

D-03-2023

Comunicación científico-técnica

## Detección de riego mediante series temporales Sentinel-1 y Sentinel-2 sobre campos de frutales

### Irrigation Detection using Sentinel-1 and Sentinel-2 Time Series on Fruit Fields

Amal Chakhar<sup>1</sup>, David Hernández-López<sup>1</sup>, Miguel A. Moreno<sup>1</sup>, Rocío Arias Calderón<sup>1</sup> y José Fernando Ortega Álvarez<sup>1</sup>.

<sup>1</sup> Instituto de Desarrollo Regional, Universidad de Castilla-La Mancha, 02071 Albacete, España.

**Resumen:** En países caracterizados por climas áridos y semiáridos, el riego juega un papel importante porque reduce la pérdida de rendimiento afectada por el estrés hídrico. Sin embargo, la sobreexplotación del agua por parte del sector agrícola puede conducir a la escasez de recursos hídricos. Es por esto que la extensión de los campos de regadío ha requerido la implementación de diversas estrategias y políticas de riego para el ahorro de agua. La gestión eficaz del agua regional o de mayor escala depende de la demanda de riego estimada a partir de mapas de áreas irrigables o de estadísticas nacionales y regionales de áreas irrigadas, que a menudo son inexactas. Estos datos estadísticos no siempre son de calidad confiable porque: (i) generalmente no reflejan en el tiempo la distribución espacial de las áreas irrigadas y de secano, (ii) también cuando los agricultores no reportan el riego. En consecuencia, una distribución espacial más actualizada del área de riego es importante para garantizar la aplicación de políticas regionales de agua. Por lo tanto, el mapeo preciso de las áreas irrigadas es esencial. En este contexto, la teledetección proporciona métodos fiables para recuperar información agrícola útil a partir de sus registros derivados. El uso combinado de datos de observación de la tierra ópticos y de radar aumenta la probabilidad de detectar eventos de riego que pueden mejorar la precisión del mapa de riego. Es por ello que nos propusimos explotar Sentinel-1 (VV y VH) y Sentinel-2 (NDVI) de las Misiones Sentinel para clasificar los frutales de regadío de los de secano sobre un área de estudio situada en la región de Castilla La-Mancha donde se encuentran árboles frutales como la vid, el almendro y el pistacho que están aumentando sus superficies alcanzando cerca del 31% de la superficie total de regadío en 2021. Esta expansión es consecuencia del aumento de los precios de la almendra y los bajos precios de los cereales en el mercado internacional lo que ha provocado la aparición de prácticas ilegales de riego que deben ser detectadas para garantizar una adecuada gestión de los recursos hídricos. Para obtener las series temporales de los índices derivados de las misiones espaciales Sentinel-1 y Sentinel-2, que constituyen los datos de entrada de los algoritmos empleados en la posterior clasificación que detecta las parcelas con los cultivos de interés, se ha desarrollado una herramienta que automatiza el uso de Sentinel-Hub para calcular en el propio servicio y descargar únicamente los productos organizados por tiles para la región de interés y para toda la serie temporal, garantizando la repetibilidad espacial de cada píxel en todos los productos y fechas. La clasificación de parcelas de riego se realizó seleccionando el algoritmo de aprendizaje automático con mejor rendimiento entre todos los disponibles en la aplicación "Classification Learner" de Matlab®. Nuestra metodología utilizada mostró resultados prometedores con una precisión general del 88,4% y, de hecho, la herramienta pudo detectar cuatro parcelas irrigadas que fueron clasificadas erróneamente como no irrigadas en la base de datos SIGPAC. Para evaluar estos resultados, aplicamos el método de detección de cambio del coeficiente de retrodispersión  $\sigma_p^0$  a escala de parcela.

