superficie rugosa depende principalmente de su rugosidad superficial, mientras que la intensidad con la que la señal regresa al sensor está modulada por las características dieléctricas, es decir, su cantidad de humedad (Pampaloni & Sarabandi, 2004). Específicamente, las propiedades de rugosidad de la superficie determinarán la "configuración" del patrón de retrodispersión que regresa al sensor (especular, lambertiano, difuso, etc.), mientras que el nivel de humedad en el suelo influirá en la "magnitud" en relación a la reflexión, absorción o transmisión del retorno de la señal (Solorza, 2013).

2.5. Ventajas del radar SAR para suelos agrícolas

La principal ventaja del uso de SAR en la caracterización de la humedad del suelo reside en que las microondas (bandas radar) son el único rango del Espectro Electromagnético que tienen la capacidad de medir de forma cuantitativa la humedad del suelo. Además, las mediciones se realizan bajo diferentes condiciones de relieve y cobertura vegetal (Behari, 2005).

Actualmente, la mayoría de los radares de apertura sintética (SAR) instalados en satélites como RADARSAT-2, COSMO-SkyMed, TerraSAR-X o Sentinel-1 operan en bandas C y X, que no son las más ideales para estimar la humedad del suelo. Aunque algunos estudios recientes muestran que es posible usar estos sensores, especialmente la nueva generación en banda X (Baghdadi et al., 2012), trabajar con frecuencias tan altas implica lidiar con interferencias causadas por la rugosidad del terreno y, sobre todo, por la vegetación, que también influye en la señal de la retrodispersión.

Además, el modo en que una onda radar se refleja o penetra en el suelo depende del ángulo de incidencia (ϕ), es decir, el ángulo entre el haz del radar y la perpendicular a la superficie. Como regla general, cuanto menor es este ángulo, mayor es la penetración de la señal (Salgado et al., 2021).

El satélite Sentinel-1, lanzado por la Agencia Espacial Europea (ESA) en el marco del programa Copernicus, ofrece imágenes en banda C con resoluciones de hasta 10 m y frecuencias de revisita de 6 a 12 días, dependiendo de la cobertura y combinación de órbitas ascendentes y descendentes. Esto permite un monitoreo detallado a escala parcelaria, con una frecuencia adecuada para capturar eventos de riego, lluvia o sequía.

Las microondas en banda C tienen una capacidad de penetración limitada, lo cual es adecuado para capturar señales desde los primeros centímetros del suelo, donde se encuentra la humedad superficial, sin verse afectadas por capas más profundas.

Los datos de Sentinel-1 están disponibles de forma gratuita y abierta, y pueden ser preprocesados con herramientas como SNAP, ArcGIS Pro, o Google Earth Engine. Esto facilita su uso para análisis temporales.

2.5.1. Modelo semiempíricos para la estimación de humedad del suelo

La estimación de humedad superficial del suelo mediante imágenes radar requiere la implementación de modelos que permitan interpretar o invertir la señal de retrodispersión (σ^0) observada en los datos satelitales, transformándola en estimaciones cuantitativas del contenido de agua en el suelo. Para ello, a lo largo de las últimas décadas, se han desarrollado diversos enfoques que pueden agruparse en tres grandes categorías:

- **Modelos físicos**, que simulan la interacción entre la señal radar y la superficie terrestre a partir de principios electromagnéticos.
- **Modelos semiempíricos**, que combinan componentes físicos con ajustes estadísticos basados en datos experimentales.

- **Modelos empíricos**, que establecen relaciones directas entre variables observadas (como retrodispersión y humedad) a través de ajustes matemáticos simples.

Modelos Semi-Empírico: Hallikainen

El modelo de Hallikainen es fundamental para el proceso de inversión, ya que permite la conversión entre la constante dieléctrica (ϵ) y el contenido volumétrico de humedad (θ). Este modelo semiempírico representa la constante dieléctrica como una función polinómica cuadrática (*ecuación 1*), calibrada experimentalmente a partir de un amplio conjunto de mediciones en diferentes tipos de suelos.

$$\epsilon' = (a_0 + a_1S + a_2C) + (b_0 + b_1S + b_2C)m_v + (c_0 + c_1S + c_2C)m_v^2$$

Ecuación 1. *Expresión matemática del modelo de Hallikainen.*

Su principal utilidad radica en la capacidad de integrar la textura del suelo (porcentaje de arena, S, y arcilla, C) directamente en la fórmula. Al conocer estos porcentajes y la frecuencia de la señal radar (válido entre 1.4 y 18 GHz), el modelo de Hallikainen proporciona una forma simple y práctica de estimar el contenido hídrico a partir de la respuesta dieléctrica observada.

Modelo Semi-Empírico: Modelo de Dubois

El modelo de Dubois (Dubois et al., 1995) es un modelo semiempírico optimizado para predecir el coeficiente de retrodispersión (σ^0) en suelos desnudos a partir de la constante dieléctrica del suelo (obtenida típicamente con modelos como el de Hallikainen) y su rugosidad (altura RMS).

Es un modelo muy sensible a la vegetación, a partir de un NDVI > 0.4 subestima la humedad del suelo y sobrestima el nivel de rugosidad (RMS) (Dubois et al., 1995).

Este modelo se diseñó inicialmente utilizando datos de escaterómetros, y es particularmente eficaz cuando se utilizan canales co-polarizados y frecuencias entre 1.5 GHz y 11 GHz. Los mejores resultados se dan con un $kh < 2.5$ (siendo k el número de onda y h el RMS height), una humedad < 35% y un ángulo de incidencia > 30°. A continuación, se muestra la expresión matemática del modelo original, sin adaptaciones:

$$\sigma^0(VV) = 10^{-2.35} \left(\frac{\cos^3 \theta}{\sin^3 \theta} \right) \cdot 10^{0.046\epsilon \tan \theta} (ks \sin \theta)^{1.1} \lambda^{0.7}$$

Ecuación 2. *Expresión matemática del modelo de Dubois.*

VARIABLES QUE AFECTAN A LA OBSERVACIÓN DE LA RETRODISPERSIÓN

La intensidad de la señal radar está condicionada por factores relacionados con la superficie o blanco como la geometría, la rugosidad y la humedad, por las características del sensor (polarización, longitud de onda λ y ángulo de incidencia ϕ) y por la dirección de la órbita del satélite, ya sea ascendente o descendente. La polarización controla la forma en que la onda electromagnética interactúa con la superficie y, en consecuencia, la sensibilidad de la retrodispersión (σ^0) frente a variaciones en la constante dieléctrica (ϵ) (Solorza, 2013).

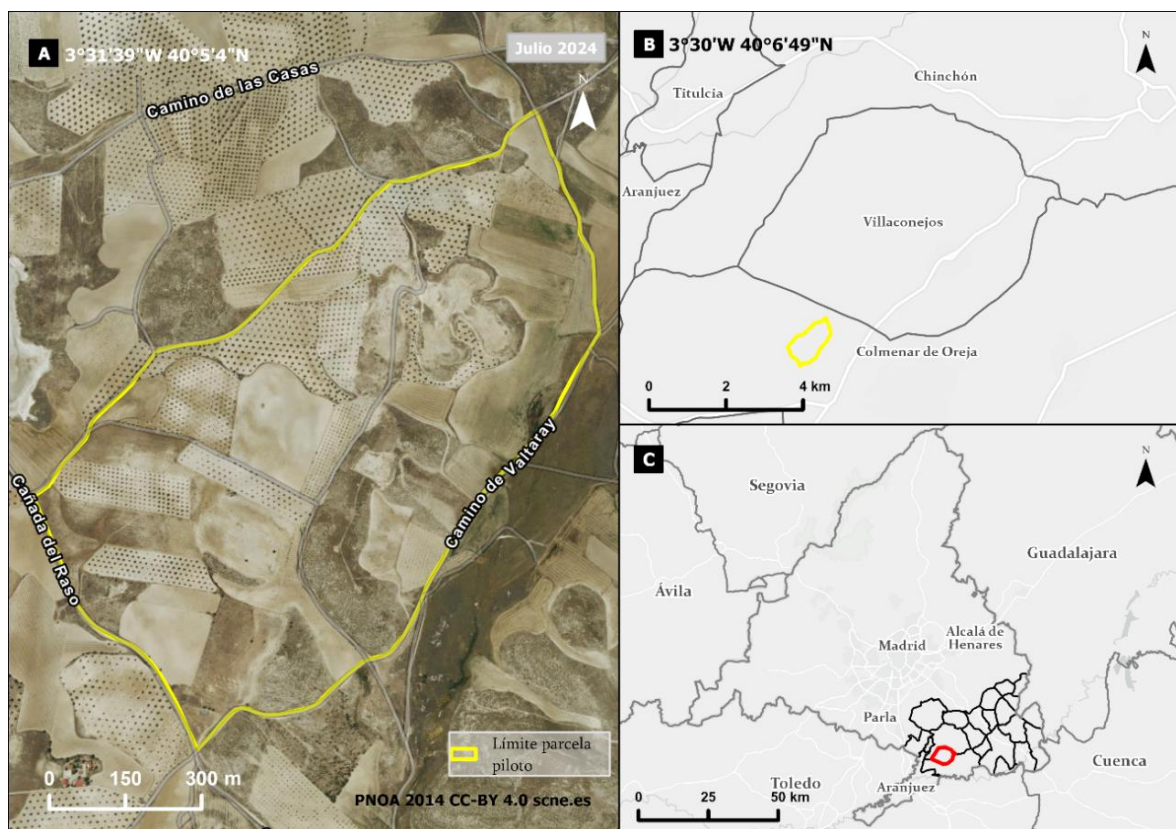
En términos generales, la σ^0 es representativa de la humedad de una capa superficial cuyo espesor depende de la capacidad de penetración de la señal, directamente relacionada con la longitud de onda empleada a mayor λ , mayor penetración, además de verse afectada por la rugosidad del terreno y la cobertura vegetal. En este contexto, la rugosidad superficial debe entenderse como un concepto relativo, ya que depende de la configuración del sistema SAR durante la adquisición, estando especialmente influida por la longitud de onda de la señal incidente (Ulaby et al., 1978).

3. Área de estudio

3.1. Localización y delimitación

El presente trabajo tiene como ámbito de estudio dos unidades territoriales localizadas en el sureste de la Comunidad de Madrid (*mapa 1*):

- Parcela piloto ($3^{\circ} 31' 38'' W 40^{\circ} 5' 4'' N$) situada en las inmediaciones de la urbanización Urtajo y Balcón del Tajo, en el término municipal de Colmenar de Oreja.
- El propio municipio de Villaconejos, como unidad administrativa completa.

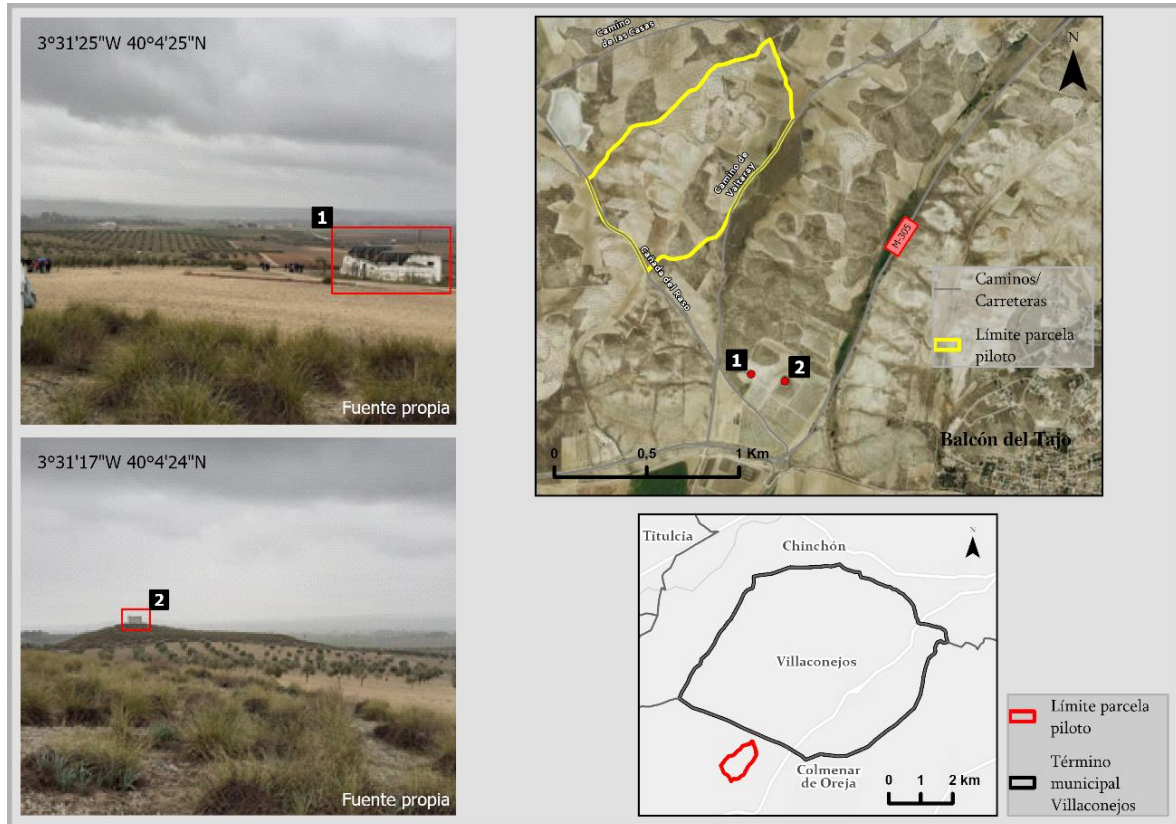


Mapa 1. Localización de la parcela piloto (A), municipio de Villaconejos (B) y Comunidad de Madrid (C).

Ambas localizaciones se sitúan en el sureste de la Comunidad de Madrid. La parcela piloto se ha elegido por cumplir una serie características que consideraba interesantes como: las plantaciones de olivar en secano, suelos calizos y pobres en nutrientes, gran número de

espartales, por presentar una alta erosión hídrica y por conocer la zona de primera mano. Pertenece a la comarca agrícola con la mayor producción de toda la región y la que proporciona una mayor diversidad dentro de los paisajes agrarios debido a los usos del agua que se han hecho. Se encuentra en la región Mediterránea (Pérez Ramírez, 2022).

El municipio de Villaconejos se encuentra en la comarca natural de Las Vegas, limitando con los municipios de Colmenar de Oreja, Chinchón, Aranjuez, Belmonte de Tajo y Titulcia.



Mapa 2. Paisaje del entorno de una parcela cercana a la zona de estudio. Predominan los olivares y espartales. Fuente propia.

El paisaje agrario de esta comarca se caracteriza por un relieve predominantemente ondulado, con pendientes generalmente bajas. Las altitudes oscilan entre un mínimo de aproximadamente 500 m.s.n.m. cerca de los principales cauces fluviales y un máximo cercano a los 840 m.s.n.m. en las zonas de páramo más elevadas (Pérez Ramírez, 2022).

Desde el punto de vista de la clasificación ecológica, Villaconejos se incluye en la unidad de paisaje de la Meseta Sur mediterránea, caracterizada por:

- Clima mediterráneo continentalizado, con precipitaciones anuales en torno a 350–450 mm y temperaturas medias entre 13–15 °C.
- Vegetación potencial compuesta por encinares y coscojares (Ministerio para la Transición Ecológica y el Reto Demográfico [MITECO], 2020), hoy sustituidos por cultivos agrícolas o matorrales.
- Presencia de especies típicas de ambientes semiáridos: retama, esparto, romero, tomillo.

- Suelos con cobertura vegetal discontinua, lo que favorece procesos de erosión y pérdida de humedad superficial.

La unidad ecológica dominante en el entorno del Balcón del Tajo y de Villaconejos se considera de tipo agrario subárido, con importantes implicaciones para la hidrología superficial, el balance hídrico y la respuesta espectral SAR.

3.1.1. Caracterización geológica y edáfica

Desde el punto de vista geológico, Villaconejos se ubica en la unidad estructural de la Submeseta Sur, dentro de la Cuenca del Tajo, sobre sedimentos terciarios y cuaternarios. La litología predominante está compuesta por margas, yesos y arcillas de la época Mioceno (que se extiende desde hace 23 hasta 5.3 millones de años), así como depósitos aluviales recientes, que datan de la época Holoceno (desde hace unos 11.700 años hasta la actualidad). Se encuentran predominantemente rocas detríticas con baja permeabilidad, seguido de evaporíticas de baja permeabilidad y detríticas del cuaternario de muy alta y media permeabilidad normalmente asociadas a valles o cauces (*anexo 9.2*).

En cuanto a los suelos, según el Mapa de Suelos de España (1:1.000.000) del Instituto Geográfico Nacional (IGN), los suelos predominantes en la zona son:

- Calcisoles y Luvisoles desarrollados sobre materiales arcillosos y carbonatados.
- Suelos de textura franca o franco-arcillosa, con buen desarrollo estructural.
- Capacidad de retención hídrica media-alta, aunque con susceptibilidad a procesos de compactación y erosión.

Los suelos de este municipio son muy erosionables, a menudo como consecuencia de elevadas pendientes, falta de cohesión, escasa materia orgánica y formación de costras superficiales. A ello se une la erosividad de las lluvias del clima mediterráneo (Marques et al., 2009).



Imagen 3. Perfil edáfico de un suelo próximo a la parcela piloto. Fuente propia.

Un ejemplo de una cata cercana a la parcela piloto muestra el perfil edáfico (*imagen 3*) de los suelos de la zona, con tres horizontes edáficos bien diferenciados: Ap (horizonte superficial arado con materia orgánica ligada a la fracción mineral), Cy1 y Cy2 (material original con acumulación de yesos).

Los suelos de Villaconejos taxonómicamente se corresponden con un *Typic Calcixerepts* (Marques et al., 2009). Sus texturas son respectivamente franca, franco arenosa y franco arcillosa. Otras características de estos suelos se detallan en la *tabla 2*.

En el horizonte superficial Ap (0-18 cm), se observa una Conductividad Eléctrica (C.E.) de 0.19 mS/cm, un pH fuertemente alcalino de 8.49, un contenido bajo de Materia Orgánica (M.O.) del 0.38% y un valor de Fósforo (P) de 8 ppm. En cuanto al complejo de cambio, el Calcio (Ca) domina claramente con 14.69 meq/100 gr. Estas propiedades se mantienen en los horizontes inferiores Bw, C1ca y C2ca, donde el pH se sitúa en torno a 8.31-8.49 y la C.E. se incrementa ligeramente hasta 0.30 mS/cm en el horizonte más profundo.

| Hor. F.A.O | Prof. (cm) | C.E (mS/cm a 25°C) | pH (1:2,5 H ₂ O) | M.O (%) | N (%) | P (ppm) | Complejo de cambio (meq/100 gr) | | | |
|------------|------------|--------------------|-----------------------------|---------|-------|---------|---------------------------------|------|------|------|
| | | | | | | | Ca | Mg | Na | K |
| Ap | 0 - 18 | 0,19 | 8,49 | 0,38 | 0,02 | 8 | 14,69 | 0,93 | 0,08 | 0,31 |
| Bw | 18 - 43 | 0,22 | 8,31 | 0,47 | 0,01 | n.d | 14,71 | 0,92 | 0,10 | 0,15 |
| C1ca | 43 - 82 | 0,27 | 8,49 | 0,34 | n.d | n.d | 15,34 | 1,09 | 0,09 | 0,14 |
| C2ca | 82 - 105 | 0,30 | 8,49 | 0,23 | n.d | n.d | 14,14 | 1,11 | 0,13 | 0,11 |

Tabla 1. Resultados de los análisis físico-químicos del perfil edáfico realizado en Villaconejos. **Hor. F.A.O:** Horizonte del suelo, clasificado según el Sistema de la FAO; **Prof. (cm):** Profundidad del horizonte en centímetros; **C.E. (mS/cm a 25°C):** Conductividad Eléctrica; **pH (1:2,5 H₂O):** Medida de la acidez o alcalinidad del suelo en una suspensión de suelo y agua en proporción 1:2,5; **M.O. (%):** Porcentaje de Materia Orgánica; **N (%):** Porcentaje de Nitrógeno total; **P (ppm):** Contenido de Fósforo disponible; **Complejo de cambio (meq/100 gr):** Concentración de cationes de cambio; **n.d:** No determinado.