**Palabras clave:** detección de riego, árboles frutales, Sentinel-1, Sentinel-2, algoritmo de aprendizaje automático.



# XXXIX Congreso Nacional de Riegos ÚBEDA (JAÉN)

18, 19, 20 de octubre de 2023



**Abstract:** In countries characterized by arid and semi-arid climates, irrigation plays an important role in reducing yield loss caused by water stress. However, overexploitation of water resources by the agricultural sector can lead to water scarcity. This is why the expansion of irrigated fields has necessitated the implementation of various irrigation strategies and policies to conserve water. Effective regional or larger-scale water management depends on estimating irrigation demand using maps of irrigable areas or national and regional statistics of irrigated areas, which are often inaccurate. These statistical data are not always of reliable quality because: (i) they generally do not reflect the spatial distribution of irrigated and rainfed areas over time, (ii) they may not account for unreported irrigation by farmers. Consequently, an updated spatial distribution of irrigated areas is crucial to enforce regional water policies. Therefore, accurate mapping of irrigated areas is essential. In this context, remote sensing provides reliable methods to gather useful agricultural information from derived records. The combined use of optical and radar Earth observation data enhances the likelihood of detecting irrigation events, which can improve the accuracy of irrigation mapping. Hence, we aimed to utilize Sentinel-1 (VV and VH) and Sentinel-2 (NDVI) data from the Sentinel Missions to classify irrigated fruit trees and rainfed ones in a study area located in the Castilla La-Mancha region. This region hosts fruit trees such as vines, almonds, and pistachios, which have been increasing their areas and account for about 31% of total irrigated area in 2021. This expansion is driven by rising almond prices and low cereal prices in the international market, leading to illegal irrigation practices that must be identified to ensure proper water resource management. To obtain time series of derived indices from Sentinel-1 and Sentinel-2 satellite missions, which constitute the input data for the classification algorithms used in subsequent detection, a tool has been developed to automate the use of Sentinel-Hub. This tool calculates and downloads products organized by tiles for the region of interest and the entire time series within the service, ensuring spatial repeatability of each pixel across all products and dates. The classification of irrigated plots was carried out by selecting the best-performing machine learning algorithm among those available in the "Classification Learner" application of Matlab®. Our used methodology showcased promising results with an overall accuracy of 88.4% and indeed the tool was able to detect four irrigated plots that were misclassified as non-irrigated in the SIGPAC database. To evaluate these results, we applied the change detection method of the  $\sigma_p^0$  backscattering coefficient at the plot scale.

**Keywords:** irrigation detection, fruit trees, Sentinel-1, Sentinel-2, machine learning algorithm.

## 1. Introducción

En regiones áridas y semiáridas, la irrigación es crucial para mitigar la pérdida de rendimiento causada por la sequía y el estrés hídrico [1-3]. Sin embargo, la gestión de los recursos hídricos se está volviendo cada vez más desafiante debido a los impactos del cambio climático [4-6], que incluyen el aumento de las temperaturas y la disminución de las precipitaciones [7-9]. A pesar de la disminución de los suministros de agua, la demanda de irrigación ha aumentado como estrategia de adaptación al clima para los agricultores [10,11]. Sin embargo, la escasez de agua a menudo resulta de la sobreexplotación, especialmente en la agricultura [11]. Para abordar esto, las estrategias y políticas de irrigación son esenciales para ahorrar agua y garantizar una distribución equitativa [12]. En este contexto, la teledetección proporciona métodos confiables para obtener información agrícola útil a partir de sus registros derivados.

La detección de áreas irrigadas se ha abordado desde diversas perspectivas: (i) utilizando diferentes productos de teledetección, como solo ópticos [13-15], solo de microondas [16-18] y una combinación de datos ópticos y de microondas [19-25]. Si bien la mayoría de estos estudios se han centrado principalmente en cultivos herbáceos, algunos han incluido clases de árboles frutales dentro de los datos de referencia clasificados [16,17,25,26]. Sin embargo, según nuestro conocimiento actual, no ha habido un estudio exclusivo dedicado a la separación de campos de árboles frutales irrigados de los de secano. Esta brecha resalta la necesidad de una investigación especializada en regiones que experimentan expansión de cultivos. Este estudio dedicado abordaría desafíos específicos, que incluyen: (i) la escasa cobertura del suelo de cultivos como viñedos plantados en espaldera, (ii) el denso crecimiento vegetativo de los árboles frutales de secano (por ejemplo, almendros o pistachos) durante el verano, lo que podría complicar el uso de la información de teledetección por satélite óptico que puede ser fácilmente confundida con campos irrigados, y (iii) la influencia de los métodos de irrigación en la detectabilidad utilizando la teledetección de microondas. Es importante destacar que los sistemas de irrigación, como los métodos de riego por aspersión y superficial, exhiben fuertes señales de microondas debido a la humedad del suelo sustancial, mientras que el riego por goteo, comúnmente utilizado para los cultivos de árboles frutales, implica un uso mínimo de agua, lo que dificulta su detección [27].

En la región de Castilla-La Mancha en España, ha habido un notable aumento en el cultivo de árboles frutales como viñedos, almendros y pistachos, que ocuparon colectivamente alrededor del 31% del área total de campos irrigados en 2021 [28]. Especialmente en 2021, el cultivo de almendros y pistachos experimentó un crecimiento significativo, con una expansión de aproximadamente 3,180 hectáreas en comparación con 2019 [28]. Durante la última década, ha surgido una tendencia de reemplazar cultivos, lo que ha llevado a la transformación de numerosos campos de cereales en huertos de almendros. Este cambio ha resultado en un aumento del área de tierra cubierta por almendros, que ha aumentado de 411,587 hectáreas a 625,421 hectáreas. La fuerza impulsora detrás de esta expansión es el mayor valor de las almendras en contraste con los precios más bajos de los cereales en el mercado global. Sin embargo, esta expansión también ha llevado al surgimiento de prácticas ilegales de irrigación que deben ser identificadas para garantizar una gestión eficaz de los recursos hídricos.