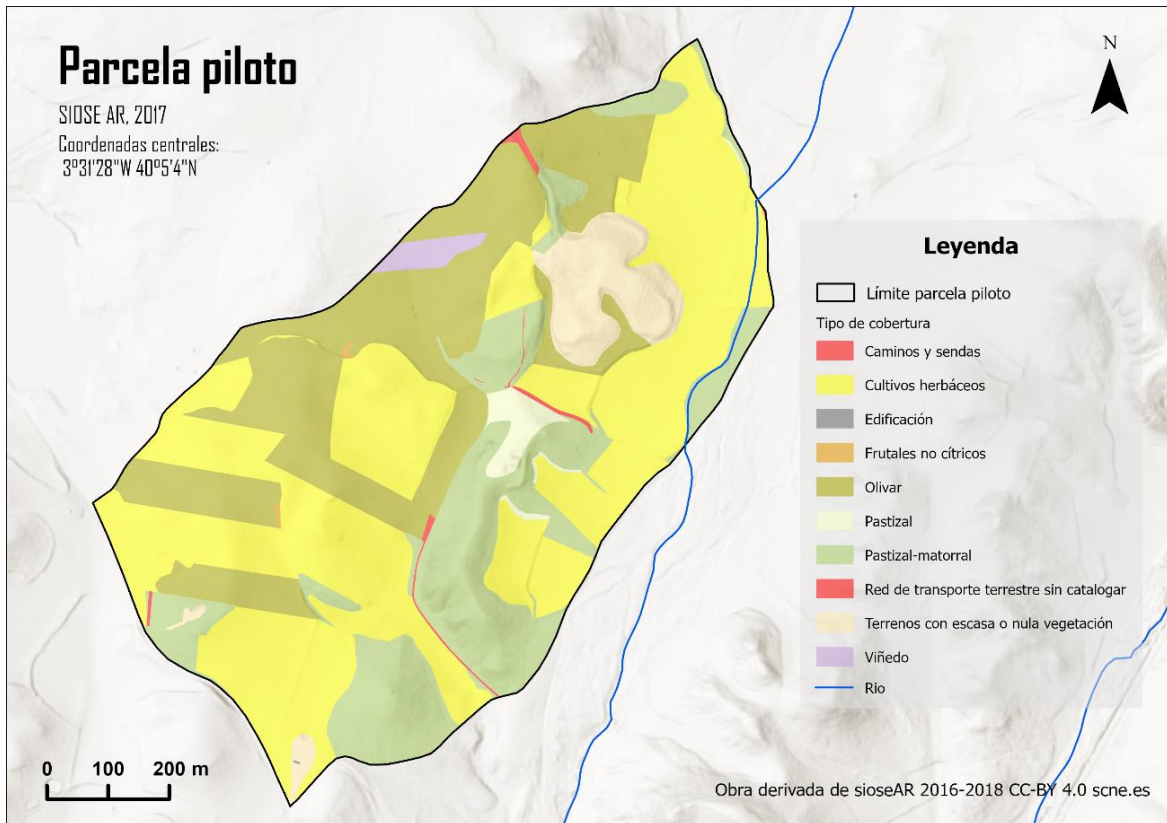
3.1.2. Cobertura vegetal y usos del suelo

La riqueza florística de Villaconejos está destacada por encinares (*Quercus ilex L.*), coscojares (*Quercus coccifera L.*) y quejigares (*Quercus faginea Lam.*). También, suelen estar acompañados de enebros (*Juniperus communis L.*) y sabinas (*Juniperus sabina L.*). En estratos más arbustivos se observan espartales (*Stipa tenacissima L.*), tomillares (*Thymus sp.*) y romerales (*Rosmarinus officinalis L.*). Mientras que, en las vegas, junto a las riberas fluviales, se encuentran fresnos (*Fraxinus sp.*), álamos (*Populus sp.*) o sauces (*Salix sp.*) (Pérez-Ramírez, 2022).

La cobertura vegetal y los usos del suelo en el municipio de Villaconejos (*mapa 4*) están dominados por un paisaje agrario típico de zonas semiáridas del centro peninsular, caracterizado por:

- Cultivos de secano, especialmente cereal (trigo, cebada), vid y olivar.
- Amplias superficies de pastizales, matorral mediterráneo y vegetación ruderal en zonas no cultivadas.

En el entorno de la urbanización de Balcón del Tajo, se alternan campos de olivar tradicional con zonas de vegetación espontánea y parcelas sin cultivo (*mapa 3*).



Mapa 3. Usos del suelo de la parcela de estudio (sioseAR 2016-2018 CC-BY 4.0)


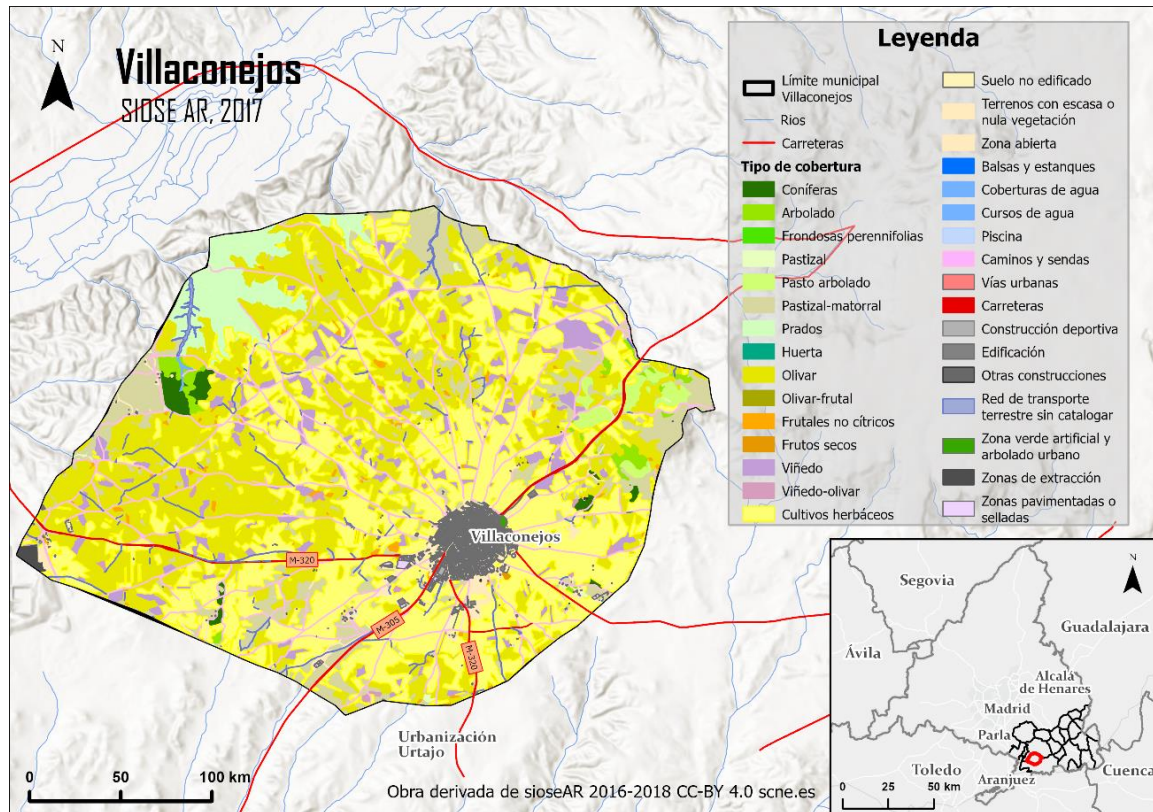


Gráfico 2. Gráfico circular con la distribución porcentual de las coberturas del suelo en la parcela piloto.

La distribución de los usos del suelo en la parcela piloto (véase gráfico 2) se basa en los datos más recientes del SIOSE (CNIG-IGN, 2017), e incluye:

- Agrícola: ~75%
- Forestal/Natural: ~18%
- Urbano y artificial: ~7%

Sobre una superficie total de 1,18 km².



Mapa 4. Usos del suelo del municipio de Villaconejos (sioseAR 2016-2018 CC-BY 4.0)

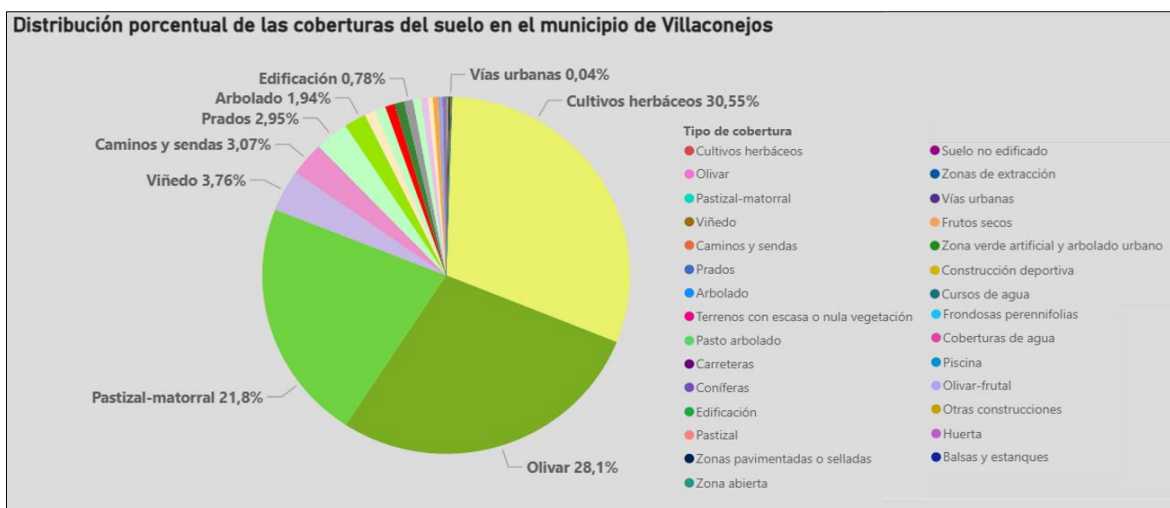


Gráfico 3. Gráfico circular con la distribución porcentual de las coberturas del suelo en el municipio de Villaconejos.

Actualmente los principales agroecosistemas son cultivos herbáceos de regadío situados en las vegas del río Tajo y sus afluentes Jarama y Tajuña, así como, el mosaico de cultivos herbáceos de secano, olivar y viñedo, que se distribuyen por los páramos, campiñas y vertientes (Pérez Ramírez, 2022).

Según los datos del Sistema de Información sobre Ocupación del Suelo en España (SIOSE), elaborado por el CNIG-IGN (2017), y representados en el *mapa 4*, los usos del suelo en Villaconejos se reparten en:

- Agrícola: más del 80 % del término municipal.
- Forestal/natural: en torno al 12–15 %.
- Urbano y artificial: por debajo del 5 %.

Con una superficie total de 36,65 km². Para más detalle visualizar el *gráfico 3*.

3.1.3. Hidrología

Desde el punto de vista hidrológico, el término municipal de Villacanejos se encuentra dentro de la Demarcación Hidrográfica del Tajo, más concretamente en la subcuenca del río Tajo medio (Confederación Hidrográfica del Tajo, 2022).

- No existen grandes cursos fluviales permanentes en el municipio.
- Predominan los arroyos temporales, y barrancos, activos sólo tras lluvias intensas.
- La escorrentía superficial presenta un comportamiento estacional y está condicionada por la pendiente, textura del suelo y cobertura vegetal.
- La infiltración en suelos de tipo franco-arcilloso suele ser moderada a baja, lo que influye directamente en la retención de humedad superficial (Departamento de Edafología, Universidad de Granada, s.f.).

4. Materiales y métodos

El objetivo del trabajo fue estimar la humedad superficial del suelo combinando el modelo de Hallikainen y de Dubois, a partir de imágenes radar. Para ello se realizó un flujo de preprocesamiento (*apartado 4.2*) y post procesamiento de los datos satelitales que se detalla a continuación.

El trabajo sigue un diseño metodológico secuencial y resumido (*imagen 4*), organizado en cuatro etapas principales: la captura de datos de diferentes fuentes; el tratamiento y homogeneización de la señal radar conforme al subflujo detallado en la *imagen 5*; la fase de modelización, orientada a la estimación de la humedad superficial mediante modelos físico-empíricos; y, finalmente, una evaluación estadístico-espacial que utiliza tres enfoques complementarios para determinar la fiabilidad y estructura de la información obtenida.

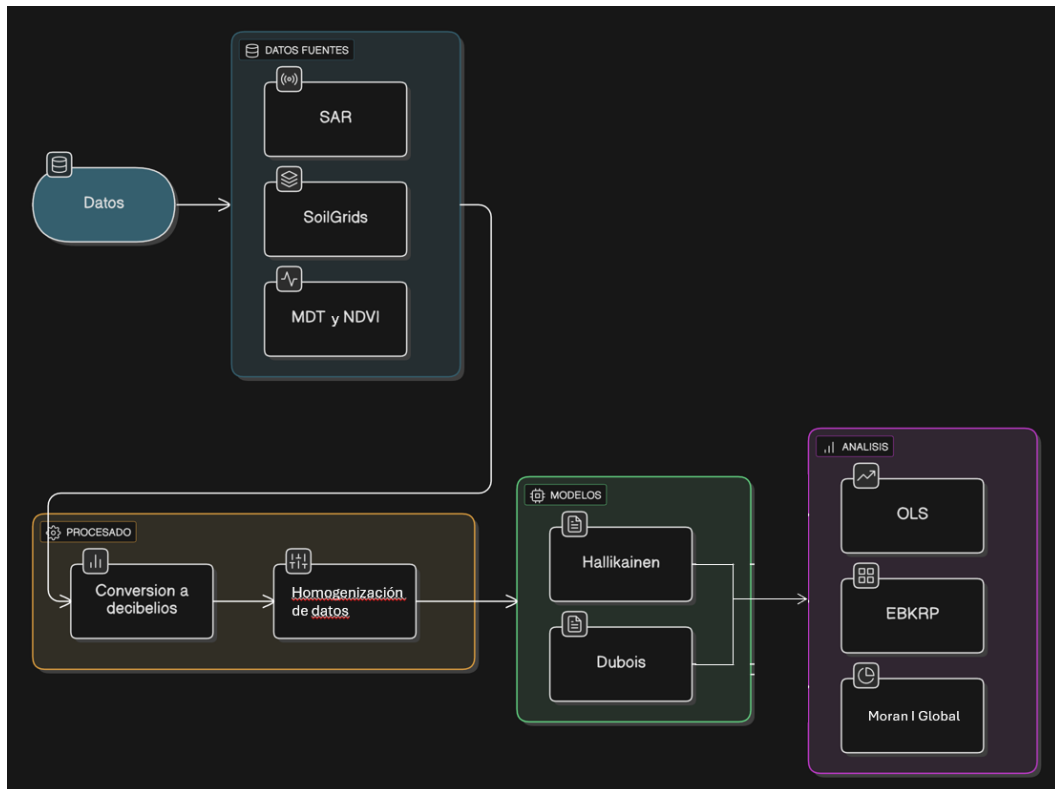


Imagen 4. Diagrama del flujo de trabajo llevado a cabo en el trabajo.

4.1. Fuentes de datos

Para el desarrollo del trabajo final de máster se ha precisado del uso de 12 imágenes radar Sentinel-1 y 12 imágenes multiespectrales de Sentinel-2 (anexo 9.1). A su vez, se han utilizado modelos digitales del terreno (MDT), ortofotos de máxima actualidad del programa PNOA (año 2025), datos del SIGPAC (a través de la plataforma Living Atlas), coberturas del suelo del SIOSE AR (tabla 2). A su vez, se han empleado una serie de softwares: SNAP, ArcGIS Pro 3.3, módulo de VBA en Excel y Power BI para la visualización, procesamiento y representación de los resultados.

| Producto | Uso | Resolución | Fuente | Cita |
|-------------------------------|---------------------------------|------------|---|---|
| Modelos digitales del terreno | Interpolación y retrodispersión | 5 metros | Instituto Geográfico Nacional (IGN) | BDLJE CC-BY 4.0 Instituto Geográfico Nacional |
| Imágenes SAR Sentinel 1 | Estimación de Humedad | 10 metros | European Space Agency (ESA) | Copernicus (2025) |
| Imágenes Sentinel 2 | Estimación de Humedad y NDVI | 10 metros | European Space Agency (ESA) | Copernicus (2025) |
| Delimitación parcelas | Área de estudio | N/A | Fondo Español de Garantía Agraria (FEGA) (Living Atlas, Esri) | (FEGA, 2025) |

| | | | | |
|-------------------------------|-------------------------------|---------|-------------------------------------|--|
| Delimitación municipio | Municipio de Villaconejos | N/A | Instituto Geográfico Nacional (IGN) | BDLJE CC-BY 4.0 Instituto Geográfico Nacional |
| Usos del suelo | Interpolación y área estudio. | 1:5.000 | SIOSE AR, 2025 | BDLJE CC-BY 4.0 Instituto Geográfico Nacional |

Tabla 2. Fuentes de datos usados para la obtención de los resultados.

4.1.1. Imágenes Sentinel-1

Se descargaron las imágenes radar a través de la plataforma *Copernicus Browser*, pertenecientes al programa del satélite Sentinel-1 con el procesamiento GRD (Ground Range Detection). Las características y parámetros principales de estas imágenes son: polarización VV, ángulo de incidencia alrededor de 39° - 40°, órbitas ascendentes (a excepción de 4 imágenes que son descendentes) y banda C (tabla 3).

| Satélite | Sentinel 1A |
|--------------------------------------|-------------|
| Altura orbital | ~693 km |
| Sensor | C-SAR |
| Modo | IW |
| Polarización | VV |
| Angulo de incidencia | 39, 23° |
| Resolución azimut | 22 m |
| Resolución en rango terrestre | ~20 m |
| Nivel y tipo | 1 GRD |

Tabla 3. Parámetros generales del sensor y de las imágenes radar Sentinel-1A.

Las imágenes del año 2025 correspondientes a Sentinel-1 pertenecen al tercer satélite de la misma misión, lanzado en abril de 2024 como reemplazo y continuidad operativa del sistema.

4.1.2. SoilGrids

SoilGrids es un sistema de información global de suelos que proporciona datos estandarizados sobre sus propiedades y clases a diferentes profundidades. Para los valores de arcilla (A_r) y arena (A_r), se tomó como referencia los valores recopilados por la plataforma (imagen 5), los cuales son 335 g/kg para arena y 208 g/kg para arcilla (Poggio et al., 2021; ISRIC, 2020) en las coordenadas de la parcela. Estos valores se tomaron a escala global con una resolución de 250 m, basado en mapeos digitales de suelos y machine learning.

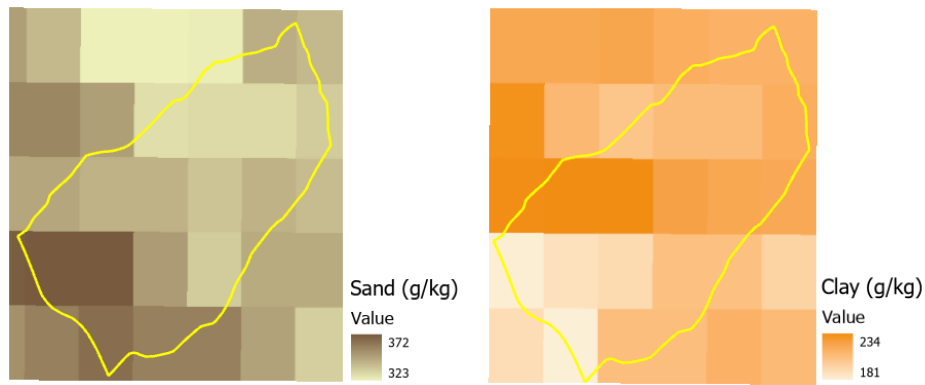


Imagen 5. Estimación del contenido de arena (izquierda) y arcilla (derecha) en la parcela piloto obtenidos a través de la plataforma SoilGrids.

4.1.3. Variables explicativas

Para la realización de desescalados o downscaling basados en algoritmos de geoestadística, se utilizaron variables explicativas (*tabla 4*) que pudieran justificar el comportamiento de la humedad del suelo. Se consideró que estas variables fueron capaces de explicar en gran parte la dinámica y distribución de la humedad superficial. A su vez, se utilizaron para el modelo EBK Regression Prediction de ArcGIS Pro y el posterior downscaling.

| Variables Explicativas/Resolución ráster | Resultado | Fuente |
|---|-----------|--|
| MDT (2 m) | | MDT02-cob2 2015-2021 CC-BY 4.0 scene.es |
| Pendientes (2 m) | | Obra derivada de MDT02-cob2 2015-2021 CC-BY 4.0 scene.es |
| Orientaciones (2 m) | | Obra derivada de MDT02-cob2 2015-2021 CC-BY 4.0 scene.es |
| Índice TWI (5 m) | | Obra derivada de MDT02-cob2 2015-2021 CC-BY 4.0 scene.es |
| Índice NDVI (10 m) | | Sinergise Solutions d.o.o., s.f. |

Tabla 4. Listado de variables explicativas usadas para comprender e interpretar la dinámica y distribución de la humedad superficial. Contains modified Copernicus Sentinel data [2015–2025].

El índice TWI o índice topográfico de humedad fue una herramienta que ayudó a identificar las áreas donde tendió a concentrarse la humedad o donde se acumuló el agua de forma natural. Su cálculo se basó en el estudio de la forma del terreno. El proceso para obtener el TWI parte del análisis de Modelos Digitales del Terreno (MDT) y de su morfología, con el

fin de localizar los sectores con mayor probabilidad de acumulación de humedad (*imagen 6*).

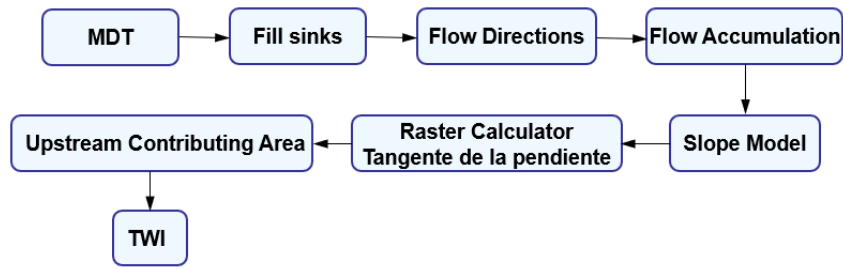


Imagen 6. Diagrama de flujo para obtener el índice TWI.

El procedimiento implicó analizar las direcciones de flujo y las pendientes, así como aplicar una corrección al modelo de elevación, ajustando su resolución y rellenando los sumideros para asegurar resultados más precisos (GIS & Beers, 2018).

El índice NDVI o Índice de Vegetación de Diferencia Normalizada fue uno de los indicadores que se obtuvieron al combinar distintas bandas espectrales para analizar la cobertura vegetal. Básicamente, midió la reflectancia de la luz en dos zonas clave del espectro: la banda del rojo visible y la del infrarrojo cercano (GIS & Beers, 2016).

$$NDVI = (NIR - RED) / (NIR + RED)$$

$$NDVI = (B8 - B4) / (B8 + B4)$$

4.2. Preprocesamiento de imágenes Sentinel-1

Una vez descargadas las imágenes, se procedió a realizar un flujo de preprocesamiento (*imagen 7*) usando el software SNAP (Sentinel Application Platform). El diseño de este flujo se basó en la metodología expuesta en el curso de procesamiento de imágenes Sentinel desarrollado por el IGN Spain (2021), teniendo en cuenta el tipo de producto descargado, en este caso GRD (Ground Range Detection).

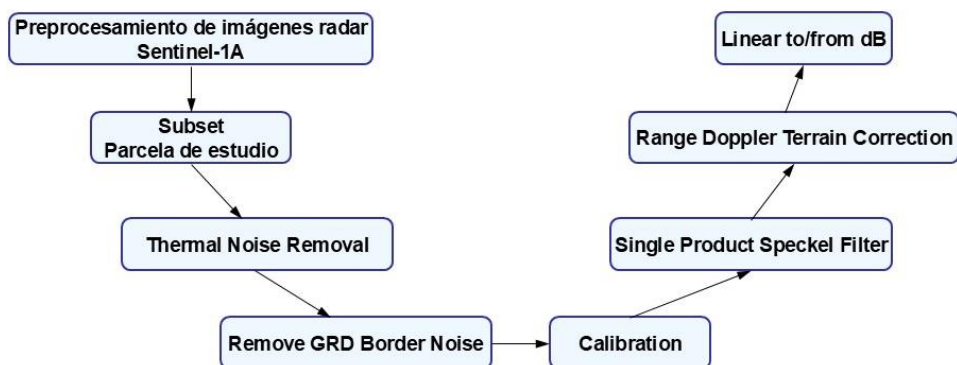


Imagen 7. Diagrama del flujo de trabajo del preprocesamiento de las imágenes Sentinel-1A en SNAP. Fuente propia.

En primer lugar, se recortó el área de interés usando la herramienta Subset, con el fin de optimizar los posteriores cálculos y procesos.

Después, se realizó el procesamiento Thermal Noise Removal, que elimina el ruido proveniente de errores del sensor, del sistema de transmisión/recepción y del grabador. Ese ruido puede ser geométrico o radiométrico, y este último se corrige parcialmente mediante calibración y técnicas de eliminación de ruido térmico (Sentinel-1 Team, 2013). En productos GRD, esta corrección se aplica por defecto, aun así, se realizará este procesado para evitar posibles errores.

La herramienta Remove GRD Border Noise se aplicó debido a que la conversión de los datos RAW a productos de Nivel 1 (L1) implica varios pasos de procesamiento que inevitablemente generan artefactos en los bordes de la imagen (European Space Agency [ESA], 2023).

La herramienta Calibration es el procedimiento que garantiza que un radar y los datos que produce sean lo más exactos y uniformes posibles (Sentinel-1 Team, 2013). Para análisis cualitativos se pueden usar imágenes sin calibrar, las calibradas son indispensables en trabajos cuantitativos como el presente estudio (Santana, 2016).

En todas las imágenes SAR aparece un tipo de ruido llamado *Speckle*. El speckle noise es un producto de la señal rebotada proveniente de muchos objetos distintos y mezclados de forma aleatoria. Este ruido se ve como un “salpicado” de puntos claros y oscuros en zonas que, en realidad, son uniformes. Es por ello que para reducir este efecto se hace uso de la herramienta Single Product Filter Speckel de SNAP (Santana, 2016).

En las imágenes SAR, las distancias pueden aparecer deformadas debido a las irregularidades del terreno y al ángulo con el que el sensor del satélite capta la escena. Cualquier punto que no esté justo debajo del sensor en lo que se llama posición *nadir* sufrirá algún tipo de distorsión. Para solucionar esto, se aplican correcciones del terreno como Range Doppler Terrain Correction, basado en modelos digitales de elevaciones del SRTM (Shuttle Radar Topography Mission) (ESA, 2023).

4.2.1. Transformación de decibelios y homogenización de datos

Por último, los valores de retrodispersión obtenidos están en valores lineares, necesarios para poder aplicar en los modelos posteriores. Aunque, será necesario transformarlos después a decibelios (dB) para el análisis, comparación y representación de los resultados.

$$dB = 10 \log_{10}(ND)$$

Ecuación 3. Expresión matemática para transformar valores de nivel digital (ND) a decibelios (dB).

4.3. Interpretación de las imágenes

Una vez que los valores de retrodispersión se encuentran en decibelios (dB), se ha procedido a analizarlos para comprender si los rangos que se observan tienen sentido en función de las características del área de estudio.

Una vez obtenidos los valores de retrodispersión (dB) tras el preprocesamiento de las imágenes Sentinel-1, la fase de interpretación se centró en comparar los resultados obtenidos con los escenarios típicos definidos en la literatura técnica. Específicamente, se contrastaron

los rangos de retrodispersión observada en la parcela piloto (*tabla 6*) con los umbrales de coeficientes de retrodispersión propuestos por Santana (2016) para diversos escenarios típicos (*tabla 5*).

| Niveles de coeficientes de retrodispersión | Escenario típico |
|--|---|
| Muy alto (por encima de -5 dB) | Estructuras antrópicas, montañas, pendientes a favor del sensor, mucha rugosidad |
| Alto (-10 dB a 0 dB) | Superficie rugosa. Vegetación densa (bosques) |
| Moderado (-20 dB a -10 dB) | Nivel medio de vegetación. Cultivos agrícolas, superficies moderadamente rugosas. |
| Bajo (por debajo de -20 dB) | Superficies planas. Agua en calma. Carreteras. Terrenos con bajos niveles de humedad (arena). |

Tabla 5. Niveles del coeficiente de retrodispersión para escenarios típicos (Santana, 2016).

Este análisis comparativo permitió validar si los rangos registrados eran coherentes con las características conocidas del área de estudio (zona agrícola con suelos franco-arcillosos cercanos a Villaconejos) en las distintas fechas de adquisición. Por ejemplo, la presencia de rangos de retrodispersión Bajo (por debajo -20 dB) o Moderado (entre -20 dB y -10 dB) en la mayoría de las imágenes capturadas fue evaluada en función de si se correspondía con un nivel bajo de humedad superficial o la presencia de una superficie agrícola con rugosidad media, respectivamente. La clave fue interpretar la señal de radar como un indicador directo de las condiciones de la superficie en cada momento de observación.

| Fecha de imágenes | Rango de retrodispersión observada (dB) |
|-------------------|---|
| 2015-03-22 | (-14,17 a 1,28) |
| 2015-07-26 | (-17,42 a 0,27) |
| 2017-05-04 | (-19,88 a -2,93) |
| 2017-08-08 | (-16,95 a -1,29) |
| 2019-04-24 | (-13,96 a 1,02) |
| 2019-06-29 | (-16,08 a 0,3) |
| 2021-04-25 | (-16,96 a -1,9) |
| 2021-08-05 | (-16,19 a -1,34) |
| 2023-05-27 | (-16,49 a -2,08) |
| 2023-08-19 | (-16,71 a -0,68) |
| 2025-03-11 | (-16,43 a -1,09) |
| 2025-06-03 | (-17,04 a -1,61) |

Tabla 6. Rangos de retrodispersión observados en cada imagen capturada.

4.4. Selección de periodos húmedos y secos

Las fechas de las imágenes se han escogido en función de un periodo húmedo (febrero a mayo) y un periodo seco (junio a agosto). Además, se ha tenido en cuenta para los periodos secos, que no haya registro de precipitaciones previas a la imagen, y viceversa para los periodos húmedos, a partir de datos históricos de la AEMET (*anexo 9.3*).

| SENTINEL-1 (2015-2025) | | | | |
|-------------------------------|----------------|-------------------------------------|----------------|--|
| Fecha | Periodo | Motivo (precipitación en mm) | Cultivo | Observación |
| 2015-03-22 | Húmedo | 5,7 | Cereal | Incremento de retrodispersión por crecimiento vertical; sensibilidad a humedad. |
| 2015-07-26 | Seco | Sin precipitación | Cereal | Campo cosechado; retrodispersión baja a media según rastrojos. |
| 2017-05-04 | Húmedo | 7,8 y 1,3 en los días 29/04 y 30/04 | Cereal | Máxima cobertura vegetal; alto VV/VH, señal saturada. |
| 2017-08-08 | Seco | Sin precipitación | | - |
| 2019-04-24 | Húmedo | 15,9 | Suelo desnudo | Posible incremento de humedad tras lluvias primaverales; variación en retrodispersión. |
| 2019-06-29 | Seco | Sin precipitación | Suelo desnudo | Muy seca; retrodispersión muy baja, mayor contraste de rugosidad. |
| 2021-04-25 | Húmedo | 7,8 | | - |
| 2021-08-05 | Seco | Sin precipitación | | - |
| 2023-05-27 | Húmedo | 21,6 | Viñedo | Desarrollo vegetativo intermedio |
| 2023-08-19 | Seco | Sin precipitación | Viñedo | Plena vegetación; VV variable según densidad de copa. |
| 2025-03-11 | Húmedo | 8 | Viñedo | Inicio de brotación |
| 2025-06-03 | Seco | Sin precipitación | | - |

Tabla 7. Principales observaciones de las fechas seleccionadas para el estudio.

4.5. Estimación de parámetros físicos

4.5.1. Obtención de la constante dieléctrica (Modelo Hallikainen)

Para estimar los valores de humedad superficial (m^3/m^3) se utilizaron como entrada los datos del sensor (ángulo de incidencia, polarización, tipo de banda) y los valores de retrodispersión observados. Para ello, se empleó el modelo de Hallikainen, que relaciona la constante dieléctrica (ϵ) del suelo directamente con su contenido de agua.

Dado que la retrodispersión se conoce, pero el valor de humedad (θ) es desconocido, se ha aplicado el modelo de Hallikainen de forma inversa a través de un proceso de iteración.

Este proceso consistió en asignar un valor de constante dieléctrica a cada valor de humedad iterado en un rango físicamente plausible:

- Se iteraron valores de humedad volumétrica (θ) en un rango de 0.02 a 0.45 m^3/m^3 , con saltos de 0.01 m^3/m^3 (es decir, 0.02, 0.03, 0.04, 0.05, etc.).
- Para cada iteración, el modelo de Hallikainen generó el valor correspondiente de la constante dieléctrica (ϵ).

Los rangos de humedad volumétrica elegidos (0.02 a $0.45 \text{ m}^3/\text{m}^3$) representan un espectro completo de las condiciones de agua que se esperan encontrar en los primeros centímetros del suelo ($0\text{-}5 \text{ cm}$ o $0\text{-}10 \text{ cm}$) cubriendo desde un suelo extremadamente seco ($\sim 0,02 \text{ m}^3/\text{m}^3$ cercano al típico de Punto de Marchitez Permanente) hasta un suelo muy húmedo o cercano a la Capacidad de Campo ($\sim 0,45 \text{ m}^3/\text{m}^3$ en suelos arcillosos o francos) según Hillel (2004). Este rango es coherente con el contenido de humedad que se puede observar en la capa superficial de suelos agrícolas.

El resto de los parámetros necesarios para el modelo (como la textura o granulometría) se obtuvieron a través de la literatura técnica y de la plataforma SoilGrids. Las variables S y C representaron el porcentaje de arena (Sand) y arcilla (Clay) en el suelo, respectivamente. Los coeficientes a_0 , a_1 , a_2 , b_0 , b_1 , b_2 , c_0 , c_1 y c_2 fueron factores constantes que ya habían sido calibrados previamente a distintas frecuencias (específicamente 1.4 , 4 , 6 , 8 , 10 , 12 , 14 , 16 y 18 GHz), usando mediciones de la constante dieléctrica del suelo (Hallikainen et al., 1985) (Anexo 9.4). Por lo tanto, para convertir la constante dieléctrica en contenido de humedad del suelo a esas frecuencias, solo fue necesario conocer los valores de arena (S) y arcilla (C).

Con la expresión del modelo de Hallikainen se obtuvo el valor de la constante dieléctrica (ϵ), la cual se sustituyó posteriormente en el modelo de Dubois.

4.5.2. Aplicación del Modelo de Dubois

Desde los metadatos de las imágenes, se tomaron los parámetros de adquisición como la longitud de onda (0.555 m) a partir de la frecuencia (banda C $\sim 5.405 \text{ GHz}$) y el ángulo de incidencia del satélite ($\theta = 39, 23^\circ$). El parámetro s corresponde a la desviación estándar de la rugosidad de la superficie (root mean square height, RMS height), en el cual se tomó como valor $0,015 \text{ m}$ (tabla 8) en referencia a estudios realizados previamente como en Konings (2009). Con esta referencia se iteraron valores de rugosidad entre $0,0085$ a $0,02 \text{ m}$ en pasos de $0,0001 \text{ m}$.

| Land Cover Type | s [m] |
|------------------------------|---------|
| Evergreen needleleaf forest | 0.01 |
| Evergreen broadleaf forest | 0.01 |
| Deciduous needleleaf forest | 0.01 |
| Deciduous broadleaf forest | 0.01 |
| Mixed forest | 0.01 |
| Closed shrubland | 0.01 |
| Open shrubland | 0.01 |
| Woody savanna | 0.01 |
| Savanna | 0.01 |
| Grassland | 0.01 |
| Cropland | 0.015 |
| Urban | 0 |
| Barren or sparsely vegetated | 0.01 |
| Water | 0 |

Tabla 8. Rugosidad del suelo utilizada según el tipo de cobertura del terreno (Konings, 2009)

Este proceso generó una matriz de 44 columnas y 116 filas, es decir, un total de 5.104 valores distintos de retrodispersión estimados.

El problema principal de disponer de tantas opciones fue la ambigüedad paramétrica, es decir, la retrodispersión observada en el radar pudo coincidir con múltiples combinaciones de humedad y rugosidad que eran muy diferentes entre sí.

Para hacer que la metodología fuese más estable y manejase mejor las incertidumbres, se redujeron drásticamente la influencia de las pequeñas variaciones en la rugosidad superficial. Para ello, se agruparon los 116 valores de rugosidad en 11 rangos de igual tamaño. El resultado fue una matriz de 44 columnas por 11 filas. Para representar cada uno de estos 11 rangos de rugosidad, se calculó la media aritmética de los valores de retrodispersión que cayeron dentro de ese rango. De esta manera, el valor de retrodispersión estimado se volvió más robusto y menos sensible a los detalles finos de la rugosidad.

Una vez simplificada la matriz, en el siguiente paso se vinculó la retrodispersión que el radar observó en cada punto del terreno con el valor de retrodispersión que nuestro modelo estimó en la matriz simplificada. Se aplicó la primera Ley de Tobler, donde las cosas que están cerca tienden a ser más parecidas que las cosas que están lejos. En otras palabras, la humedad del suelo no suele cambiar abruptamente entre dos puntos muy cercanos.

Para aplicar esta ley, se desarrolló un código en VBA de asignación integrado en Excel. El objetivo fue asegurar que, al elegir la mejor solución de la matriz, no solo se pareciera a la observación del radar, sino que también fuera coherente con la humedad estimada en los puntos vecinos. Si el modelo encontraba una solución que se ajustaba perfectamente a la retrodispersión, pero que asignaba una humedad extremadamente seca a un punto rodeado de puntos húmedos, el algoritmo la descartaba.

Cada observación incluyó el valor de retrodispersión y sus coordenadas en el terreno. De los datos simulados, además de la retrodispersión, se registraron la rugosidad y la humedad asociadas.

El algoritmo trabajó observación por observación. Para cada punto medido, buscaba en su entorno espacial inmediato (definido como un radio de 20 metros) si existen observaciones anteriores que puedan aportar información sobre la humedad local. Si las había, calculaba un promedio de humedad a partir de estos vecinos; si no, asignaba un valor de referencia por defecto.

Con esa referencia de humedad vecina, el código recorrió todos los casos simulados y evaluó cuál se ajustaba mejor al punto observado. La decisión se basó en un “puntaje” que combina dos criterios: la diferencia absoluta entre la retrodispersión observada y la simulada, y la diferencia entre la humedad simulada y la humedad promedio de los vecinos. De esta forma, no se seleccionó simplemente el valor más parecido en retrodispersión, sino aquel que al mismo tiempo resultaba consistente con la dinámica de humedad del entorno.

Finalmente, los resultados se guardaron en una nueva tabla que incluye:

- La retrodispersión observada,
- La humedad y rugosidad asociadas al valor simulado elegido,
- La retrodispersión estimada correspondiente,

- El error cometido en la asignación,
- Los vecinos que se tuvieron en cuenta en el cálculo.

Este procedimiento permitió vincular de manera más robusta las mediciones reales con los valores generados por el modelo, reduciendo la influencia de coincidencias fortuitas y aprovechando la información espacial del conjunto de datos (*anexo 9.5*).

4.6. Análisis espacial entre la humedad superficial y variables explicativas

Se realizó un análisis de autocorrelación y regresión exploratoria usando la herramienta “Autocorrelación espacial (I de Moran global)” de ArcGIS Pro, aplicándola a la variable dependiente humedad superficial. Considerando como variables explicativas las descritas en el *apartado 4.1.3*. El objetivo fue identificar los factores que presentaron una relación estadísticamente significativa con la humedad del suelo y evaluar la estructura espacial de los residuos mediante el estadístico global de Moran (SA).

4.7. Modelización estadística: regresión OLS

El análisis se centró en la aplicación de un modelo de Mínimos Cuadrados Ordinarios (OLS) para examinar la relación lineal entre la variable dependiente, la humedad superficial del suelo, medida sobre una capa ráster de 8.316.371 observaciones (píxeles), y un conjunto de variables explicativas. La selección de las cinco covariables se fundamentó en su conocida influencia hidrológica y biofísica sobre la distribución y retención de la humedad del suelo, tal como se establece en la literatura científica (Schröter et al., 2017).

Las tres primeras variables se derivaron del Modelo Digital del Terreno (MDT) y fueron relevantes para entender el movimiento y la acumulación de agua (Schröter et al., 2017):

1. MDT (Altitud): Controla los gradientes de presión y temperatura. La altitud se relaciona inversamente con la humedad superficial debido a los efectos del escurrimiento y la evapotranspiración diferencial.
2. Slope (Pendiente): Determina la velocidad del flujo superficial y subsuperficial. Una mayor pendiente generalmente conduce a un mayor escurrimiento y, por lo tanto, a una menor retención de humedad.
3. Aspect (Orientación): Influye indirectamente en la humedad al determinar la exposición a la radiación solar. Esto afecta las tasas locales de evapotranspiración, siendo las orientaciones expuestas al sol (sur, por ejemplo, en el hemisferio norte) típicamente más secas.
4. El TWI (Índice Topográfico de Humedad) estima la tendencia de acumulación de agua en una ladera, basándose en el área de drenaje upstream y la pendiente local, lo que permite identificar áreas propensas a la saturación.
5. NDVI (Índice de Vegetación de Diferencia Normalizada): Refleja la densidad, la vigorosidad y el estado de la vegetación. El NDVI es un indicador indirecto esencial de los procesos de intercepción y, fundamentalmente, de la evapotranspiración (Schröter et al., 2017). Una vegetación más densa (alto NDVI) puede indicar una

mayor extracción de agua del suelo (transpiración), pero también una mayor protección contra la evaporación directa.

El modelo OLS de ArcGIS Pro asume una relación lineal entre las variables, así como independencia, homocedasticidad y normalidad de los residuos. En su aplicación se estimaron coeficientes de regresión, errores estándar, estadísticos de contraste y medidas de ajuste global como el R^2 , incorporando pruebas diagnósticas para verificar el cumplimiento de los supuestos del modelo. El análisis se desarrolló en un contexto geoespacial, considerando variables topográficas y de cobertura vegetal.

El modelo adoptó la siguiente forma:

$$\text{Humedad} = \beta^0 + \beta_1 MDT + \beta_2 \text{Aspect} + \beta_3 \text{Slope} + \beta_4 \text{TWI} + \beta_5 \text{NDVI} + \varepsilon$$

Ecuación 4. Modelo OLS generado para el análisis estadístico.

donde ε representa los residuos (errores) no explicados por el modelo. ArcGIS Pro genera una serie de estadísticas que permiten evaluar la significancia, ajuste global, redundancia entre variables y supuestos de normalidad e independencia de residuos.

4.8. Desescalado por técnicas geoestadísticas: Empirical Bayesian Kriging Regression Prediction

Dado que Sentinel-1 recogió los datos con una resolución espacial de 10 metros de lado de píxel, se ideó un proceso de desescalado espacial basado en interpolaciones estadísticas.

Los desescalados o Downscaling, son técnicas de aumento de la resolución espacial basadas en interpolaciones con variables independientes. En este trabajo se utilizó la herramienta Empirical Bayesian Kriging Regression Prediction (EBK-RP) de ArcGIS Pro, para generar las interpolaciones de la humedad estimada previamente calculada con los modelos semiempíricos de Hallikainen y Dubois. Esta herramienta se aplicó con éxito para estimar temperaturas medidas desde satélite, logrando resultados con un nivel bajo de incertidumbre (Zhang y Du, 2019), por lo que es un buen indicativo o razón para aplicar su uso en este trabajo.

EBK-RP pertenece a la familia de métodos geoestadísticos conocidos como Kriging. Los métodos geoestadísticos basan la estimación de nuevos valores (interpolación) según la autocorrelación de las series de datos y la distancia entre datos.