Estudios previos han destacado que el uso sinérgico de datos de observación de la Tierra (EO) tanto ópticos como de radar aumenta la probabilidad de detectar eventos de irrigación, mejorando así la precisión de la cartografía de irrigación [19,23]. Además, para lograr una detección precisa de la irrigación, es necesario utilizar datos de series temporales de satélites de alta resolución, lo que ayuda a distinguir de manera efectiva entre campos irrigados y de secano. Esto lleva nuestro enfoque a aprovechar los datos de los satélites Sentinel-1 (radar) y Sentinel-2 (ópticos) de la misión Copernicus Sentinel para clasificar los campos de árboles frutales irrigados versus los de secano. Sin embargo, la implementación de este enfoque presenta desafíos

significativos relacionados con Big Data: (i) el volumen sustancial de datos EO que requiere descarga, procesamiento y gestión [29,30], y (ii) la dificultad de trabajar con datos de diferentes sensores [31], lo que implica manejar diferentes resoluciones espaciales, espectrales, temporales y radiométricas, así como distintos métodos de adquisición y procesamiento. Para superar estas limitaciones, los autores desarrollaron una herramienta que simplifica la obtención de información de datos analizables (ARD) de análisis diferentes facilitando la descarga desde la plataforma en la nube Sentinel-Hub de manera amigable para el usuario [32]. Asegura una gestión eficiente de los datos, ofrece la flexibilidad para seleccionar análisis deseados (como la detección de irrigación en campos de árboles frutales o herbáceos) e incorpora el uso de un algoritmo de aprendizaje automático efectivo.

## 2. Materiales y métodos

### 2.1 Area de estudio

En este estudio, se adquirieron los datos del Sistema de Información Geográfica de Parcelas Agrícolas (SIGPAC) para toda el área de Fuente Alamo, Albacete, España, y se utilizaron para la calibración y validación del algoritmo de aprendizaje automático utilizado para obtener los resultados de clasificación. El sistema SIGPAC proporciona tanto los límites geográficos como información alfanumérica de las parcelas de tierra individuales. Esto incluye detalles esenciales como códigos de identificación únicos, áreas superficiales, actualizaciones anuales sobre el uso de la tierra, códigos de irrigación que indican si la tierra está irrigada (100) o de secano (0), pendiente promedio y otros atributos relevantes.



**Figura 1.** Presentación del área de estudio.

### 2.2 Adquisición de datos de Sentinel-1 y Sentinel-2

Para obtener series temporales de índices derivados de las misiones satelitales Sentinel-1 y Sentinel-2, se utilizó la herramienta desarrollada por el grupo de investigación para automatizar la descarga de datos de teledetección de Sentinel Hub. Esta herramienta se utilizó para descargar estos productos organizados por mosaicos para el área de estudio de Fuente Alamo y para todo el período de tiempo desde el 01/06/2020 hasta el 31/09/2020, asegurando la repetibilidad espacial de cada píxel en todos los productos y fechas. Para los datos de Sentinel-1, se consideraron las bandas de retrodispersión VH y VV. En cuanto a los datos ópticos de Sentinel-2, se utilizó el Índice de Vegetación de Diferencia Normalizado NDVI.

### 2.3 Descripción general de la metodología de detección de irrigación

Para diferenciar entre campos de árboles frutales irrigados y de secano, empleamos un enfoque de clasificación basado en el análisis de series temporales de imágenes satelitales, un método comúnmente

utilizado en este tipo de contextos. Sin embargo, el manejo de series temporales de satélites dispares como Sentinel-1 (SAR) y Sentinel-2 (ópticos) planteó desafíos en el manejo de la gran cantidad de datos, que incluye la descarga, el procesamiento y la gestión. Para abordar esto, recurrimos a la herramienta desarrollada por el grupo de investigación. El uso de esta herramienta permitió descargar un subconjunto de imágenes ARD correspondientes al área de estudio desde la plataforma de Sentinel-Hub. También, operar con las estadísticas zonales incorporadas en esta herramienta permitió obtener la media de NDVI, así como VV y VH a escala de parcela para cada fecha disponible del conjunto de datos de series temporales descargado. La salida de este paso sirvió como datos de entrenamiento para calibrar el algoritmo de aprendizaje automático seleccionado, que fue la Máquina de Soporte Vectorial SVM lineal, algoritmo que resultó apropiado al combinar el uso de datos ópticos y SAR, como se menciona en [33,34]. Por lo tanto, cuando el modelo de aprendizaje automático está calibrado, se puede aplicar para detectar los campos de árboles frutales irrigados que fueron designados como no irrigados en la base de datos SIGPAC, pero que en realidad estaban siendo irrigados. Estos fueron los principales pasos de la metodología de clasificación, como se describe en la Figura 2.