A diferencia del Ordinary Kriging, EBK-RP realiza automáticamente procesos de exploración y transformación de los datos, como el análisis del histograma o de la tendencia espacial. También ajusta los datos a diferentes modelos teóricos de distribución, de manera semi-automática, lo que facilita comparar distintas opciones de ajuste. En este caso, la herramienta permitió trabajar con cuatro modelos: Nugget, Whittle, K-Bessel y Exponential. En el caso de este trabajo se optó por usar el modelo K-Bessel y ninguna transformación de los datos.

Una de las ventajas más importantes de EBK-RP es que no se limita a interpolar una sola variable, sino que permite introducir variables adicionales (explicativas) que ayudan a

mejorar las predicciones. Lo hace estableciendo una relación de regresión lineal entre la variable principal (en este caso, la humedad superficial estimada) y varias variables explicativas (*tabla 4*). En este análisis, se utilizó como variable complementaria la altitud, a partir de un Modelo Digital del Terreno (MDT) del IGN, y con una resolución espacial de 2 metros por píxel. De este modo, la altitud actúa como un factor que ayuda a afinar la distribución espacial de la humedad. A su vez, se usaron las variables descritas en el *apartado 4.1.3*.

4.9. Caracterización de las Estimaciones de Humedad, Rugosidad y Retrodispersión

Con el objetivo de realizar una evaluación exploratoria de la distribución y las relaciones clave entre los parámetros estimados, se diseñaron y desarrollaron tres análisis gráficos específicos. Estos análisis se implementaron en la plataforma Microsoft Power BI, utilizando como fuente de datos las hojas de cálculo de Microsoft Excel que contienen los resultados de la inversión del modelo por píxel, previamente descrita.

4.9.1. Distribución de Humedad por Rugosidad y Período

Se empleó un gráfico de cajas y bigotes (box plot) (*apartado 5.5*) para analizar la variabilidad interna de la humedad estimada en función de las dos variables categóricas más influyentes: el rango de Rugosidad (s) y el Período Temporal (Seco/Húmedo). Los datos de humedad por píxel se agruparon por año, periodo y por cada uno de los 11 rangos de rugosidad previamente definidos. El gráfico de cajas y bigotes resultante mostró cinco estadísticos clave para cada grupo: el Mínimo, el Cuartil 1, la Mediana, el Cuartil 3 y el Máximo, junto con la media.

4.9.2. Análisis de Variaciones del Período Seco y Húmedo

Para comprender la dinámica temporal y la respuesta del radar a los cambios de humedad, se creó un gráfico combinado de barras y líneas (*apartado 5.6*). Se calculó la Retrodispersión Media (dB) y la Humedad Media (m^3/m^3) mediante la agregación (promedio) de los valores estimados de todos los píxeles dentro de cada periodo (Húmedo y Seco) de cada año.

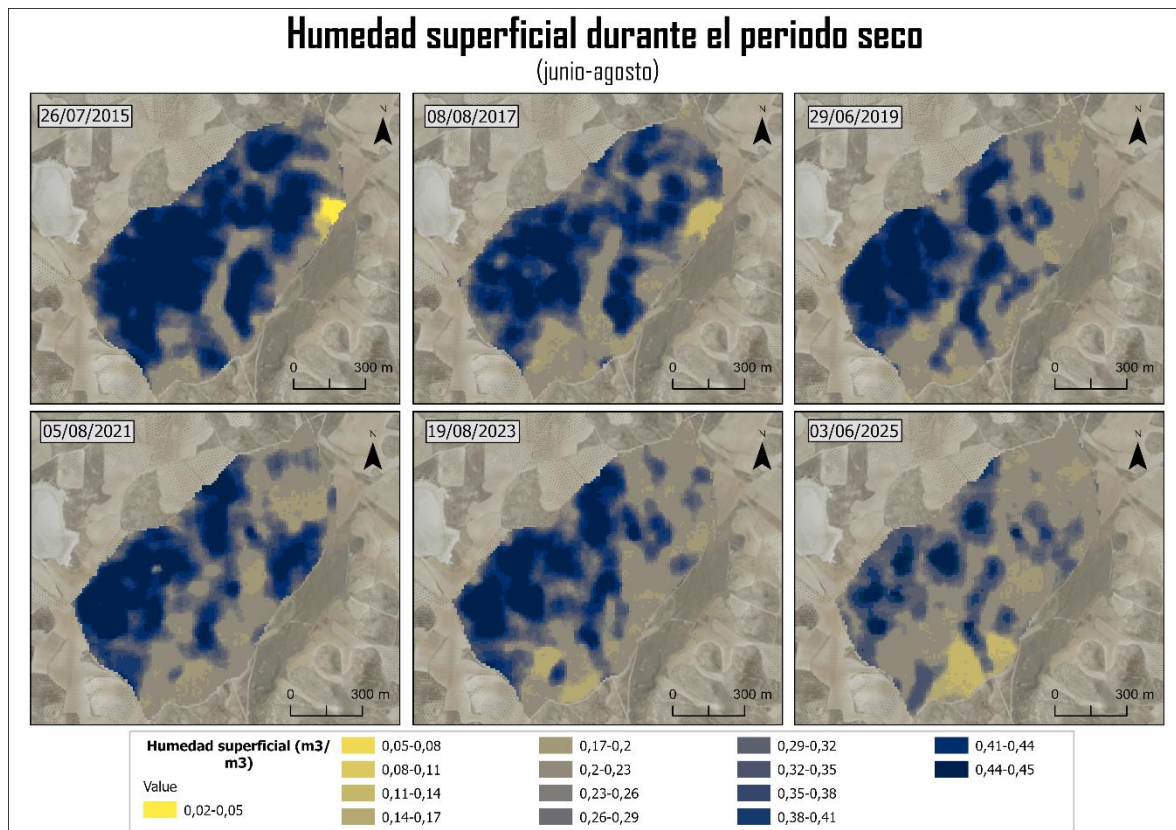
4.9.3. Correlación Retrodispersión vs. Rugosidad Estimada

Para aislar la dependencia de la señal radar con la morfología del suelo, se desarrolló un gráfico de dispersión (*apartado 5.6*). Variación de la retrodispersión media en función de la rugosidad). Se calculó la Retrodispersión Media (dB) para cada uno de los 11 rangos de rugosidad (s) establecidos en el proceso de inversión.

5. Resultados

5.1. Mapas de humedad superficial (2015-2025)

Las siguientes composiciones (*mapa 5*) muestran un mapa independiente de la parcela de estudio por cada año analizado, dividido entre el periodo seco y húmedo.



Mapa 5. Composición cartográfica de la humedad superficial en el periodo seco en la parcela de estudio. *Contains modified Copernicus Sentinel data [2015–2025].*

Durante el periodo seco (junio-agosto), los seis mapas presentados corresponden a los años 2015, 2017, 2019, 2021, 2023 y 2025, mostrando la distribución espacial de la humedad superficial (m^3/m^3) dentro de la parcela de estudio.

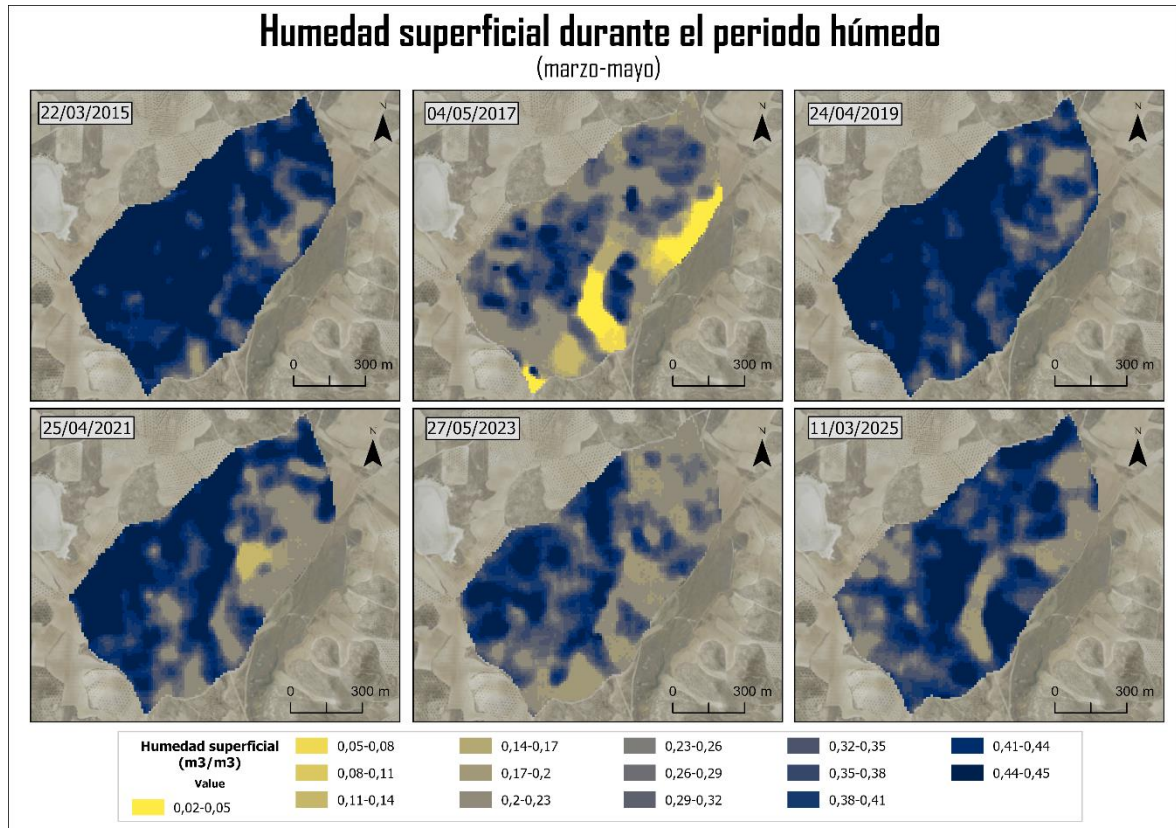
En el mapa de 2015 (26/07/2015) se observan predominantes tonos azules, especialmente hacia las zonas centrales y occidentales del área, indicando niveles relativamente altos de humedad (entre $0,35$ y $0,45 \text{ m}^3/\text{m}^3$). En contraste, las zonas orientales muestran parches amarillentos, donde los valores caen por debajo de $0,05 \text{ m}^3/\text{m}^3$, representando condiciones más secas.

Para 2017 (08/08/2017), la distribución espacial mantiene un patrón similar al de 2015, aunque con una ligera reducción de las áreas más húmedas. El predominio de valores entre $0,2$ y $0,35 \text{ m}^3/\text{m}^3$ sugiere una disminución generalizada de la humedad.

En 2019 (29/06/2019), el patrón muestra una notable expansión de zonas con valores bajos ($0,14$ – $0,26 \text{ m}^3/\text{m}^3$), principalmente en el noreste. Las áreas más húmedas se reducen significativamente, indicando un periodo seco más marcado. Esta tendencia parece revertirse

ligeramente en 2021 (05/08/2021), donde reaparecen zonas con valores medios y altos (0,29–0,38 m³/m³), en el este de la parcela.

En 2023 (19/08/2023), los mapas reflejan una situación decreciente, más significativa en el sur de la parcela. Finalmente, en 2025 (03/06/2025) se evidencia una reducción generalizada de la humedad superficial, especialmente en el sur y el oeste donde previamente encontrábamos valores entre 0,38 y 0,45 m³/m³.



Mapa 6. Composición cartográfica de la humedad superficial en el periodo húmedo en la parcela de estudio. Contains modified Copernicus Sentinel data [2015–2025].

En los mapas del periodo húmedo (*mapa 6*), se puede apreciar que los valores más generalizados de humedad están dentro de 0,32 a 0,45 m³/m³, es decir, muestran suelos muy húmedos. En el año 2017 se puede observar que la tendencia cambia abruptamente. Con valores muy secos en áreas muy bien delimitadas en el sur y suroeste de la parcela. Los resultados obtenidos, parten de unos valores genéricos de humedad mayores, respecto a los del periodo seco. Tampoco, hay una clara tendencia a suelos más secos como si se pueden intuir en el periodo seco. En la *tabla 9*, se puede observar la evolución de los valores medios de humedad superficial y retrodispersión estimada.

Tabla resumen por año y periodo

| Año | Periodo | Humedad media (m ³ /m ³) | Retrodispersión media |
|------|---------|---|-----------------------|
| 2015 | Húmedo | 0,41 | -8,30 |
| | Seco | 0,35 | -9,74 |
| 2017 | Húmedo | 0,25 | -12,13 |
| | Seco | 0,32 | -10,68 |

| Año | Periodo | Humedad media (m3/m3) | Retrodispersión media |
|------|---------|-----------------------|-----------------------|
| 2019 | Húmedo | 0,40 | -8,73 |
| | Seco | 0,30 | -10,92 |
| 2021 | Húmedo | 0,35 | -10,04 |
| | Seco | 0,31 | -10,79 |
| 2023 | Húmedo | 0,31 | -10,94 |
| | Seco | 0,30 | -10,99 |
| 2025 | Húmedo | 0,34 | -10,13 |
| | Seco | 0,25 | -11,98 |
| | | 0,32 | -10,45 |

Tabla 9. Valores de humedad y retrodispersión medios de cada año y periodo analizado.

5.2. Análisis de la relación espacial entre la humedad superficial y variables explicativas

Con el objetivo de evaluar la estructura espacial de la humedad superficial, se llevó a cabo un análisis exploratorio espacial mediante el estadístico I de Moran Global. Para ello, se analizaron múltiples configuraciones de las variables explicativas, considerando un conjunto de combinaciones que permitió evaluar distintos escenarios espaciales.

El resultado más relevante desde el punto de vista exploratorio fue la detección de autocorrelación espacial significativa. El I de Moran Global aplicado a los residuos mostró, en todos los casos, p-valores iguales a 0,000, lo que indica que los residuos no se distribuyen aleatoriamente en el espacio, sino que presentan un patrón claramente agrupado. Este comportamiento muestra que existe dependencia espacial no explicada por las variables incluidas en los modelos.

Respecto a la significancia individual de las variables, todas alcanzaron un nivel de significancia del 99 % ($p < 0,01$). El resumen de dirección de los efectos indicó que el MDT y el TWI presentaron signo positivo en el 100 % de los modelos; ASPECT y NDVI mostraron signo negativo en el 100 % de los casos; mientras que SLOPE presentó valores positivos y negativos en proporciones similares (50 % cada uno).

5.3. Evaluación del modelo OLS

El modelo de regresión lineal ordinaria (OLS) mostró que todas las variables explicativas incluidas son estadísticamente significativas, con p-valores extremadamente bajos ($p < 0,001$), lo que indica una relación estadísticamente robusta entre los predictores y la humedad superficial.

Los valores del Factor de Inflación de la Varianza (VIF) fueron inferiores a 2 en todas las variables, descartando la presencia de multicolinealidad.

En términos de bondad de ajuste, el modelo presentó un R^2 y un R^2 ajustado de 0,03 que indica que el conjunto de variables explicativas logra explicar aproximadamente un 3 % de la variabilidad observada en la humedad superficial. Aunque los valores son bajos, los estadísticos globales F y Wald resultaron altamente significativos, lo que confirma que el modelo posee capacidad explicativa a nivel global.

No obstante, los diagnósticos del modelo evidencian limitaciones importantes. El estadístico Koenker (BP) fue altamente significativo ($p < 0,001$), indicando la presencia de heterocedasticidad, es decir, que la relación entre la humedad superficial y las variables explicativas no es constante en todo el espacio. Asimismo, el estadístico Jarque-Bera también resultó significativo ($p < 0,001$), lo que indica que los residuos no siguen una distribución normal (*anexo 9.6*).

5.4. Resultados a escala municipal

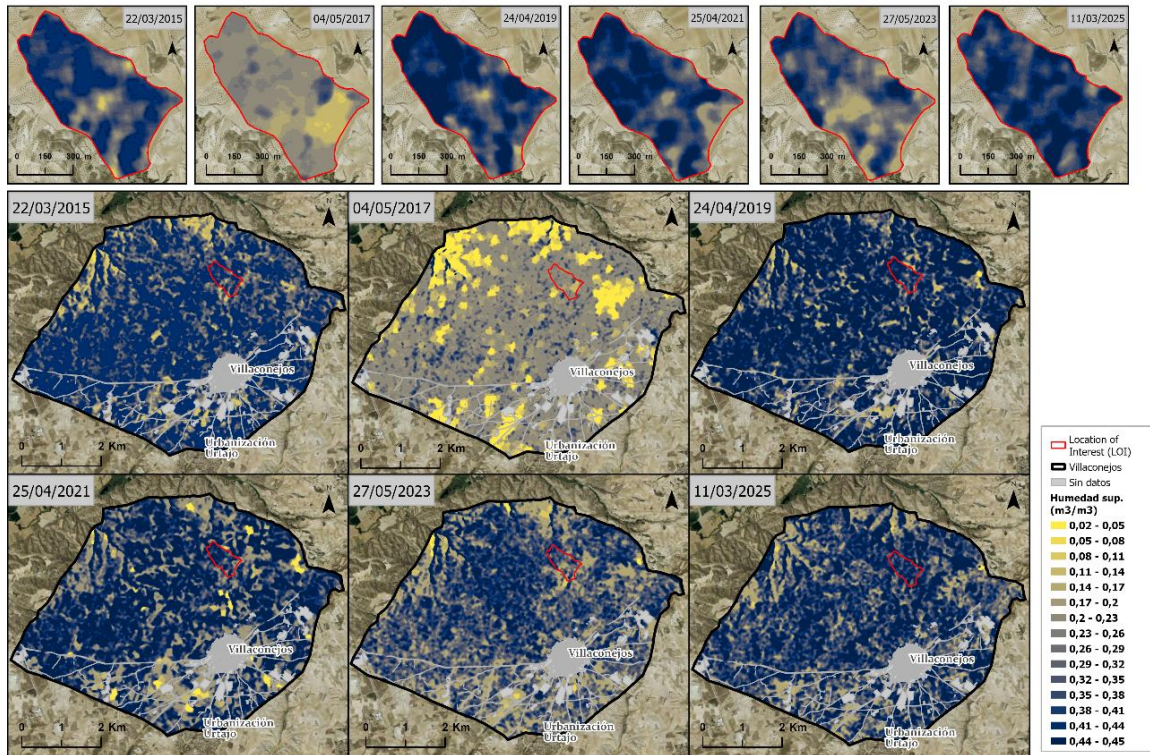
El análisis de los mapas a nivel del municipio de Villaconejos evidencia la gran variabilidad espacial de la humedad superficial, manteniendo una coherencia espacial con los patrones observados en la escala de parcela.

A pesar de la mayor extensión geográfica, es posible identificar variaciones claras en la serie temporal. La comparación interanual muestra que los valores generales de humedad superficial son consistentemente menores en los periodos húmedos de los años 2017 y 2023 en comparación con el resto de los años analizados, siendo 2017 particularmente seco.

Las imágenes a nivel municipal permiten destacar la dinámica dentro de un Lugar de Interés (LOI), que fue definido como una subzona específica para visualizar con mayor detalle las variaciones locales de la humedad superficial. A través de los seis años, el LOI refleja una tendencia descendente en sus valores de humedad media en ambos periodos. Sin embargo, el mapa correspondiente al último año de la serie (2025) del periodo seco, muestra un incremento en la humedad superficial en comparación con los años inmediatamente anteriores (2023 y 2024), lo que representa una reversión de la tendencia de desecación observada previamente en el LOI (*mapa 7 y 8*).

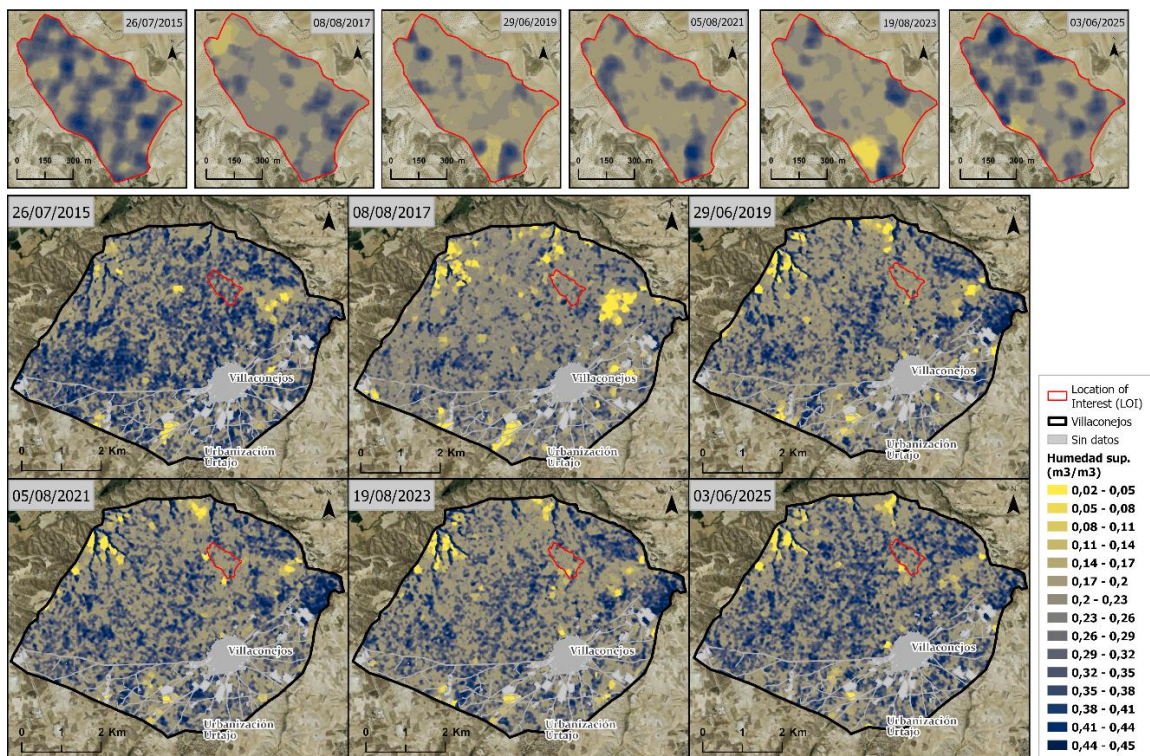
Para el periodo seco (*mapa 8*), es posible observar que el año con mayores tonos amarillos, es decir, con mayor sequedad en el suelo corresponde al año 2017 y 2021. Aunque no es posible, ver una tendencia decreciente como si ocurría a nivel de parcela.

Humedad del suelo durante el periodo húmedo (marzo-mayo)



Mapa 7. Composición cartográfica con los mapas de humedad superficial a nivel municipal en el periodo húmedo. Contains modified Copernicus Sentinel data [2015–2025].

Humedad del suelo durante el periodo seco (junio-agosto)



Mapa 8. Composición cartográfica con los mapas de humedad superficial a nivel municipal en el periodo seco. Contains modified Copernicus Sentinel data [2015–2025].

5.5. Análisis de variaciones por periodo seco y húmedo

En este apartado se analizó la variación que existe entre los periodos secos y húmedos de la humedad media.

Distribución de humedad por rugosidad y periodo




Gráfico 4. Diagrama box-plot de la variación de la humedad por rugosidad y periodo.

El gráfico 4 indica que entre el 2015–2019, las cajas son más altas y amplias, lo que muestra mayor variabilidad de humedad. A partir de 2021–2025, las cajas se estrechan y bajan, lo que sugiere condiciones más homogéneas o secas. Las medianas tienden a bajar ligeramente con los años, lo que puede apuntar a una tendencia a menor contenido de agua en el suelo.

En todos los periodos a excepción del año 2017, la caja de los periodos “Húmedo” está por encima del periodo “Seco”, algo que es consistente con lo esperado (suelo más húmedo al haber mayor precipitación). Sin embargo, las diferencias no siempre son grandes: en algunos años (2023, 2025) las cajas se solapan casi totalmente, indicando condiciones similares entre ambas categorías (quizá una estación seca menos marcada o un suelo con alta retención).

En el eje Y, la humedad varía entre ~0,02 y ~0,45 m³/m³. Los valores altos (~0,4–0,45) corresponden a 2015–2019, y los bajos (~0,1–0,2) a 2023–2025. Esto indica que las condiciones más húmedas se concentraron en los primeros años.

5.6. Relación entre retrodispersión, rugosidad y humedad

Se ha realizado una comparación temporal entre la retrodispersión (decibelios, dB) y la humedad superficial media del suelo (m^3/m^3) durante los períodos secos de los años 2015 a 2023. En el *gráfico 5*, las barras azules oscuras ilustran la retrodispersión.

Paralelamente, la línea azul punteada corresponde a la humedad media del suelo. En el periodo analizado se observa una tendencia general decreciente, aunque con fluctuaciones interanuales. En 2015 (periodo húmedo), los valores se sitúan en torno a $0.4 m^3/m^3$, seguidos de una disminución marcada hasta aproximadamente $0.25 m^3/m^3$ en 2017. Posteriormente, en 2019 se registra una recuperación, alcanzando un máximo cerca de $0.4 m^3/m^3$, mientras que en 2021 se presenta un nuevo descenso hasta valores cercanos a $0.35 m^3/m^3$. En 2023, la humedad media continúa decreciendo hasta alrededor de $0.3 m^3/m^3$. Finalmente, se observa un nuevo incremento de la humedad en 2025.

La humedad media estimada durante el periodo seco comienza en aproximadamente $0.35 m^3/m^3$ y exhibe una tendencia descendente general con variaciones interanuales: cae hasta $0.31 m^3/m^3$ en 2016, y continúa decreciendo hasta $0,3 m^3/m^3$ en 2019, se mantiene estable en 2021 y 2023, y finalmente cae abruptamente hasta $0,25 m^3/m^3$ en el último año. En términos interpretativos, estos resultados sugieren una relación positiva entre la retrodispersión y la humedad, es decir, a mayor humedad en el suelo mayores niveles de retrodispersión, y viceversa.

Retrodispersión y humedad media por Año/Periodo

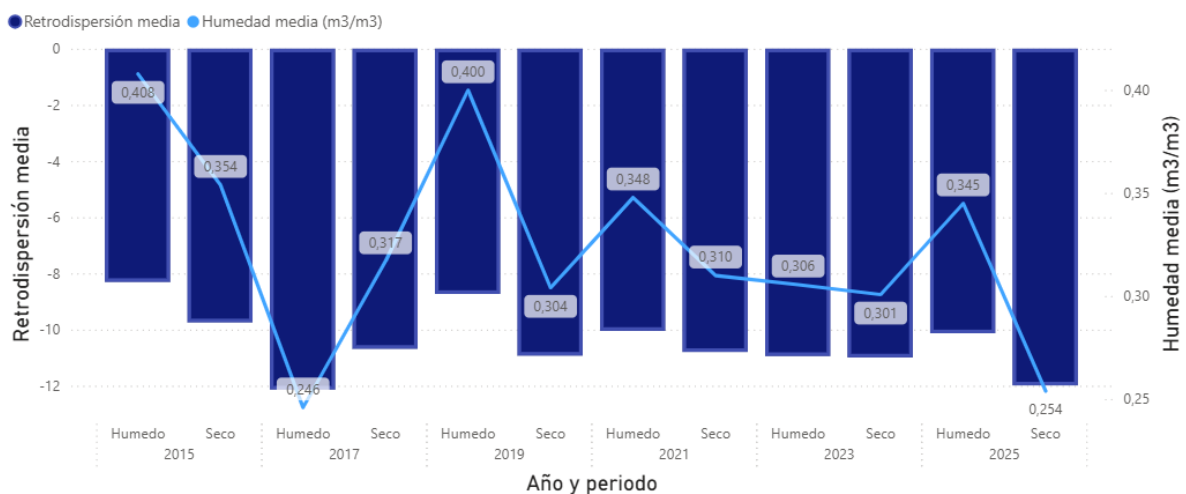


Gráfico 5. Diagrama de barras con la retrodispersión y humedad media por año y periodo.

A su vez, se ha querido analizar si existe relación y como es, entre la retrodispersión y la rugosidad del terreno. Para ello, se representa la variación de la retrodispersión media en función de la rugosidad, mediante un diagrama de dispersión con puntos azules que ilustran la relación entre estas dos variables. En el eje vertical (ordenadas) se indica la retrodispersión media, que oscilan aproximadamente entre -16 y -8 dB. Los puntos comienzan en un valor bajo de retrodispersión alrededor de -16 dB para una rugosidad de 1, y muestran una tendencia ascendente casi lineal a medida que la rugosidad aumenta, y alcanzando aproximadamente -9 dB en una rugosidad 10, con una ligera curvatura hacia el final que

sugiere una posible saturación o no linealidad en valores altos. No se observa una línea de tendencia explícita, pero los puntos están alineados de manera consistente, indicando una correlación positiva fuerte.

Los valores de rugosidad que se muestran en el eje X del *gráfico 6* corresponden a categorías de rugosidad, que representan los siguientes rangos en cm:

| Categoría | Rango (cm) |
|-----------|-------------|
| R1 (1) | 0,85 a 0,95 |
| R2 (2) | 0,96 a 1,06 |
| R3 (3) | 1,07 a 1,16 |
| R4 (4) | 1,17 a 1,27 |
| R5 (5) | 1,28 a 1,37 |
| R6 (6) | 1,38 a 1,48 |
| R7 (7) | 1,49 a 1,59 |
| R8 (8) | 1,6 a 1,69 |
| R9 (9) | 1,7 a 1,79 |
| R10 (10) | 1,8 a 1,89 |
| R11 (11) | 1,9 a 2 |

Tabla 10. Categorías de los rangos de rugosidad analizados.

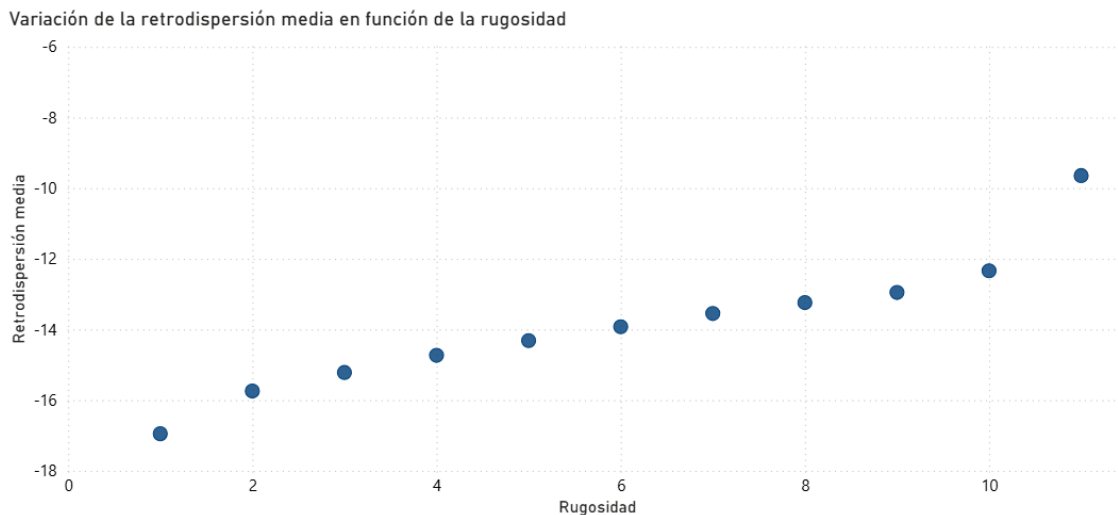


Gráfico 6. Gráfico de puntos con la variación de la retrodispersión media en función de la rugosidad.

6. Discusión

Diversos estudios han estimado la humedad superficial del suelo a partir de datos SAR mediante modelos físicos, enfoques estadísticos y técnicas de aprendizaje automático. Aunque la integración de modelos de dispersión radar con análisis espacial no es novedosa, su aplicación en entornos semiáridos mediterráneos con datos Sentinel-1 sigue en desarrollo. Entre los enfoques alternativos destacan los métodos basados en aprendizaje automático, como el propuesto por Ezzahar et al. (2020) mediante Support Vector Machine (SVM), así como enfoques híbridos que combinan datos SAR y ópticos, como los de Bousbih et al. (2018), basados en la inversión del Water Cloud Model (WCM) con Sentinel-1 y Sentinel-2, y Xing et al. (2019), que emplearon una versión modificada del WCM (MWCM) con

datos RADARSAT-2. En comparación, los resultados de este trabajo, obtenidos a partir de la inversión combinada de los modelos de Dubois y Hallikainen, muestran una capacidad razonable para captar la dinámica espacial de la humedad superficial del suelo. No obstante, es necesaria una validación adicional con datos in situ o al menos de forma indirecta con sensores pasivos como SMOS o SMAP, para evaluar el ajuste del modelo y su margen de error.

En comparación con estos enfoques, los resultados obtenidos en este trabajo a partir de la inversión combinada de los modelos de Dubois y Hallikainen indican que la metodología propuesta presenta una capacidad razonable para capturar la dinámica espacial de la humedad superficial del suelo, especialmente durante los periodos secos. Este comportamiento es coherente con lo descrito en la literatura, donde se señala que los modelos semiempíricos basados en retrodispersión radar tienden a ofrecer mejores resultados en condiciones de baja a moderada humedad y escasa cobertura vegetal. No obstante, resulta necesario llevar a cabo una validación adicional con datos in situ que permita cuantificar el ajuste del modelo a la realidad y estimar el margen de error asociado.

Entre los beneficios del uso de la metodología de emparejamiento con VBA (Blayney & Sun, 2019), destaca la capacidad para manejar grandes cantidades de datos en un entorno como Excel, asegurando resultados reproducibles y minimizando errores humanos. Este método ayudó a reducir inconsistencias no deseadas y mejoró la uniformidad espacial en las estimaciones de humedad, lo que facilitó una comparación más precisa entre datos reales y simulados.

Sin embargo, presenta ciertas limitaciones: depende de una estructura rígida en las hojas de cálculo, puede ser menos eficiente para conjuntos de datos muy grandes en comparación con lenguajes como Python o R (Ronak et al., 2025), y utiliza criterios simplificados (como la distancia euclidiana y el promedio de vecinos) que no reflejan toda la complejidad espacial del fenómeno.

En resumen, este script ofrece una solución práctica para el preprocesamiento y ajuste inicial de datos en estudios de humedad superficial, siendo una herramienta útil y accesible dentro de las limitaciones mencionadas.

La metodología empleada para estimar valores de humedad del suelo parece que a nivel visual tiene coherencia, ya que, los mapas resultantes muestran la compleja dinámica espacial. A su vez, hay grandes cambios notorios, desde zonas muy húmedas a zonas muy secas, pero de forma gradual. Lo que considero que se puede asemejar más a la realidad (Bohn, 2024; Hu et al., 2025). Las zonas con menos contenido en agua que se observan en la zona sur y sureste pueden estar relacionadas con el camino que bordea la parcela, donde normalmente el uso de este provoca la compactación y la degradación del ese suelo. Coincidiendo así, con valores más bajos de humedad. Las zonas excesivamente húmedas se pueden dar primero por sobrestimaciones de los valores, ya que, el modelo de Dubois tiene una serie de limitaciones (véase el apartado 2.5.1), con valores de humedad superiores a $0,35 \text{ m}^3/\text{m}^3$. Aunque también, es cierto que influyen otras variables como la textura y profundidad del suelo, la vegetación, o las prácticas agrarias que hagan en esas parcelas (Scholz et al., 2024; Gaur & Mohanty, 2016). A grandes rasgos se puede visualizar un decrecimiento de

los valores de humedad entre los años 2015 y 2025 o en el aumento de tonos amarillos en la parcela. Dando a entender que el suelo está perdiendo la capacidad de retener humedad o las precipitaciones son menores o menos recurrentes, etc. (Mulvihill, 2021; Wang et al., 2025).

En el periodo húmedo es más complicado afirmar lo anterior, ya que, los valores de humedad que se representan son bastante más altos a los del periodo húmedo. Lo que coincide con la hipótesis, de que al analizar imágenes de días donde previamente ha llovido, el radar y los modelos de estimación debían reflejarlo, y así es. En este periodo, el año 2017 muestra una rareza frente al resto de años estudiados. Esta muestra unos menores valores de humedad del suelo, con gran contraste con la media de los del resto de años. Los valores recopilados por la AEMET los días antes como la temperatura máxima y mínima o la precipitación registrada, no muestran diferencias grandes con el resto de los años. Por lo que no está claro esta diferencia tan grande.

Sin embargo, la interpretación de estas tendencias a partir de datos SAR debe realizarse con cautela, considerando las limitaciones inherentes al modelo de inversión de Dubois empleado. Este modelo es altamente sensible a la parametrización de la rugosidad superficial y a las propiedades dieléctricas; una estimación imprecisa de estas variables, o la falta de homogeneidad temporal en las fechas de adquisición de Sentinel-1, puede introducir errores significativos. Es crucial reconocer que el modelo de Dubois pierde precisión en condiciones extremas. Según Dubois et al. (1995), en estados próximos a la saturación (valores superiores a $0,35 \text{ m}^3/\text{m}^3$), la constante dieléctrica elevada genera procesos de dispersión volumétrica y atenuación que el modelo no representa adecuadamente.

Respecto a la influencia de la vegetación en la estimación de la humedad superficial del suelo a partir de datos SAR, ha sido ampliamente reconocida en la literatura. Singh et al. (2020), por ejemplo, procesaron imágenes Sentinel-1A aplicando una versión modificada del modelo de Dubois para estimar la permitividad relativa del suelo a partir de la retrodispersión radar (σ^0), y posteriormente derivaron la humedad volumétrica por píxel mediante el modelo universal de Topp, una relación empírica que vincula la permitividad dieléctrica del suelo con su contenido de agua volumétrico de forma independiente del tipo de suelo. Con el objetivo de minimizar la interferencia de la vegetación sobre la señal radar, estos autores aplicaron una máscara excluyendo los píxeles con valores de NDVI superiores a 0,4, siguiendo el criterio propuesto originalmente por Dubois, lo que permitió generar mapas de humedad más representativos de las condiciones reales del suelo desnudo.

Finalmente, la fiabilidad de las estimaciones también se ve condicionada por factores climáticos que alteran la señal radar, como la lluvia interceptada o el suelo congelado (Benninga et al., 2019). En este estudio, el enfoque centrado en periodos secos y húmedos claramente diferenciados ha permitido mitigar parcialmente estas perturbaciones, facilitando una interpretación más robusta. Aun así, la marcada tendencia hacia la sequedad detectada en 2025 refuerza la necesidad de integrar información auxiliar o enfoques híbridos en el futuro para asegurar que las variaciones observadas reflejen fielmente la realidad física del suelo y no sesgos metodológicos del algoritmo de inversión.

Por otro lado, el análisis de autocorrelación de Moran's I muestran que, aunque la capacidad explicativa global de las variables explicativas usadas en los modelos es baja (R^2 ajustado máximo de 0,03), todas las variables analizadas ejercen una influencia estadísticamente significativa sobre la humedad superficial. Esto sugiere que cada factor contribuye parcialmente a su distribución espacial, pero que existen otros elementos no considerados que explican la mayor parte de la variabilidad.

La variable MDT es positiva, es decir, indica que las zonas situadas a mayor altitud tienden a registrar valores ligeramente superiores de humedad superficial, lo que podría estar relacionado con condiciones microclimáticas más húmedas o con menor evaporación (Li et al., 2022). Estos resultados tienen buena correspondencia con los mostrados en Radula et al. (2018). Las orientaciones presentan un efecto negativo, lo que sugiere que las más expuestas al sol (habitualmente sur o suroeste en el hemisferio norte) muestran menores valores de humedad (Wang et al., 2025). La pendiente manifiesta un comportamiento mixto, reflejando que las pendientes moderadas pueden favorecer la retención de agua, mientras que las más pronunciadas facilitan su escorrentía (Bao et al., 2024). El Índice Topográfico de Humedad (TWI) mantiene una relación positiva, indicando que las áreas topográficamente convergentes o con potencial de acumulación hídrica concentran mayores valores de humedad (Liu et al., 2024). Por último, el resultado del índice NDVI, se asocia negativamente con la humedad del suelo, probablemente debido al incremento de la evapotranspiración en áreas con vegetación más densa (Scholz et al., 2024).

Los bajos valores del R^2 ajustado ponen de manifiesto que la relación entre la humedad superficial y las variables topográficas y vegetativas es compleja y no lineal, y que otros factores como la textura del suelo, la infiltración, la cobertura superficial o las condiciones meteorológicas recientes pueden tener un papel más determinante (Scholz et al., 2024; Gaur & Mohanty, 2016). Por último, los bajos valores de VIF confirman la independencia estadística entre los predictores empleados.

Otros estudios como los de Yin et al. (2025) aplicaron el análisis exploratorio de Moran's I a mediciones de humedad del suelo en un área kárstica de China y hallaron índices positivos significativos.

Los resultados obtenidos con el modelo OLS son similares a los obtenidos por el análisis exploratorio. Y nos corroboran que las variables explicativas empleadas, contribuyen de manera significativa individualmente a explicar la variación espacial de la humedad superficial. A su vez, tampoco hay problemas de colinealidad, por tanto, cada variable se complementa sin redundancia excesiva. Sin embargo, el poder explicativo global es bajo o limitado, dando a entender que hay otras variables o condicionantes que no estamos teniendo en cuenta como el uso del suelo, tipo de suelo (textura, materiales, ...), radiación incidente, etc.

Este análisis no cumple con los supuestos de homocedasticidad ni de normalidad de los residuos. Por lo tanto, aunque los coeficientes sean significativos, la estructura espacial subyacente no está bien representada.

Esto sugiere que la relación entre la humedad superficial y sus factores explicativos es no estacionaria, y que metodologías espaciales más avanzadas, como la Regresión Geográficamente Ponderada (GWR), serían más adecuadas para describir y comprender los patrones observados. En síntesis, el análisis confirma que la humedad superficial no se distribuye aleatoriamente, sino que muestra agrupamientos espaciales significativos, y que un enfoque global resulta insuficiente para capturar esta complejidad espacial.

Existen otros trabajos que han empleado el mismo análisis de forma muy similar, pero con resultados muy distintos como los de Ahmadi et al. (2022), donde construyeron un modelo OLS en la provincia de Fars, Irán con la humedad superficial del suelo como variable dependiente y como explicativas precipitaciones, agua equivalente en nieve, índice de vegetación y pendiente topográfica. Su modelo OLS general logró un coeficiente de determinación $R^2 \approx 0,66$, indicando que estas variables pueden explicar parte de la distribución espacial de la humedad

Los mapas a nivel del municipio de Villaconejos muestran una dinámica espacial de la humedad del suelo aún más compleja. El resultado del downscaling provee de una calidad de detalle muy alta y coincidiendo con algunos aspectos de la naturaleza de la humedad superficial. Una obviedad sería encontrar valores más altos de humedad en zonas donde corra el agua en superficie como ríos, arroyos o barrancos, naturaleza que coincide con los barrancos observados en la zona noroeste.