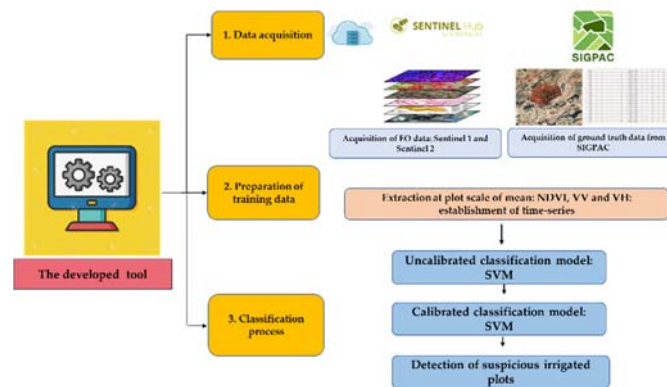


Figura 2. Flujo de trabajo general.

## 2.4 Validación de los resultados de la clasificación: detección de cambios en $\sigma_p^0$ a escala de parcela

Para evaluar los resultados de salida de la herramienta desarrollada, que son los campos que se etiquetaron como no irrigados pero que fueron detectados como irrigados, decidimos aplicar el método propuesto que se describe en detalle en [19] y que se basa en detectar el cambio en el coeficiente de retrodispersión  $\sigma_p^0$  a escala de parcela. Este método se basa en el hecho de que si hay un aumento en el valor SAR  $\sigma_p^0$  entre dos fechas sucesivas de adquisición de SAR, es posible que haya ocurrido un evento de irrigación [35,36]. Aunque también la disminución insignificante de los valores de  $\sigma_p^0$  entre estas dos fechas o la estabilidad pueden estar relacionados posiblemente con un evento de irrigación si los valores de  $\sigma_p^0$  alcanzan valores altos. De lo contrario, una disminución de  $\sigma_p^0$  entre los tiempos sucesivos  $t_1$  y  $t_2$ , durante la primavera y el verano, significa que no hubo un evento de irrigación.

El método [19] propone calcular, en cada adquisición de VV, la diferencia a escala de parcela  $\Delta VV_p$  entre las fechas sucesivas de adquisición de SAR. Por lo tanto, calculamos  $\Delta VV_p$  a escala de parcela de la siguiente manera:

$$\Delta VV_p = VV_{pti} - VV_{pti-1}$$

donde  $VV_{pti}$  es el  $\sigma_p^0$  en polarización VV en la fecha de SAR actual y  $VV_{pti-1}$  es el  $\sigma_p^0$  en polarización VV en la fecha previa.

Para posibles eventos de irrigación en cultivos leñosos, sugerimos tres umbrales principales para el valor  $\sigma_p^0$ :

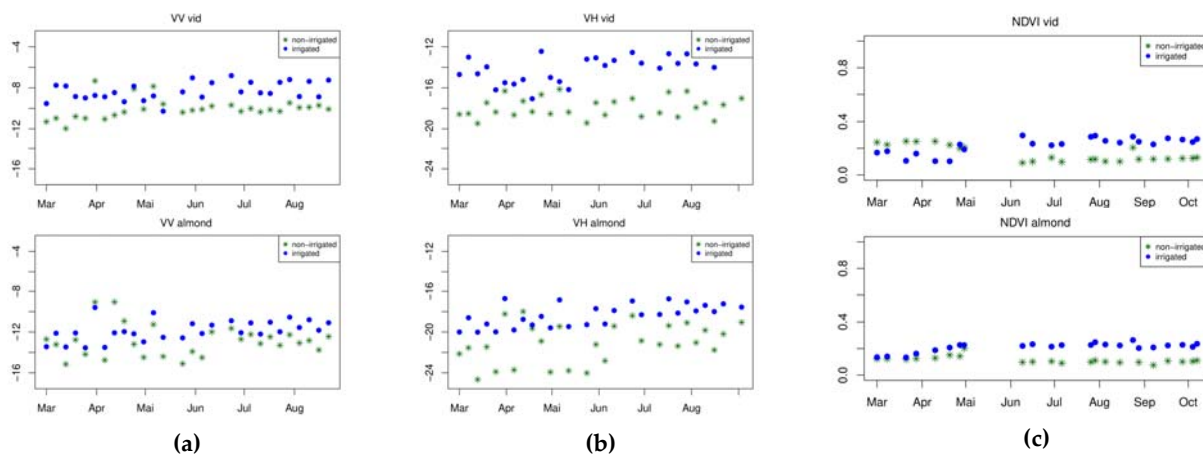


- Primer umbral, si  $\Delta VV_p$  es menor o igual a -0.5 dB, corresponde a no posibles eventos de irrigación: baja probabilidad de irrigación.
- Segundo umbral, si  $\Delta VV_p$  es mayor o igual a 0.5 dB, corresponde a posibles eventos de irrigación: alta probabilidad de irrigación.
- Tercer umbral, si  $\Delta VV_p$  está entre -0.5 dB y 0.5 dB, corresponde a una estabilización o una ligera disminución, lo que también significa un posible evento de irrigación: probabilidad media de irrigación.