El uso de una localización de interés (LOI) sirvió para apreciar el nivel de detalle obtenido, aunque no podemos afirmar tales cosas como que se observó un decrecimiento de los valores de humedad o no, ya que, cada año analizado en el LOI es distinta la visualización. Posiblemente debido a factores que no estamos teniendo en cuenta.

Los resultados obtenidos en este trabajo ponen de manifiesto una problemática similar a la descrita por Singh et al. (2020), especialmente al ampliar el análisis a escalas mayores como la del municipio de Villaconejos. En estas áreas, se observó una infraestimación de la humedad superficial en zonas con cobertura vegetal (espartales, pinares o cultivos herbáceos), debido a que la vegetación absorbe y dispersa la energía de microondas (atenuación y volume scattering), reduciendo la retrodispersión directa del suelo (Solorza, 2013). Como consecuencia, los procedimientos de inversión para suelo desnudo, como el de Dubois, interpretan erróneamente esta señal atenuada como condiciones de mayor sequedad. Este fenómeno refuerza la necesidad de emplear máscaras de NDVI o modelos que incorporen explícitamente la contribución de la vegetación al extrapolar datos a contextos con heterogeneidad de cobertura.

Ante esta limitación, el presente estudio demuestra la aplicabilidad real del método Empirical Bayesian Kriging Regression Prediction (EBK-RP) como una solución robusta para refinar la resolución de las estimaciones. Mientras que autores como Krivoruchko (2012) destacan al EBK como una alternativa superior al kriging ordinario en entornos de alta variabilidad, nuestra implementación de EBK-RP permitió realizar un proceso de downscaling de los 10 m originales de Sentinel-1 a una resolución de 2 m, similar a lo que hicieron Lötter y Le Maitre (2021) al interpolar la precipitación media anual en Sudáfrica y

con una serie de variables explicativas obtuvieron un mapa de precipitaciones desescalado. Esta mejora se fundamenta en el uso de variables explicativas (pendiente, orientación, TWI y NDVI) que poseen una resolución espacial superior a la variable de estudio, capturando la dinámica local de forma más precisa.

Este enfoque metodológico supera en detalle a propuestas previas, como la de Bauer-Marschallinger et al. (2018), quienes desarrollaron un downscaling a 1 km basado en un modelo de Change of Support. Aunque dichos autores lograron un RMSE de $0.04 \text{ m}^3/\text{m}^3$ en áreas agrícolas europeas, no incorporaron covariables topográficas de forma tan explícita como en este trabajo.

Siguiendo con el análisis de la distribución de humedad por rugosidad y periodo, parece que se puede intuir una tendencia temporal decreciente, ya que, si interpretamos los años como cronológicos, parece que el contenido hídrico del suelo disminuye progresivamente, lo que podría reflejar:

- Disminución de precipitaciones.
- Mayor evaporación por aumento de temperatura.
- Cambios en el tipo de cobertura (menos vegetación o cultivos).
- Efectos de compactación o menor infiltración.

Los resultados obtenidos muestran una relación positiva consistente entre la retrodispersión y la humedad superficial estimada, de modo que incrementos en el contenido de humedad volumétrica se asocian con valores más elevados de retrodispersión, mientras que condiciones más secas producen una disminución de la señal radar. Este comportamiento concuerda con los principios físicos de la interacción de las microondas con el suelo y ha sido ampliamente documentado en la literatura. Asimismo, se observó que un aumento de la rugosidad superficial conduce a una mayor retrodispersión, lo que confirma la influencia conjunta de los parámetros geométricos y dieléctricos en la respuesta radar, tal y como señalan diversos estudios basados en el análisis de series temporales de Sentinel-1 (Gao et al., 2018).

Al analizar la evolución temporal de estas relaciones, los resultados sugieren una tendencia progresiva hacia menores contenidos hídricos del suelo a lo largo del periodo de estudio. Este patrón, que se manifiesta tanto en la distribución de la humedad en función de la rugosidad como en la comparación entre periodos secos y húmedos, es coherente con los cambios observados en regiones mediterráneas, caracterizadas por una disminución de las precipitaciones, un aumento de las temperaturas y, en consecuencia, mayores tasas de evaporación. En trabajos previos, el análisis estadístico de series temporales de retrodispersión SAR ha permitido diferenciar entre superficies agrícolas con distinta disponibilidad hídrica, incluyendo la distinción entre parcelas irrigadas y no irrigadas (Gao et al., 2018), lo que refuerza la interpretación de que los patrones detectados en este estudio reflejan cambios reales en la dinámica hídrica del suelo.

Respecto al análisis de los datos de rugosidad, humedad y retrodispersión, se ha podido observar la relación positiva entre los niveles de retrodispersión y los valores de humedad detectados. Es decir, a mayor humedad volumétrica mayor retrodispersión, y viceversa.

Ocurre lo mismo con los valores de rugosidad, a mayor rugosidad, mayor retrodispersión. Esta dinámica podría indicar un aumento progresivo en la sequedad del suelo a lo largo de los años, potencialmente debido a factores climáticos como sequías prolongadas en regiones mediterráneas, lo que resalta la utilidad de estos indicadores para monitorear la sostenibilidad agrícola, como en viñedos en pendiente, donde la erosión y la productividad están vinculadas a la humedad edáfica.

6.1. Posibles mejoras y perspectivas futuras

La presencia de cobertura vegetal, como es el caso de los cultivos agrícolas, complica la estimación de humedad debido principalmente a que las plantas en desarrollo contienen un porcentaje importante de humedad. En correspondencia, la adquisición del sensor corresponderá a la respuesta combinada del agua presente en el suelo y del agua presente en la propia vegetación (Solorza, 2013). La presencia de vegetación desarrollada incrementará la respuesta de radar total.

Un enfoque efectivo para mitigar la ambigüedad introducida por la vegetación y la rugosidad consiste en focalizar la atención en las variaciones temporales a través de adquisiciones de imágenes de radar. El fundamento en este caso es asumir que las características promedio de rugosidad y vegetación permanecen casi inalteradas mientras que las variaciones en el contenido de humedad sí afectan a la señal de retrodispersión a lo largo del tiempo (Pierdicca et al., 2010; Balenzano et al., 2011).

Otra posible mejora consiste en generar una máscara que cubra la zona de cobija cubierta de la vegetación (olivos, encinas u otros árboles dispersos) con el fin de estimar con mayor precisión la humedad del suelo bajo estas cubiertas. En muchos olivares no se mantiene una cubierta vegetal, por lo que la medición de la humedad superficial no se ve afectada por la vegetación ruderal.

Para poder medir la humedad del suelo de manera precisa utilizando las imágenes de radar de Sentinel-1, intenté eliminar la influencia de la vegetación mediante la creación de una máscara. Para ello realicé una clasificación supervisada en ArcGIS Pro. Inicialmente, se realizaron pruebas con una cantidad limitada de datos, pero el resultado no era perfecto. Fue necesario ser muy meticuloso y proporcionar muchísimas muestras de entrenamiento de las copas de los olivos y del suelo desnudo. Este esfuerzo ha dado frutos, logrando una clasificación súper precisa que permitió identificar la cubierta vegetal con una exactitud muy alta. Adicionalmente, se ha ensayado una técnica más avanzada utilizando la herramienta “Train Deep Learning Model” de ArcGIS Pro, con la idea de que la inteligencia artificial reconociera los árboles de manera autónoma. Sin embargo, a pesar de los esfuerzos, el modelo de Deep Learning no logró alcanzar la precisión y confiabilidad necesarias para el análisis. Finalmente, no se llegó a usar esta máscara debido a que los conjuntos de píxeles categorizados como vegetación eran más pequeños que el propio píxel de la imagen radar. Si se opta por este tipo de enfoque para generar la máscara de vegetación, es fundamental considerar la resolución de las imágenes radar. En el caso de Sentinel-1, la resolución es de 10 m, mientras que las copas de los olivos se digitalizaron a partir de una ortofoto de máxima actualidad con resolución de 15 cm. Esta diferencia de resolución implica que cada píxel

radar abarca una superficie mucho mayor que la de las copas individuales que se pretende enmascarar. Por ello, no es posible identificar cada árbol de forma separada a partir de las imágenes de Sentinel-1. Para que la metodología fuera plenamente coherente a nivel de objeto, sería necesario emplear imágenes radar con resolución igual o superior al tamaño de las copas.

Otras formas de mejorar este trabajo de fin de máster son con la obtención de imágenes radar de alta resolución. Si optamos por radares de libre acceso como Sentinel, su portal de descarga otorga la opción de descargar imágenes en modo StripMap, las cuales alcanzan resoluciones de 3 m, aunque suelen tener menos resolución temporal. Por otro lado, hay compañías como AIRBUS o dentro del portal de la Agencia Espacial Europea – ESA a las que se pueden encargar imágenes de TerraSAR-X, TanDEM-X (teniendo en cuenta que estos dos ejemplos trabajan con banda X) con motivos científicos.

La metodología llevada a cabo en este trabajo, es posible automatizarla usando Google Earth Engine (GEE), ya que tiene acceso a imágenes Sentinel-1. De esta forma, es posible aumentar el número de años analizados sin tener que dedicar tanto tiempo. También, es posible aplicar los preprocesamientos en el servicio de GEE.

Considero que es fundamental mantener la consistencia en los parámetros de adquisición de las imágenes Sentinel-1 para optimizar la comparación. Sin embargo, en el desarrollo de este trabajo, fue necesario utilizar imágenes de radar adquiridas tanto en órbita descendente como ascendente. Esta variación en la dirección de la órbita implica un cambio significativo en la geometría de observación (es decir, el ángulo y la dirección en que el radar 'ilumina' la superficie). Este cambio es crucial porque, en zonas con relieve o pendientes marcadas, la retrodispersión observada se ve notablemente afectada por la orientación de los elementos de la superficie, como los surcos del laboreo (anisotropía de la rugosidad). Por lo tanto, la retrodispersión medida sobre un mismo punto puede cambiar drásticamente dependiendo de si la imagen fue tomada de forma ascendente o descendente.

A su vez, sería interesante hacer este mismo análisis usando imágenes de satélite con banda L, ya que, estos sensores son capaces de penetrar más centímetros en el suelo y a estar menos influenciada la onda a la rugosidad del terreno, debido a la longitud de onda (mayor que en banda C).

Una posible mejora en la metodología de estimación de la humedad del suelo habría sido la implementación de modelos físicos de retrodispersión, como el Modelo de Ecuación Integral (IEM). El modelo IEM es considerado una formulación unificada porque combina los enfoques de modelos más simples: el Modelo de Kirchhoff (que funciona bien para superficies muy lisas o muy rugosas) y el Modelo de Pequeña Perturbación (SPM) (que se limita a superficies poco rugosas). Esta combinación de fundamentos teóricos dota al IEM de la gran ventaja de poder aplicarse en un espectro mucho más amplio de condiciones de rugosidad superficial que los modelos anteriores, haciendo su aplicación potencialmente más precisa en terrenos heterogéneos. El IEM reproduce la retrodispersión de la superficie a partir de dos parámetros clave de rugosidad, la desviación estándar de las alturas del terreno (s) y la longitud de correlación (l), junto con la permitividad dieléctrica y los parámetros de

observación del sensor. A pesar de su robustez y de ser uno de los modelos más empleados en la literatura (Solorza, 2013), su complejidad matemática elevada para replicarlo en hojas de cálculo y la dificultad inherente en la obtención precisa de sus parámetros de entrada (especialmente la longitud de correlación en amplias zonas) fueron las razones principales por las que decidí no utilizar el modelo IEM en este estudio.

Por último, la necesidad de validar los resultados obtenidos de humedad es fundamental para poder asumir que la metodología empleada es útil o mínimamente cercana a la realidad. Para ello, lo que considero más preciso, es realizar trabajo de campo y tomar muestras *in situ*. Si esto no es posible, hay herramientas que permiten hacer una validación indirecta. Los productos globales obtenidos mediante radiometría pasiva, como SMAP (Soil Moisture Active Passive) de la NASA y SMOS (Soil Moisture and Ocean Salinity) de la ESA, proporcionan estimaciones consistentes y validadas de la humedad del suelo a escala global, con resoluciones espaciales del orden de 25 a 36 km y una frecuencia de revisita de entre dos y tres días.

La utilización de estos conjuntos de datos permitiría realizar una validación indirecta de los resultados obtenidos a partir de sensores SAR, especialmente en áreas donde la disponibilidad de mediciones *in situ* es limitada. Para ello, sería necesario adaptar la escala espacial de los productos derivados de radar (por ejemplo, mediante agregación o promedio espacial) a la resolución de los datos SMAP o SMOS, de modo que las comparaciones sean coherentes y permitan evaluar la correspondencia espacial y temporal entre ambas fuentes. Este enfoque contribuiría a identificar posibles sesgos sistemáticos y a mejorar la robustez del modelo de estimación desarrollado.

De cara al futuro, la combinación de observaciones activas (SAR) y pasivas (radiometría) podría constituir una herramienta poderosa para mejorar la precisión y estabilidad de las estimaciones de humedad superficial, aprovechando las ventajas complementarias de ambas tecnologías.

6.2. Limitaciones de los modelos empleados

El modelo de Hallikainen usado para estimar la constante dieléctrica, presenta algunos puntos débiles, debido a los coeficientes, los cuales solo se ajustan a unas pocas frecuencias radar específicas. A esto se suma que el número de muestras usadas para calibrar el modelo es muy reducido (menos de 100), lo que limita su fiabilidad (Quan et al., 2014).

Por otro lado, el modelo de Dubois presenta una limitación importante: sus resultados dependen mucho de las condiciones del lugar donde se tomaron las mediciones, lo que significa que solo es válido dentro de ese contexto. Por esa razón, hoy en día se utiliza con menos frecuencia que otros modelos.

Los resultados son algo delicados de interpretar debido a que el modelo de Dubois está definido para valores de humedad por debajo del 35% o $0,35 \text{ m}^3/\text{m}^3$, lo cual todos los valores estimados superiores a $0,35 \text{ m}^3/\text{m}^3$ han podido ser subestimados o sobrestimados, y no reflejar la realidad. En nuestro caso, para el periodo seco aproximadamente el 16% de todos

los píxeles están por encima de $0,35 \text{ m}^3/\text{m}^3$, sin embargo, este porcentaje aumenta en el periodo húmedo hasta el 57% de todos los píxeles calculados.

Respecto a la regresión de Mínimos Cuadrados Ordinarios (OLS), si bien proporciona una idea general y bastante sólida sobre la dirección y la fuerza de la relación entre las variables, el análisis diagnóstico de los resultados revela importantes limitaciones que comprometen la validez y la eficiencia del modelo, y, por ende, sugieren que un enfoque geoespacial es indispensable.

En primer lugar, se observa un bajo coeficiente de determinación, lo que indica que el modelo en su conjunto no explica una porción significativa de la varianza total de la humedad del suelo; esto implica que la variación de la humedad del suelo responde a un número mayor de factores (biofísicos, temporales, o intrínsecos del suelo) que los predictores elegidos, o bien, que la relación entre la humedad y los predictores no es estrictamente lineal y cambia en el espacio.

Sumado a esto, se detecta que la dispersión de los errores no es constante, un fenómeno conocido como heterocedasticidad, esto viola uno de los supuestos fundamentales de OLS al indicar que la varianza del error no es uniforme en todas las observaciones; esta inconstancia en la varianza de los errores sugiere que el modelo posee un poder predictivo desigual según la ubicación, y además, es un indicio fuerte de una posible falta de estacionariedad espacial, lo cual implica que las relaciones funcionales (los coeficientes de regresión) probablemente no son las mismas en todos los lugares.

El análisis de los errores se profundiza con la confirmación de que los residuos de los cálculos no siguen una distribución normal, lo cual es una violación crítica del supuesto de normalidad en OLS. Esta desviación de la normalidad es particularmente importante en este contexto geoespacial porque sugiere fuertemente que el modelo lineal simple está omitiendo la detección de patrones sistemáticos en el espacio, lo cual puede estar relacionado directamente con la presencia de autocorrelación espacial en los errores; en otras palabras, las localizaciones cercanas tienden a tener errores de predicción similares (los residuos se agrupan en valores positivos o negativos), demostrando que la información espacial importante no está siendo capturada por las variables independientes o por la estructura lineal del modelo, comprometiendo así la validez de las pruebas estadísticas y requiriendo la implementación de modelos de regresión espacial.

En resumen, el análisis de la regresión OLS deja en evidencia que la humedad superficial del suelo es una variable que presenta una marcada variabilidad espacial, un resultado habitual dada la influencia de la topografía, la vegetación y otros factores ambientales. El modelo OLS confirma que todas las variables topográficas y espectrales consideradas tienen una influencia estadísticamente significativa sobre la humedad superficial; sin embargo, su carácter global limita la capacidad del modelo para capturar adecuadamente procesos locales y relaciones espacialmente no estacionarias. Esta limitación se manifiesta en un efecto global relativamente débil y en la presencia de autocorrelación espacial en los residuos, lo que sugiere que una parte sustancial de la estructura espacial del fenómeno no es explicada por el modelo.

Ante este escenario, el OLS no resulta adecuado como herramienta predictiva final, pero cumple un rol fundamental como análisis diagnóstico inicial, al poner de relieve la necesidad de emplear modelos más avanzados que incorporen explícitamente la variación espacial. En este sentido, metodologías como la Regresión Geográficamente Ponderada (GWR) permiten abordar la no estacionariedad espacial de las relaciones al estimar coeficientes locales, mientras que enfoques que modelan directamente la estructura del error, como la Predicción por Regresión Kriging Bayesiano Empírico (EBKRP), ofrecen una alternativa más integral.

La técnica EBKRP emerge como una mejora sustancial al combinar la regresión lineal con el kriging, lo que le permite no solo utilizar los predictores ambientales, sino también modelar y explotar la autocorrelación espacial presente en los residuos del modelo OLS, una de las principales causas de su ineficiencia predictiva. Como resultado, esta metodología incrementa la capacidad predictiva y proporciona una cuantificación de la incertidumbre más robusta y espacialmente coherente que la obtenida mediante técnicas de regresión puras.

7. Conclusiones

Este estudio ha desarrollado una metodología integrada para la estimación y cartografía multitemporal de la humedad superficial del suelo (HS) en entornos agrícolas semiáridos de clima mediterráneo. La propuesta combina modelos físicos de retrodispersión radar (Hallikainen y Dubois) con técnicas geoestadísticas avanzadas (Empirical Bayesian Kriging Regression Prediction, EBK-RP), utilizando imágenes Sentinel-1 en polarización VV.

- Las pruebas metodológicas en una parcela piloto cerca de Balcón del Tajo permitieron su posterior aplicación general en todo el municipio de Villacanejos lo que ha permitido extrapolar metodologías y demostrar aplicabilidad.
- Los resultados muestran que la humedad del suelo varía espaciotemporalmente, con una tendencia clara hacia condiciones más secas entre 2015 y 2025, especialmente en verano.
- Existe una relación positiva entre la señal radar y la humedad del suelo, lo que confirma que el SAR es sensible a las propiedades del suelo, y además la rugosidad superficial.
- El análisis de sensibilidad indica que la humedad del suelo es el factor que más afecta a la retrodispersión, seguido de la rugosidad.
- A escala municipal, los mapas de Villacanejos revelan patrones claros de aridificación a lo largo del tiempo y una ligera recuperación en 2025.
- Otras variables del terreno y la vegetación también poseen influencia, aunque de forma no lineal, justificando el uso de Geoestadística e Interpolaciones con variables independientes.
- La aplicación de interpolaciones geoestadísticas en datos SAR de 10 metros a partir de variables independientes son una excelente metodología para aumentar la resolución (desescalado/resampléo) de los resultados de estimación de la humedad.

- El flujo de trabajo de estimación por modelos Hallinkanen y Dubois, aplicados a imágenes Sentinel-1 y con un proceso de desescalado/resamplero posterior por interpolación, es inédito y no se ha encontrado en la bibliografía anteriormente.
- La metodología puede aplicarse con herramientas de libre acceso y resulta útil para la gestión sostenible del agua.
- Las mejoras propuestas incluyen integrar mejor la vegetación, usar datos SAR en banda L, aplicar modelos físicos más complejos, validar con satélites y mediciones en campo, y automatizar el proceso para generar series temporales largas.

En conjunto, el presente trabajo de fin de máster aporta una base sólida para la agricultura de precisión y para entender mejor la dinámica del agua en zonas semiáridas, proponiendo una nueva metodología que mejora el detalle sin depender de satélites privados de alta resolución.

8. Referencias bibliográficas

Agencia Espacial Europea (ESA). (s.f.). El programa Copérnico. Recuperado de https://www.esa.int/Space_in_Member_States/Spain/El_programa_Copernico

AHMADI, M., KAMANGAR, M., MOLANAZAR, G. AND MADANI, B. (2022). Evaluation of OLS regression models and GWR regression for modeling Spatial Soil Moisture, Case Study: Fars Province. *Journal of Environmental Studies*, 48(3), 403-418. doi: 10.22059/jes.2022.344444.1008329

ÁLVAREZ-MOZOS, J., CASALÍ, J., & GONZÁLEZ-AUDÍCANA, M. (2005). Teledetección radar como herramienta para la estimación de la humedad superficial del suelo en cuencas agrícolas. *Revista de Teledetección*, 23, 27–42

ÁLVAREZ-MOZOS, J., CASALÍ, J., GONZÁLEZ-AUDÍCANA, M., & LÓPEZ, J. J. (2005). Estimación de la humedad superficial del suelo mediante teledetección radar en presencia de una cubierta de cereal. En F. J. Samper Calvete & A. Paz González (Eds.), *Estudios de la Zona No Saturada del Suelo Vol VII*.