### 3. Resultados y discusión

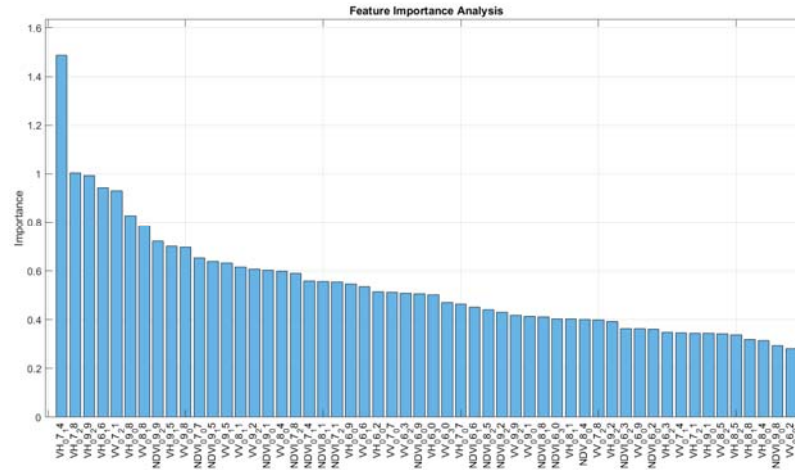
#### 3.1 Análisis Exploratorio de datos de entrada para el Algoritmo de Aprendizaje Automático: Visualización de series temporales.

La Figura 3 representa las series temporales de VV, VH y NDVI de cultivos de vid y almendros irrigados y de secano para el período de marzo a agosto. El análisis de la variación temporal de los variables seleccionadas es el primer paso para posiblemente separar los dos tipos de clases (cultivos irrigados y de secano). Observando la dinámica temporal de estas variables, podemos notar que existe una diferencia notable entre ellas tanto para los almendros como para la vid. De hecho, las parcelas irrigadas presentan unos valores de NDVI, VV y VH más altos que de secano.



**Figura 3.** Dinámica temporal de: (a) VV, (b) VH y (c) NDVI para parcelas regadas y secano de vid y almendros.

### 3.2 Análisis de importancia de variables.



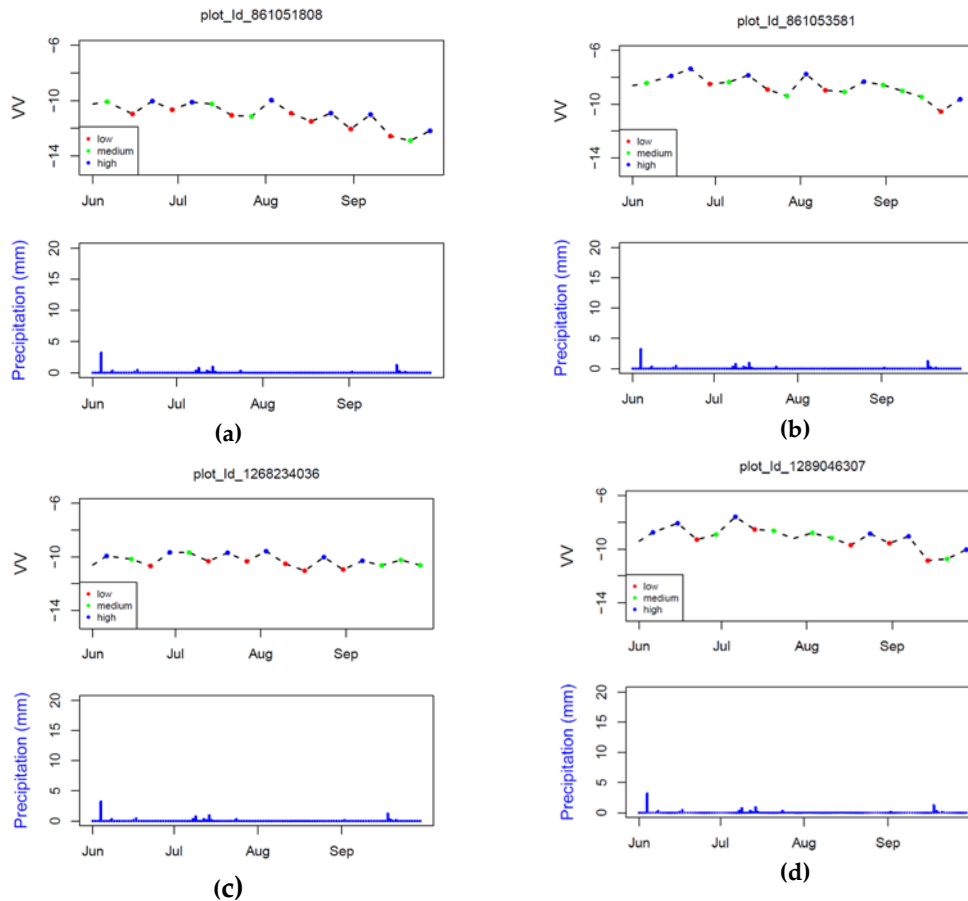
**Figura 4.** Importancia de las variables para la discriminación entre árboles irrigados y de secano.

La importancia de las características utilizadas (NDVI, VV y VH) para cada fecha dentro del período de estudio se determinó mediante la aplicación del modelo de Random Forest, utilizando la técnica de importancia de características por permutación Out-of-Bag (OOB). En la Figura 4 se muestra que VH adquirido el 14 de julio de 2020 tiene un valor de importancia de 1.5, lo que significa que la permutación de los valores de ese predictor resultó en una disminución del rendimiento de 1.5 unidades en promedio en todo el conjunto de árboles. Esta disminución en el rendimiento indica que el predictor contribuye significativamente a la precisión o error del modelo, lo que lo convierte en una característica importante para realizar predicciones precisas. La Figura 4 revela que los tres predictores más importantes se basaron en observaciones de VH (adquiridas el 14/07/2020, 28/07/2020 y 29/09/2020), lo que demuestra la importancia de las imágenes SAR durante los períodos clave de la temporada de verano para detectar la irrigación en campos de frutales. Esta observación respalda la idea de que los árboles irrigados presentan un mayor coeficiente de retrodispersión para la polarización VH, debido a la mayor densidad de vegetación resultante de la irrigación. En consecuencia, VH emerge como la variable más importante para distinguir entre árboles irrigados y de secano, reforzando su papel central en la clasificación.

### 3.3 Resultados de la detección de riego.

En el área de estudio de Fuente Alamo, aplicamos la metodología previamente descrita utilizando datos de la base de datos SIGPAC en el período comprendido entre el 01/06/2020 y el 31/09/2020. El objetivo principal de este trabajo fue evaluar rigurosamente la eficacia de nuestra herramienta para identificar parcelas que se designaron como no irrigadas, pero que en realidad estaban siendo irrigadas. La precisión general (OA) del algoritmo integrado en nuestra herramienta desarrollada, la Máquina de Soporte Vectorial (SVM), fue del 88.4%. Como se ilustra en la Figura 5, hemos mostrado cuatro parcelas, cada una asociada con su correspondiente código SIGPAC, que fueron identificadas como irrigadas a pesar de estar etiquetadas como no irrigadas en la base de datos SIGPAC. Además, como parte de nuestro análisis, hemos incorporado el gráfico de precipitación con cada parcela sospechosa. Estos gráficos nos permiten darte cuenta visualmente del impacto potencial de la lluvia en la señal de retrodispersión VV. Por otro lado, en casos donde no se observa precipitación discernible, podemos inferir que el aumento en el valor SAR  $\sigma_p^0$  entre las fechas sucesivas de adquisición de VV puede indicar potencialmente la ocurrencia de un evento de irrigación. De estas cuatro parcelas, una está dedicada al cultivo de frutas, una alberga cultivos de olivos y las dos restantes son viñedos. Además, la Figura 5 presenta los resultados de la metodología de validación basada en la detección de

cambios. En esta visualización, los puntos azules, verdes y rojos son puntos de posible irrigación detectados en la señal SAR VV con alta, mediana y baja certeza, respectivamente. Al evaluar estos resultados de clasificación y validación, observamos que estas cuatro parcelas, denominadas (a), (b), (c) y (d) en la Figura 5, mostraron un alto número de "probabilidad alta de irrigación", como se muestra en los puntos azules.



**Figura 5.** Campos de regadío detectados que han sido declarados de secano.

Al evaluar estas cuatro parcelas, encontramos que todas ellas presentaban una pendiente promedio relativamente alta, que iba desde el 17% al 52%. Esta observación tiene implicaciones significativas para la interpretación de los hallazgos. Como se destacó en el estudio realizado por [17], donde encontraron que los campos no irrigados que fueron clasificados erróneamente como cultivos irrigados tenían una pendiente elevada, con un porcentaje del 14.5%; la mayoría de ellos se encuentran en áreas montañosas, donde pueden verse influenciados por la topografía. Sin embargo, para mitigar el impacto de la topografía, una solución potencial radica en la aplicación de una "corrección de coseno". Esta corrección busca minimizar las repercusiones de las variaciones de retrodispersión a lo largo de la franja debido a los ángulos de incidencia variables.

La base de datos SIGPAC se utilizó como datos de referencia para entrenar y validar el algoritmo de aprendizaje automático. Sin embargo, es importante tener en cuenta que no todos los datos dentro de SIGPAC fueron verificados. Como se describe en el estudio [16], la base de datos SIGPAC clasifica los campos como irrigados o no irrigados en función de su potencial para estar conectados a una red de riego.



Esta clasificación no garantiza necesariamente que un campo esté siendo irrigado activamente, ya que pueden surgir casos en los que la infraestructura de riego aún no esté establecida. Por lo tanto, para futuros proyectos, es imperativo realizar un paso de validación adicional. Esta validación secundaria debe llevarse a cabo aprovechando la información de entrenamiento para garantizar que la calibración del algoritmo sea precisa y confiable.