ÁLVAREZ-MOZOS, J., CASALÍ, J., GONZÁLEZ-AUDÍCANA, M., & VERHOEST, N. E. C. (2006). Assessment of the operational applicability of RADARSAT-1 data for surface soil moisture estimation. *IEEE Transactions on Geoscience and Remote Sensing*, 44(4), 913–924. <https://doi.org/10.1109/TGRS.2005.863456>

BAGHDADI, N., CRESSON, R., EL HAJJ, M., LUDWIG, R., & LA JEUNESSE, I. (2012, June 4). Estimation of soil parameters over bare agriculture areas from C-band polarimetric SAR data using neural networks. *Hydrology and Earth System Sciences*, 16(6), 1607–1621. <https://doi.org/10.5194/hess-16-1607-2012>

BALENZANO, A., MATTIA, F., SATALINO, G., & DAVIDSON, M. (2011). Dense temporal series of C- and L-band SAR data for soil moisture retrieval over agricultural crops. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(2), 439-450. <https://doi.org/10.1109/JSTARS.2010.2052916>

BAO, H., LANN, T., AO, X., YANG, L., LAN, H., & PENG, J. (2024). Evolution characteristic of soil water in loess slopes with different slope angles. *Geoenvironmental Disasters*, 11(1), Artículo 43. <https://doi.org/10.1186/s40677-024-00293-6>

BAUER-MARSCHALLINGER, B., FREEMAN, V., CAO, S., PAULIK, C., SCHAUFLE, S., STACHL, T., MODANESI, S., MASSARI, C., CIABATTA, L., BROCCA, L., & WAGNER, W. (2018). Toward global soil moisture monitoring with Sentinel-1: Harnessing assets and overcoming obstacles. *IEEE Transactions on Geoscience and Remote Sensing*, 57(1), 520-539. <https://doi.org/10.1109/TGRS.2018.2858004>

BEHARI, J. (2005). *Microwave dielectric behavior of wet soils*. Springer-Verlag. <https://doi.org/10.1007/3-540-28363-3>

BENNINGA, H.-J.F., VAN DER VELDE, R., & SU, Z. (2019). Impacts of Radiometric Uncertainty and Weather-Related Surface Conditions on Soil Moisture Retrievals with Sentinel-1. *Remote Sensing*, 11(17), 2025. <https://doi.org/10.3390/rs11172025>

BLAYNEY, P., & SUN, Z. (2019). Using Excel and Excel VBA for preliminary analysis in Big Data research. En Z. Sun (Ed.), *Managerial perspectives on intelligent Big Data analytics* (pp. 110-132). IGI Global. <https://doi.org/10.4018/978-1-5225-7277-0.ch007>

BOHN, VANESA. (2024). Variabilidad espacio-temporal de la humedad superficial del suelo en el sur de la llanura pampeana argentina. *Investigaciones Geográficas*. 85-104. 10.14198/INGEO.25373.

BOUSBIH, S., ZRIBI, M., EL HAJJ, M., BAGHDADI, N., LILI-CHABAANE, Z., GAO, Q., & FANISE, P. (2018). Soil Moisture and Irrigation Mapping in A Semi-Arid Region, Based on the Synergetic Use of Sentinel-1 and Sentinel-2 Data. *Remote Sensing*, 10(12), 1953. <https://doi.org/10.3390/rs10121953>

BUAH, P. A., YINGBIN, Z., MANTE, G., AKWASI, T.-A., & GYAMI, C. A. (2020). Soil moisture retrieval using SAR. *Global Scientific Journals*, 8(9). <https://www.globalscientificjournal.com/>

CHEN, K. L., CHEN, K. S., LI, Z. L., & LIU, Y. (2015). Extension and validation of an advanced integral equation model for bistatic scattering from rough surfaces. *Progress in Electromagnetics Research*, 152, 59–76. <https://doi.org/10.2528/PIER15022304>

Comisión Europea. (2019). El Pacto Verde Europeo (COM/2019/640 final). Oficina de Publicaciones de la Unión Europea. <https://www.consilium.europa.eu/es/politicas/european-green-deal/>

Confederación Hidrográfica del Tajo. (2022). Plan Hidrológico de la parte española de la Demarcación Hidrográfica del Tajo (2022-2027). Organismo de Cuenca, Ministerio para la Transición Ecológica y el Reto Demográfico.

Copernicus SentiWiki. (s.f.). S1 Mission - Satellite Description. Recuperado de <https://sentiwiki.copernicus.eu/web/s1-mission#S1-Mission-Satellite-Description>

CRUZ MACEÍN, J. L., & BENITO BARBA, A. (2014). Agricultura familiar periurbana y medio ambiente: Percepciones de los agricultores de la comarca agraria de Las Vegas (Comunidad de Madrid) (Serie Estudios IMIDRA. N.º 1). Consejería de Medio Ambiente y Ordenación del Territorio. Recuperado de https://www.comunidad.madrid/sites/default/files/aud/medio-ambiente/informe_agricultura_y_medio_ambiente_en_la_cm.pdf

Departamento de Edafología, Universidad de Granada. (s.f.). Lección 4. Dinámica agua en el suelo. Recuperado de <http://edafologia.ugr.es/introeda/tema04/otraspp.htm>

- DÍAZ SANTANA, A. (2016). Procesado de datos SAR del satélite Sentinel-1 para el estudio de zonas costeras [Proyecto fin de carrera, Universidad de Las Palmas de Gran Canaria]. Acceda CRIS. <https://accedacris.ulpgc.es/handle/10553/92185>
- DUBOIS, P. C., VAN ZYL, J., & ENGMAN, T. (1995). Measuring soil moisture with imaging radars. *IEEE Transactions on Geoscience and Remote Sensing*, 33(4), 915-926. <https://doi.org/10.1109/36.406677>
- EL HAJJ, M., BAGHDADI, N., ZRIBI, M., & BAZZI, H. (2017). Synergic use of Sentinel-1 and Sentinel-2 images for operational soil moisture mapping at high spatial resolution over agricultural areas. *Remote Sensing*, 9(12), 1292. <https://doi.org/10.3390/rs9121292>
- ENTEKHABI, D., et al. (2010). The Soil Moisture Active Passive (SMAP) mission. *Proceedings of the IEEE*, 98(5), 704–716.
- European Space Agency. (2023). SNAP help and documentation (Version 10.0) [Software manual]. <https://step.esa.int/main/doc/>
- EZZAHAR, J., OUAADI, N., ZRIBI, M., ELFARKH, J., AOUADE, G., KHABBA, S., ER-RAKI, S., CHEHBOUNI, A., & JARLAN, L. (2020). Evaluation of Backscattering Models and Support Vector Machine for the Retrieval of Bare Soil Moisture from Sentinel-1 Data. *Remote Sensing*, 12(1), 72. <https://doi.org/10.3390/rs12010072>
- FAO. (2015). El estado de los recursos de tierras y aguas del mundo para la alimentación y la agricultura (SOLAW): Gestionar los sistemas en riesgo. Organización de las Naciones Unidas para la Alimentación y la Agricultura. <https://openknowledge.fao.org/server/api/core/bitstreams/d6cdccdc-9f9e-4abc-b2d1-78d0351ffc37/content>
- FERREIRA, C. S. S., SEIFOLLAHI-AGHMIUNI, S., DESTOUNI, G., GHAJARNIA, N., & KALANTARI, Z. (2022). Soil degradation in the European Mediterranean region: Processes, status and consequences. *Science of The Total Environment*, 805, 150106. <https://doi.org/10.1016/j.scitotenv.2021.150106>
- Fondo Español de Garantía Agraria. (2025). Sistema de Información Geográfica de Parcelas Agrícolas (SIGPAC). ArcGIS Living Atlas de Esri. <https://www.arcgis.com/home/item.html?id=9211b53b3f954381ac79f713d71de221>
- FUNG, A. K., LI, Q., & CHEN, K. S. (1992). Backscattering from a randomly rough dielectric surface. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 356–369. <https://doi.org/10.1109/36.134085>
- GAO, Q., ZRIBI, M., ESCORIHUELA, M. J., BAGHDADI, N., & SEGUI, P. Q. (2018). Irrigation Mapping Using Sentinel-1 Time Series at Field Scale. *Remote Sensing*, 10(9), 1495. <https://doi.org/10.3390/rs10091495>

- GARCÍA-RUIZ, J. M., NADAL-ROMERO, E., LANA-RENAULT, N., & BEGUERÍA, S. (2013). Erosion in Mediterranean landscapes: Changes and future challenges. *Geomorphology*, 198, 20-36. <https://doi.org/10.1016/j.geomorph.2013.05.023>
- GAUR, N., & MOHANTY, B. P. (2016). Land-surface controls on near-surface soil moisture dynamics: Traversing remote sensing footprints. *Water Resources Research*, 52(8), 6365–6385. <https://doi.org/10.1002/2015WR018095>
- GAZNAYEE, H. A. A., ZAKI, S. H., AL-QURAIISHI, A. M. F., ALIEHSAN, P. H., HAKZI, K. K., RAZVANICHY, H. A. S., RIKSEN, M., & MAHDI, K. (2023). Integrating Remote Sensing Techniques and Meteorological Data to Assess the Ideal Irrigation System Performance Scenarios for Improving Crop Productivity. *Water*, 15(8), 1605. <https://doi.org/10.3390/w15081605>
- GIS & Beers. (8 de diciembre de 2016). Cálculo del índice NDVI. <https://www.gisandbeers.com/calculo-del-indice-ndvi/>
- GIS & Beers. (3 de julio de 2018). Cálculo del Índice Topográfico de Humedad (TWI). GIS & Beers. <https://www.gisandbeers.com/calculo-del-indice-topografico-de-humedad-twi/>
- GRALDI, G., ZARDI, D., & VITTI, A. (2023). Retrieving soil moisture at the field scale from Sentinel-1 data over a semi-arid Mediterranean agricultural area. *Remote Sensing*, 15(12), 2997. <https://doi.org/10.3390/rs15122997>
- HALLIKAINEN, M. T., ULABY, F. T., DOBSON, M. C., EL-RAYES, M. A., & LIN, C. (1985). Microwave Dielectric Behavior of Wet Soil—Part 1: Empirical Models and Experimental Observations. *IEEE Transactions on Geoscience and Remote Sensing*, GE-23(1), 25–34. <https://doi.org/10.1109/TGRS.1985.289497>
- HILLEL, D. (2004). *Introduction to environmental soil physics*. Elsevier Academic Press.
- HU, L., XIE, Y., LIU, Y., CHEN, S., YU, H., BIE, Q., ZHAO, F., & ZHAO, Y. (2025). Mapping the primary factors driving spatiotemporal variations of surface soil moisture in the Yellow River Basin of China. *Scientific Reports*, 15(1), Artículo 12359. <https://doi.org/10.1038/s41598-025-96129-w>
- HUANG, J., HUA, Y., ZHANG, Y., XU, W., GU, L., TIAN, Y., WU, Y., LONG, Q., WEI, H., & LI, M. (2024). The Impact of Extreme Precipitation on Soil Moisture Transport in Apple Orchards of Varying Ages on the Loess Plateau. *Water*, 16(22), 3322. <https://doi.org/10.3390/w16223322>
- IGNSpain. (20 de enero de 2021). (06) Curso de procesamiento de imágenes Sentinel con SNAP – Imágenes radar (Sentinel-1). YouTube. <http://www.youtube.com/watch?v=QK8J8huXzio>
- ISRIC – World Soil Information. (2020). SoilGrids – global gridded soil information. Available at: <https://soilgrids.org>

IPCC. (2021). Climate change 2021: The physical science basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Capítulo 8: Cambios en el ciclo del agua]. Cambridge University Press. <https://www.ipcc.ch/report/ar6/wg1/>

Instituto Geográfico Nacional (2005). España. Mapas edafológicos. escala 1:1.000.000. Instituto Geográfico Nacional <https://www.igme.es/cartografia/mapa-geologico>

JACKSON, T. J., SCHMUGGE, T. J., & ENGMAN, E. T. (1996). Remote sensing applications to hydrology: Soil moisture. *Hydrological Sciences Journal*, 41(4), 517–530.

JIMÉNEZ-DE-SANTIAGO, D. E., LIDÓN, A., & BOSCH-SERRA, À. D. (2019). Soil Water Dynamics in a Rainfed Mediterranean Agricultural System. *Water*, 11(4), 799. <https://doi.org/10.3390/w11040799>

KIM, J. (2023). Tracing Archaeological Places via the Context of Paleo Geomorphic Footprints Using SAR/InSAR Data Fusion: A Case on Southern Mesopotamia. *Remote Sensing*, 15(6), 1636. <https://doi.org/10.3390/rs15061636>

KONINGS, A. G. (2009). An Observing System Simulation Experiment for Soil Moisture Measurements from the SMAP Radiometer. Massachusetts Institute of Technology. <https://dspace.mit.edu/bitstream/handle/1721.1/70758/788564357-MIT.pdf?sequence=2&isAllowed=y>

KRIVORUCHKO, K. (2012). Empirical Bayesian kriging implemented in ArcGIS Geostatistical Analyst. *ArcUser*, 15(4), 6-10

LI, L., WU, D., WANG, T., & WANG, Y. (2022). Effect of topography on spatiotemporal patterns of soil moisture in a mountainous region of Northwest China. *Geoderma Regional*, 28, e00456. <https://doi.org/10.1016/j.geodrs.2021.e00456>

LIU, S., VAN MEERVELD, I., ZHAO, Y., WANG, Y., AND KIRCHNER, J. W. (2024): Seasonal dynamics and spatial patterns of soil moisture in a loess catchment, *Hydrol. Earth Syst. Sci.*, 28, 205–216, <https://doi.org/10.5194/hess-28-205-2024>, 2024.

LÖTTER, M. C., & LE MAITRE, D. (2021). Fine-scale delineation of Strategic Water Source Areas for surface water in South Africa using Empirical Bayesian Kriging Regression Prediction: Technical report. South African National Biodiversity Institute

MA, T., HAN, L., & LIU, Q. (2021). Retrieving the soil moisture in bare farmland areas using a modified Dubois model. *Frontiers in Earth Science*. <https://doi.org/10.3389/feart.2021.735958>

MARQUES, M. J., RUIZ-COLMENERO, M., GARCÍA-MUÑOZ, S., CABELLO, F., MUÑOZ-ORGANERO, G., PÉREZ-JIMÉNEZ, M. A., & BIENES, R. (2009). Protección contra la erosión versus productividad en viñedos. Ensayos de cubiertas vegetales en cultivos en pendiente. <https://digitum.um.es/server/api/core/bitstreams/11f0d5d5-0e2e-44a0-89e0-9fa3af151d6c/content>

MIMEAU, LOUISE & TRAMBLAY, YVES & BROCCA, LUCA & MASSARI, CHRISTIAN & CAMICI, STEFANIA & FINAUD-GUYOT, PASCAL. (2021). Modeling the response of soil moisture to climate variability in the Mediterranean region. *Hydrology and Earth System Sciences*. 25. 653-669. 10.5194/hess-25-653-2021.

Ministerio para la Transición Ecológica y el Reto Demográfico. (8 de abril de 2020). Mapa de Series de Vegetación Potencial [Base de Datos Naturaleza]. Recuperado de <https://edu.forestry.es/2020/04/mapa-de-series-de-vegetacion-de-rivas.html>

Ministerio para la Transición Ecológica y el Reto Demográfico. (2025). Orden TED/776/2025, de 8 de julio, por la que se actualiza la Estrategia Nacional de Lucha Contra la Desertificación en los términos previstos en la Ley 43/2003, de 21 de noviembre, de Montes, y se aprueba su Plan de Implementación para el periodo comprendido entre 2025 y 2027. *Boletín Oficial del Estado*, 175, 97596–97598. Recuperado de <https://www.miteco.gob.es/content/dam/miteco/es/biodiversidad/planes-y-estrategias/enld/anexo-i-enld.pdf>

MULVIHILL, K. (1 de junio de 2021). Erosion 101: Everything You Need to Know About Soil Erosion. NRDC (Natural Resources Defense Council). <https://www.nrdc.org/stories/erosion-101-everything-you-need-know-about-soil-erosion>

OH, Y., SARABANDI, K., & ULABY, F. T. (1992). An empirical model and an inversion technique for radar scattering from bare soil surfaces. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 370–381. <https://doi.org/10.1109/36.134086>

OH, Y. (2004). Quantitative retrieval of soil moisture content and surface roughness from multipolarized radar observations of bare soil surfaces. *IEEE Transactions on Geoscience and Remote Sensing*, 42(3), 596–601. <https://doi.org/10.1109/TGRS.2003.821065>

PAMPALONI, PAOLO & SARABANDI, K. (2004). Microwave remote sensing of land.

PÉREZ-RAMÍREZ, I. (2022). El paisaje agrario, en-clave para pensar: Aproximación socio-ecológica a la conexión entre la sociedad y los paisajes agrarios en la comarca de Las Vegas, Madrid [Tesis doctoral, Universidad Autónoma de Madrid]. Departamento de Ecología, Universidad Autónoma de Madrid.

PIERDICCA, N., PULVIRENTI, L., & BIGNAMI, C. (2010). Soil moisture estimation over vegetated terrains using multitemporal remote sensing data. *Remote Sensing of Environment*, 114(2), 440-448. <https://doi.org/10.1016/j.rse.2009.10.001>

POGGIO, L., DE SOUSA, L. M., BATJES, N. H., HEUVELINK, G. B. M., KEMPEN, B., RIBEIRO, E., & ROSSITER, D. (2021). SoilGrids 2.0: producing soil information for the globe with quantified spatial uncertainty. *SOIL*, 7(1), 217–240. <https://doi.org/10.5194/soil-7-217-2021>

PORTA CASANELLAS, J., LÓPEZ-ACEVEDO, M., & ROQUERO, C. (2019). *Edafología: Para la agricultura y el medio ambiente* (4.^a ed.). Mundi-Prensa Libros.

QUAN, CHEN & JIULI, LIU & ZHIHUA, TANG & JIANGYUAN, ZENG & YAN, LI. (2014). Study on the relationship between soil moisture and its dielectric constant obtained by space-borne microwave radiometers and scatterometers. *IOP Conference Series: Earth and Environmental Science*. 17. 012143. 10.1088/1755-1315/17/1/012143.

RADUŁA, M. W., SZYMURA, T. H., & SZYMURA, M. (2018). Topographic wetness index explains soil moisture better than bioindication with Ellenberg's indicator values. *Ecological Indicators*, 85, 172–179. <https://doi.org/10.1016/j.ecolind.2017.10.011>

RONAK, PRIYANKA, KHANNA, C., & JINDAL, P. (2025). Enhancing data analysis efficiency: A comparative study of Excel's VBA & Power Query vs. Python for large-scale data processing. *International Journal of Advanced Research (IJAR)*, 13(07), 143-147. <https://doi.org/10.21474/IJAR01/21320>

SALGADO, H. A. (1998). Correlación entre humedad del suelo y retrodispersión en imágenes SAR. *Revista de la facultado de Agronomía*, 18(3), 163-168.

SALGADO, H., ZABALA, S. M., ROMAY, C., BERNIER, M., JACOME, A., & CHOKMANI, K. (2021). Estimación de la humedad superficial del suelo mediante datos SAR en banda X. *Meteorológica*, 46(1), e001. <https://doi.org/10.24215/1850468Xe001>

SALGADO, HÉCTOR & ZABALA, STELLA & ROMAY, CATALINA & BERNIER, MONIQUE & JACOME, ANDRES & CHOKMANI, KAREM. (2021). Estimación de la humedad superficial del suelo mediante datos sar en banda X. *Meteorologica*. 46. e001-e001. 10.24215/1850468Xe001.

SARABANDI, K., & PAMPALONI, P. (2004, January). Microwave remote sensing of land. In *Microwave Remote Sensing of Land*. Retrieved from https://www.researchgate.net/publication/228525947_Microwave_remote_sensing_of_land

SCHOLZ, H., LISCHIED, G., RIBBE, L., HERNANDEZ OCHOA, I., AND GRAHMANN, K. (2024): Differentiating between crop and soil effects on soil moisture dynamics, *Hydrol. Earth Syst. Sci.*, 28, 2401–2419, <https://doi.org/10.5194/hess-28-2401-2024>, 2024.

SCHRÖTER, I., PAASCHE, H., DOKTOR, D., XU, X., DIETRICH, P., & WOLLSCHLÄGER, U. (2017). Estimating soil moisture patterns with remote sensing and terrain data at the small catchment scale. *Vadose Zone Journal*, 16(10). <https://doi.org/10.2136/vzj2017.01.0012>. <https://acsess.onlinelibrary.wiley.com/doi/epdf/10.2136/vzj2017.01.0012>

Sentinel-1 Team. (2013). Sentinel-1 User Handbook (Reference GMES-S1OP-EOPG-TN-13-0001; Issue 1, Rev. 0). European Space Agency (ESA). Recuperado de https://ftp.itc.nl/pub/Dragon4_Lecturer_2018/ESA%20EEs%20and%20Sentinels%20Brochures%20pdf/Copernicus%20Sentinels%201,2,3/Sentinel-1%20User%20Handbook.pdf

SHI, J., WANG, J., HSU, A. Y., O'NEILL, P. E., & ENGMAN, E. T. (1997). Estimation of bare surface soil moisture and surface roughness parameter using L-band SAR image data.