#### 4. Conclusiones

En conclusión, este estudio aborda el problema crítico de la detección precisa de irrigación en una región semiárida, donde la escasez de agua y la creciente demanda de irrigación presentan desafíos significativos. La utilización de métodos de teledetección, específicamente la sinergia entre datos de teledetección ópticos y de radar, ha demostrado su eficacia en la detección de eventos de irrigación. A través de la implementación de una metodología de clasificación basada en el análisis de series temporales, esta investigación ha proporcionado información sobre el potencial de combinar datos de Sentinel-1 y Sentinel-2 para diferenciar entre campos de árboles frutales irrigados y de secano. Para adquirir la serie temporal de índices derivados extraídos de datos de Sentinel-1 y Sentinel-2, que sirven como datos de entrada para el algoritmo de SVM utilizado, se ha desarrollado una herramienta especializada para aprovechar Sentinel-Hub. Esta herramienta calcula y descarga sistemáticamente productos organizados por mosaicos para la región de interés especificada, involucrando la serie temporal completa disponible dentro del servicio. Este enfoque meticuloso garantiza la repetibilidad espacial de cada píxel en todos los productos y fechas.

La metodología de este estudio aplicada en el área de estudio de Fuente Alamo mostró resultados prometedores con una precisión general del 88.4%, y, de hecho, la herramienta pudo detectar cuatro parcelas irrigadas que fueron clasificadas erróneamente como no irrigadas en la base de datos SIGPAC. La prominencia de las observaciones de VH como los tres predictores más influyentes destaca la importancia de las imágenes SAR durante fases cruciales de la temporada de verano. En consecuencia, VH desempeña un papel fundamental en la distinción entre árboles irrigados y de secano, consolidando su importancia central en el marco de clasificación. Del mismo modo, la consideración de factores topográficos en la interpretación de los resultados de clasificación resaltó la necesidad de técnicas adicionales de corrección para tener en cuenta el impacto de las variaciones de pendiente. Sin embargo, es imperativo reconocer las limitaciones de la base de datos SIGPAC en términos de verificación completa de sus datos. Esto enfatiza la necesidad de un paso de validación secundaria para garantizar la precisión de la calibración del algoritmo de aprendizaje automático. Futuras investigaciones deben centrarse en refinar la metodología mediante la integración de datos de referencia verificados adicionales y corrección adicional de imágenes SAR para mitigar el impacto de la topografía.

En general, este estudio ha ofrecido una visión de las capacidades y desafíos de la teledetección en la detección de campos frutales irrigados. La combinación de tecnología avanzada, conjuntos de datos confiables y/o verificados, y metodologías refinadas tiene el potencial de respaldar una cartografía de irrigación más eficiente en general, pero especialmente en campos frutales.

#### Referencias

1. Howell, T.A.; Hiler, E.A.; Reddell, D.L. Optimization of Water Use Efficiency Under High Frequency Irrigation - 2. System Simulation and Dynamic Programming. **1974**.
2. Hanks, R.J. Model or Predicting Plant Yield as Influenced by Water Use. *Agron. J.* **1974**, VOL. 66, 5.
3. Pejić, B.; Maksimović, L.; Škorić, D.; Milić, S.; Stričević, R.; Čupina, B. Effect of Water Stress on Yield and Evapotranspiration of Sunflower. *Helia* **2009**, 32, 19–32, doi:10.2298/HEL0951019P.
4. Luo, P.; Sun, Y.; Wang, S.; Wang, S.; Lyu, J.; Zhou, M.; Nakagami, K.; Takara, K.; Nover, D. Historical Assessment and Future Sustainability Challenges of Egyptian Water Resources Management. *J. Clean. Prod.* **2020**, 263, 121154, doi:10.1016/j.jclepro.2020.121154.
5. Tzanakakis, V.A.; Angelakis, A.N.; Paranychianakis, N. V.; Dialynas, Y.G.; Tchobanoglous, G. Challenges and Opportunities for