IEEE Transactions on Geoscience and Remote Sensing, 35(5), 1254-1266.
<https://doi.org/10.1109/36.628792>

Sinergise Solutions d.o.o. (s.f.). Sentinel Hub. Planet Labs. <https://www.sentinel-hub.com>

SINGH, A., GAURAV, K., MEENA, G. K., & KUMAR, S. (2020). Estimation of Soil Moisture Applying Modified Dubois Model to Sentinel-1; A Regional Study from Central India. Remote Sensing, 12(14), 2266. <https://doi.org/10.3390/rs12142266>

SOLORZA, R. (2013). Estimación de la humedad superficial del suelo mediante el uso combinado de modelos electromagnéticos y el enfoque bayesiano: Estudio exploratorio en imágenes SARAT [Tesis de maestría, Universidad Nacional de Córdoba]. Comisión Nacional de Actividades Espaciales (CONAE). <https://www.famaf.unc.edu.ar/documents/1321/14-Gulich-Solorza.pdf>

ULABY, F. T., BATLIVALA, P. P., & DOBSON, M. C. (1978). Microwave backscatter dependence on surface roughness, soil moisture, and soil texture: Part I—Bare soil. IEEE Transactions on Geoscience Electronics, 16(4), 286–295. <https://doi.org/10.1109/TGE.1978.294586>

ULABY, F. T., MOORE, R. K., & FUNG, A. K. (1982). Microwave remote sensing : active and passive. Vol.2, Radar remote sensing and surface scattering and emission theory. Artech House.

VICENTE-SERRANO, S. M., CABELLO, D., TOMÁS-BURGUERA, M., MARTÍN-HERNÁNDEZ, N., BEGUERÍA, S., AZORIN-MOLINA, C., & EL KENAWY, A. (2015). Drought variability and land degradation in semiarid regions: Assessment using remote sensing data and drought indices (1982–2011). Remote Sensing, 7(4), 4391–4423. <https://doi.org/10.3390/rs70404391>

WANG, Q., XU, C., LONG, J., ZHANG, Q., LUO, Y., & LI, L. (2025). Soil moisture deficits triggered by increasing compound drought and heat events during the growing season in Arid Central Asia. Journal of Hydrology, 660(Parte A), Artículo 133397. <https://doi.org/10.1016/j.jhydrol.2025.133397>

WANG, L., WU, B., ZHU, W., ELNASHAR, A., YAN, N., & MA, Z. (2025). Evapotranspiration Disaggregation Using an Integrated Indicating Factor Based on Slope Units. Remote Sensing, 17(7), 1201. <https://doi.org/10.3390/rs17071201>

XING, M., HE, B., NI, X., WANG, J., AN, G., SHANG, J., & HUANG, X. (2019). Retrieving Surface Soil Moisture over Wheat and Soybean Fields during Growing Season Using Modified Water Cloud Model from Radarsat-2 SAR Data. Remote Sensing, 11(16), 1956. <https://doi.org/10.3390/rs11161956>

YIN, H., XIONG, B., LAO, X., JIANG, Z., WU, Y., & WANG, T. (2025). Spatial Structure and Optimal Sampling Intervals of Soil Moisture at Different Depths in a Typical Karst Demonstration Zone. Water, 17(19), 2891. <https://doi.org/10.3390/w17192891>

ZHANG, Z., & DU, Q. (2019). A Bayesian Kriging Regression Method to Estimate Air Temperature Using Remote Sensing Data. *Remote Sensing*, 11(7), 767. <https://doi.org/10.3390/rs11070767>

ZHAO, Y. S., ZHU, D., WU, Z., & CAO, Z. (2024). Extreme rainfall erosivity: Research advances and future perspectives. *Science of the Total Environment*, 917, 170425. <https://doi.org/10.1016/j.scitotenv.2024.170425>

9. Anexos

9.1. Imágenes descargadas

Nombre de archivo de las imágenes Sentinel 1:

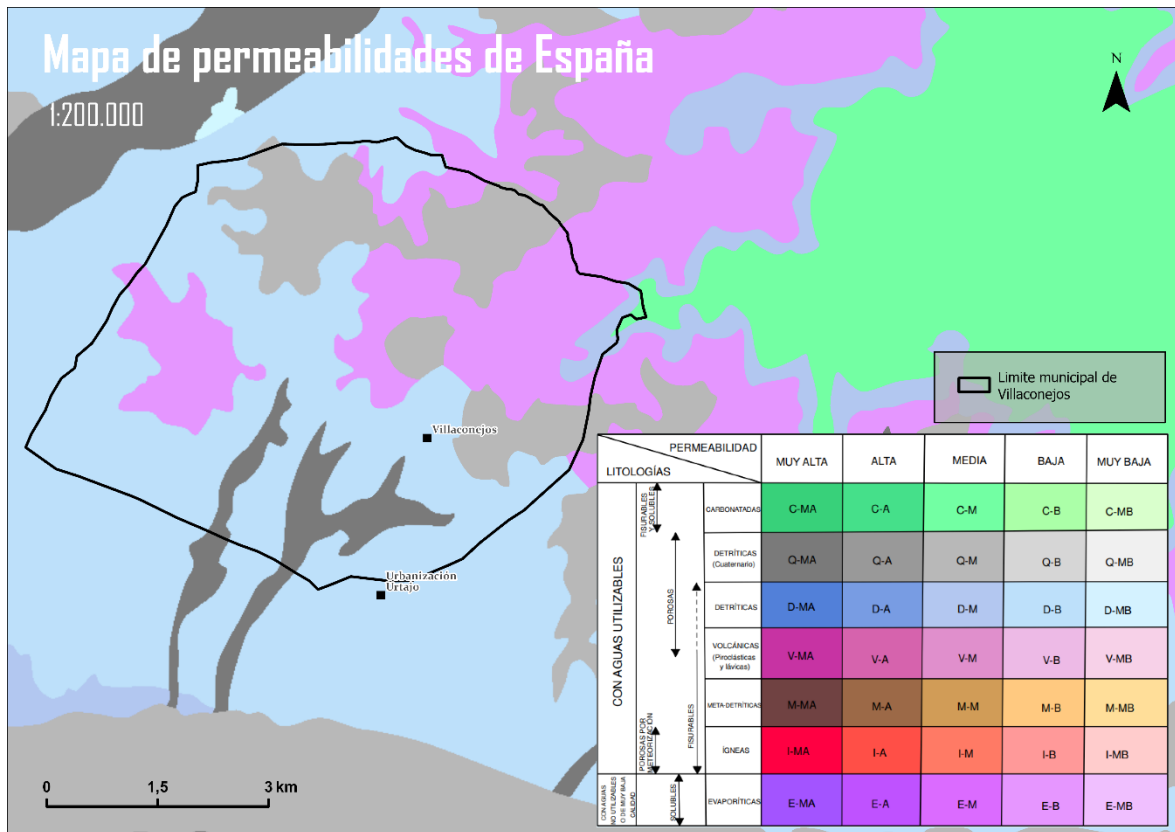
1. S1A_IW_GRDH_1SDV_20150322T181040_20150322T181105_005148_0067D1_50D2.SAFE
2. S1A_IW_GRDH_1SDV_20150726T061735_20150726T061800_006978_009766_DF10
3. S1A_IW_GRDH_1SDV_20170504T061746_20170504T061811_016428_01B358_CC6A
4. S1A_IW_GRDH_1SDV_20170808T061754_20170808T061819_017828_01DE2C_F086
5. S1B_IW_GRDH_1SDV_20190424T181013_20190424T181038_015952_01DF9B_BCAD
6. S1A_IW_GRDH_1SDV_20190629T181112_20190629T181137_027898_03264F_81F7
7. S1B_IW_GRDH_1SDV_20210425T181025_20210425T181050_026627_032E0E_2484
8. S1A_IW_GRDH_1SDV_20210805T181127_20210805T181152_039098_049D11_F6DD
9. S1A_IW_GRDH_1SDV_20230527T181134_20230527T181159_048723_05DC17_6C67
10. S1A_IW_GRDH_1SDV_20230819T181139_20230819T181204_049948_06022D_E56E
11. S1A_IW_GRDH_1SDV_20250311T061821_20250311T061846_058253_073309_6E9E
12. S1C_IW_GRDH_1SDV_20250603T180959_20250603T181024_002622_0056D7_DFDB

Nombre de archivo de las imágenes Sentinel-2:

1. LC08_L2SP_200032_20150310_20200909_02_T1
2. S2A_MSIL1C_20150729T110026_N0500_R094_T30TVK_20231010T004846
3. S2B_MSIL1C_20170424T110029_N0500_R094_T30TVK_20231111T072129
4. S2B_MSIL1C_20170812T105619_N0500_R094_T30TVK_20231003T212246
5. S2B_MSIL2A_20190504T105629_N0500_R094_T30TVK_20221207T180025
6. S2B_MSIL2A_20190703T105629_N0500_R094_T30TVK_20230717T121700
7. S2B_MSIL2A_20210324T105639_N0500_R094_T30TVK_20230608T120957
8. S2A_MSIL1C_20210826T105621_N0500_R094_T30TVK_20230217T200936
9. S2A_MSIL1C_20230518T105621_N0510_R094_T30TVK_20240905T170331
10. S2B_MSIL1C_20230821T105629_N0510_R094_T30TVK_20241024T073200
11. S2A_MSIL2A_20250330T105651_N0511_R094_T30TVK_20250330T175400
12. S2C_MSIL2A_20250606T105641_N0511_R094_T30TVK_20250606T140657

9.2. Datos de permeabilidades en el área de estudio

A continuación, se muestra las permeabilidades del suelo a partir del mapa de permeabilidades de España a escala 1:200.000 del IGME:



Mapa 9. Mapa de permeabilidades de España a escala 1:200.000, enfocado al municipio de Villaconejos (IGME, 2009).

9.3. Datos de precipitación AEMET

Se presentan los principales datos de precipitación obtenidos de la estación meteorológica de Aranjuez (la más cercana a la zona de estudio).

| | 2015 | 2017 | 2019 |
|-------------|------------|------------|------------|
| | Húmedo | Húmedo | Húmedo |
| Fecha | 2015-03-20 | 2017-04-29 | 2019-04-22 |
| Altitud (m) | 540 | 540 | 540 |
| Tmed (°C) | 10,7 | 12,2 | 12,7 |
| Prec (mm) | 4,5 | 7,8 | 1,4 |
| Tmin (°C) | 6,8 | 8,1 | 5,9 |
| Tmax (°C) | 14,6 | 16,2 | 19,5 |
| Fecha | 2015-03-21 | 2017-04-30 | 2019-04-23 |
| Tmed (°C) | 10,0 | 12,2 | 10,0 |
| Prec (mm) | 4,8 | 1,3 | 5,6 |
| Tmin (°C) | 7,9 | 8,9 | 6,0 |

| | 2015 | 2017 | 2019 |
|------------------|-------------------|------|-------------------|
| Tmax (°C) | 12,0 | 15,5 | 14,0 |
| Fecha | 2015-03-22 | - | 2019-04-24 |
| Tmed (°C) | 12,0 | - | 10,2 |
| Prec (mm) | 5,7 | - | 15,9 |
| Tmin (°C) | 7,8 | - | 5,1 |
| Tmax (°C) | 16,1 | - | 15,2 |

| | 2021 | 2023 | 2025 |
|--------------------|-------------------|-------------------|-------------------|
| | Húmedo | Húmedo | Húmedo |
| Fecha | 2021-04-24 | 2023-05-24 | 2025-03-09 |
| Altitud (m) | 540 | 540 | 540 |
| Tmed (°C) | - | 19,0 | 8,2 |
| Prec (mm) | 6,4 | 0,3 | 8,1 |
| Tmin (°C) | - | 13,0 | 4,8 |
| Tmax (°C) | - | 25,0 | 11,5 |
| Fecha | 2021-04-25 | 2023-05-25 | 2025-03-10 |
| Tmed (°C) | 7,8 | 18,2 | 10,1 |
| Prec (mm) | 4,5 | 22,5 | 8,5 |
| Tmin (°C) | 6,8 | 10,7 | 5,9 |
| Tmax (°C) | 14,6 | 25,8 | 14,3 |
| Fecha | - | 2023-05-27 | 2025-03-11 |
| Tmed (°C) | - | 17,6 | 9,6 |
| Prec (mm) | - | 21,6 | 8,0 |
| Tmin (°C) | - | 13,2 | 6,3 |
| Tmax (°C) | - | 22,1 | 12,8 |

Tabla 11. Datos de precipitación de la AEMTE recogidos en Aranjuez.

9.4. Coeficientes del Modelo de Hallikainen

| Frequency, GHz | $\epsilon_c = (a_0 + a_1S + a_2C) + (b_0 + b_1S + b_2C)m_v + (c_0 + c_1S + c_2C)m_v^2$ | | | | | | | | |
|----------------|--|--------|--------|--------|--------|--------|---------|--------|--------|
| | a_0 | a_1 | a_2 | b_0 | b_1 | b_2 | c_0 | c_1 | c_2 |
| 1.4 | 2.862 | -0.012 | 0.001 | 3.803 | 0.462 | -0.341 | 119.006 | -0.500 | 0.633 |
| 4 | 2.927 | -0.012 | -0.001 | 5.505 | 0.371 | 0.062 | 114.826 | -0.389 | -0.547 |
| 6 | 1.993 | 0.002 | 0.015 | 38.086 | -0.176 | -0.633 | 10.720 | 1.256 | 1.522 |
| 8 | 1.997 | 0.002 | 0.018 | 25.579 | -0.017 | -0.412 | 39.793 | 0.723 | 0.941 |
| 10 | 2.502 | -0.003 | -0.003 | 10.101 | 0.221 | -0.004 | 77.482 | -0.061 | -0.135 |
| 12 | 2.200 | -0.001 | 0.012 | 26.473 | 0.013 | -0.523 | 34.333 | 0.284 | 1.062 |
| 14 | 2.301 | 0.001 | 0.009 | 17.918 | 0.084 | -0.282 | 50.149 | 0.012 | 0.387 |
| 16 | 2.237 | 0.002 | 0.009 | 15.505 | 0.076 | -0.217 | 48.260 | 0.168 | 0.289 |
| 18 | 1.912 | 0.007 | 0.021 | 29.123 | -0.190 | -0.545 | 6.960 | 0.822 | 1.195 |
| All | | | | | | | | | |
| 1.4 | 0.356 | -0.003 | -0.008 | 5.507 | 0.044 | -0.002 | 17.753 | -0.313 | 0.206 |
| 4 | 0.004 | 0.001 | 0.002 | 0.951 | 0.005 | -0.010 | 16.759 | 0.192 | 0.290 |
| 6 | -0.123 | 0.002 | 0.003 | 7.502 | -0.058 | -0.116 | 2.942 | 0.452 | 0.543 |
| 8 | -0.201 | 0.003 | 0.003 | 11.266 | -0.085 | -0.155 | 0.194 | 0.584 | 0.581 |
| 10 | -0.070 | 0.000 | 0.001 | 6.620 | 0.015 | -0.081 | 21.578 | 0.293 | 0.332 |
| 12 | -0.142 | 0.001 | 0.003 | 11.868 | -0.059 | -0.225 | 7.817 | 0.570 | 0.801 |
| 14 | -0.096 | 0.001 | 0.002 | 8.583 | -0.005 | -0.153 | 28.707 | 0.297 | 0.357 |
| 16 | -0.027 | -0.001 | 0.003 | 6.179 | 0.074 | -0.086 | 34.126 | 0.143 | 0.206 |
| 18 | -0.071 | 0.000 | 0.003 | 6.938 | 0.029 | -0.128 | 29.945 | 0.275 | 0.377 |
| All | | | | | | | | | |

Tabla 12. Coeficientes de la expresión polinomial desarrollada en el modelo de Hallikainen. En rojo los valores correspondientes a la banda C (1,4 GHz) usados en el estudio.

9.5. Script VBA para el emparejamiento de retrodispersión observada y estimada

```

1  Sub EmparejarRetrodispersión_Optimizado()
2
3      Dim wsObs As Worksheet, wsSim As Worksheet, wsRes As Worksheet
4      Dim i As Long, j As Long, k As Long
5      Dim valObs As Double, valEst As Double
6      Dim xObs As Double, yObs As Double, xVec As Double, yVec As Double
7      Dim humedadVecina As Double, dist As Double
8      Dim contadorVecinos As Long, mejorIdx As Long
9      Dim errActual As Double, mejorScore As Double, scoreActual As Double
10
11     Const radioVecindad As Double = 20 ' en metros
12
13     ' Asignar hojas
14     Set wsObs = ThisWorkbook.Sheets("Observados")
15     Set wsSim = ThisWorkbook.Sheets("Simulados")
16     Set wsRes = ThisWorkbook.Sheets("Resultado")
17
18     ' Leer rangos en arrays
19     Dim nObs As Long, nSim As Long
20     nObs = wsObs.Cells(wsObs.Rows.Count, 1).End(xlUp).Row - 1
21     nSim = wsSim.Cells(wsSim.Rows.Count, 1).End(xlUp).Row - 1
22
23     Dim obsArray() As Variant
24     Dim simArray() As Variant
25     Dim resultArray() As Variant
26
27     obsArray = wsObs.Range("A2:C" & nObs + 1).Value
28     simArray = wsSim.Range("A2:C" & nSim + 1).Value
29     ReDim resultArray(1 To nObs, 1 To 6)
30

```

```

31 ' Inicializar arreglo para resultados
32 For i = 1 To nObs
33     valObs = obsArray(i, 1)
34     xObs = obsArray(i, 2)
35     yObs = obsArray(i, 3)
36
37     ' Calcular humedad vecina de observaciones anteriores
38     humedadVecina = 0
39     contadorVecinos = 0
40     If i > 1 Then
41         For k = 1 To i - 1
42             If IsNumeric(resultArray(k, 2)) Then
43                 xVec = obsArray(k, 2)
44                 yVec = obsArray(k, 3)
45                 dist = Sqr((xObs - xVec) ^ 2 + (yObs - yVec) ^ 2)
46                 If dist <= radioVecindad Then
47                     humedadVecina = humedadVecina + resultArray(k, 2)
48                     contadorVecinos = contadorVecinos + 1
49                 End If
50             End If
51         Next k
52     End If
53
54     If contadorVecinos > 0 Then
55         humedadVecina = humedadVecina / contadorVecinos
56     Else
57         humedadVecina = 0.20 ' Valor por defecto
58     End If
59
60 ' Buscar el mejor candidato entre simulaciones (menor error en retro + humedad cercana a vecinos)
61 mejorScore = 999999
62 mejorIdx = -1
63
64 For j = 1 To nSim
65     valEst = simArray(j, 3)
66     errActual = Abs(valObs - valEst)
67     scoreActual = errActual + Abs(simArray(j, 2) - humedadVecina) ' penaliza humedad lejana
68
69     If scoreActual < mejorScore Then
70         mejorScore = scoreActual
71         mejorIdx = j
72     End If
73 Next j
74
75 ' Guardar resultados
76 If mejorIdx <> -1 Then
77     resultArray(i, 1) = valObs
78     resultArray(i, 2) = simArray(mejorIdx, 2) ' humedad
79     resultArray(i, 3) = simArray(mejorIdx, 1) ' rugosidad
80     resultArray(i, 4) = simArray(mejorIdx, 3) ' retrodispersion estimada
81     resultArray(i, 5) = Abs(valObs - simArray(mejorIdx, 3)) ' error
82     resultArray(i, 6) = contadorVecinos
83 End If
84 Next i
85
86 ' Escribir cabeceras
87 wsRes.Cells(1, 1).Resize(1, 6).Value = Array("retrodispersion_observada", "humedad",
88 "rugosidad", "retrodispersion_estimada", "error", "vecinos_usados")
89
90 ' Volcar resultados al Excel
91 wsRes.Range("A2").Resize(nObs, 6).Value = resultArray
92
93 MsgBox "Asignación completada. Observaciones procesadas: " & nObs
94
95 End Sub

```

Imagen 8. Código VBA de asignación en Visual Studio Code

9.6. Tabla resultados OLS

| Variable | Coefficiente | Interpretación |
|-----------------------------|--------------|--|
| Intercepto | 0.093857 | Valor base de humedad cuando las demás variables son cero. |
| MDT | +0.000331 | A mayor altitud, la humedad superficial tiende a aumentar ligeramente. Este efecto puede deberse a microclimas más húmedos o menor evaporación a mayor altitud. |
| Modelo orientaciones | -0.000115 | Las pendientes orientadas hacia ciertos aspectos (por ejemplo, sur o suroeste en zonas templadas) tienden a presentar menor humedad. Indica influencia de la radiación solar y exposición. |
| Modelo de pendientes | +0.000716 | Pendientes más pronunciadas se asocian con un leve aumento en humedad. Esto podría parecer contraintuitivo, pero puede reflejar que las zonas planas están más expuestas a evaporación o compactación del suelo. |
| Índice TWI | +0.003671 | Como era de esperarse, el índice topográfico de humedad está positivamente relacionado con la humedad superficial; a mayor TWI, mayor acumulación potencial de agua. |
| Índice NDVI | -0.192406 | Relación negativa fuerte: zonas con mayor vegetación (mayor NDVI) presentan menor humedad superficial aparente, posiblemente porque la vegetación transpira activamente o porque el NDVI elevado se asocia a coberturas más densas que reducen la reflectancia del agua en superficie. La vegetación absorbe y dispersa la onda de microondas, reduciendo la contribución del suelo a la retrodispersión total. Esto puede llevar a una subestimación de la humedad si el modelo asume un suelo desnudo. |

Tabla 13. Resultados de los coeficientes *p*-valor del análisis OLS.