- Sustainable Management of Water Resources in the Island of Crete, Greece. *Water (Switzerland)* **2022**, *14*, doi:10.3390/w14071024.
6. Calicioglu, O.; Flammini, A.; Bracco, S.; Bellù, L.; Sims, R. The Future Challenges of Food and Agriculture: An Integrated Analysis of Trends and Solutions. *Sustain.* **2019**, *11*, doi:10.3390/su11010222.
  7. Zhang, Q.; Xu, C.Y.; Zhang, Z.; Chen, Y.D.; Liu, C. ling; Lin, H. Spatial and Temporal Variability of Precipitation Maxima during 1960-2005 in the Yangtze River Basin and Possible Association with Large-Scale Circulation. *J. Hydrol.* **2008**, *353*, 215–227, doi:10.1016/j.jhydrol.2007.11.023.
  8. Zhang, Q.; Xu, C.Y.; Tao, H.; Jiang, T.; Chen, Y.D. Climate Changes and Their Impacts on Water Resources in the Arid Regions: A Case Study of the Tarim River Basin, China. *Stoch. Environ. Res. Risk Assess.* **2010**, *24*, 349–358, doi:10.1007/s00477-009-0324-0.
  9. Jamali, M.; Gohari, A.; Motamedi, A.; Haghighi, A.T. Spatiotemporal Changes in Air Temperature and Precipitation Extremes over Iran. *Water (Switzerland)* **2022**, *14*, doi:10.3390/w14213465.
  10. Tramblay, Y.; Koutroulis, A.; Samaniego, L.; Vicente-Serrano, S.M.; Volaire, F.; Boone, A.; Le Page, M.; Llasat, M.C.; Albergel, C.; Burak, S.; et al. Challenges for Drought Assessment in the Mediterranean Region under Future Climate Scenarios. *Earth-Science Rev.* **2020**, *210*, 103348, doi:10.1016/j.earscirev.2020.103348.
  11. Ferguson, C.R.; Pan, M.; Oki, T. The Effect of Global Warming on Future Water Availability: CMIP5 Synthesis. *Water Resour. Res.* **2018**, *54*, 7791–7819, doi:10.1029/2018WR022792.
  12. Russo, T.; Alfredo, K.; Fisher, J. Sustainable Water Management in Urban, Agricultural, and Natural Systems. *Water (Switzerland)* **2014**, *6*, 3934–3956, doi:10.3390/w6123934.
  13. Deines, J.M.; Kendall, A.D.; Crowley, M.A.; Rapp, J.; Cardille, J.A.; Hyndman, D.W. Mapping Three Decades of Annual Irrigation across the US High Plains Aquifer Using Landsat and Google Earth Engine. *Remote Sens. Environ.* **2019**, *233*, 111400, doi:10.1016/j.rse.2019.111400.
  14. Xie, Y.; Lark, T.J.; Brown, J.F.; Gibbs, H.K. Mapping Irrigated Cropland Extent across the Conterminous United States at 30 m Resolution Using a Semi-Automatic Training Approach on Google Earth Engine. *ISPRS J. Photogramm. Remote Sens.* **2019**, *155*, 136–149, doi:10.1016/j.isprsjprs.2019.07.005.
  15. Zurqani, H.A.; Allen, J.S.; Post, C.J.; Pellett, C.A.; Walker, T.C. Mapping and Quantifying Agricultural Irrigation in Heterogeneous Landscapes Using Google Earth Engine. *Remote Sens. Appl. Soc. Environ.* **2021**, *23*, 100590, doi:10.1016/j.rsase.2021.100590.
  16. Dari, J.; Quintana-Seguí, P.; Escorihuela, M.J.; Stefan, V.; Brocca, L.; Morbidelli, R. Detecting and Mapping Irrigated Areas in a Mediterranean Environment by Using Remote Sensing Soil Moisture and a Land Surface Model. *J. Hydrol.* **2021**, *596*, doi:10.1016/j.jhydrol.2021.126129.
  17. Gao, Q.; Zribi, M.; Escorihuela, M.J.; Baghdadi, N.; Segui, P.Q. Irrigation Mapping Using Sentinel-1 Time Series at Field Scale. *Remote Sens.* **2018**, *10*, 1–18, doi:10.3390/rs10091495.
  18. Lawston, P.M.; Santanello, J.A.; Kumar, S. V. Irrigation Signals Detected From SMAP Soil Moisture Retrievals. *Geophys. Res. Lett.* **2017**, *44*, 11,860–11,867, doi:10.1002/2017GL075733.
  19. Bazzi, H.; Baghdadi, N.; Fayad, I.; Zribi, M.; Belhouchette, H.; Demarez, V. Near Real-Time Irrigation Detection at Plot Scale Using Sentinel-1 Data. *Remote Sens.* **2020**, *12*, doi:10.3390/RS12091456.
  20. Demarez, V.; Helen, F.; Marais-Sicre, C.; Baup, F. In-Season Mapping of Irrigated Crops Using Landsat 8 and Sentinel-1 Time Series. *Remote Sens.* **2019**, *11*, doi:10.3390/rs11020118.
  21. Bousbih, S.; Zribi, M.; Hajj, M. El; Baghdadi, N.; Lili-Chabaane, Z.; Gao, Q.; Fanise, P. Soil Moisture and Irrigation Mapping in a Semi-Arid Region, Based on the Synergetic Use of Sentinel-1 and Sentinel-2 Data. *Remote Sens.* **2018**, *10*, 1–22, doi:10.3390/rs10121953.
  22. Bazzi, H.; Baghdadi, N.; Ienco, D.; Hajj, M. El; Zribi, M.; Belhouchette, H.; Escorihuela, M.J.; Demarez, V. Mapping Irrigated Areas Using Sentinel-1 Time Series in Catalonia, Spain. *Remote Sens.* **2019**, *11*, 1–25, doi:10.3390/rs11151836.
  23. Bazzi, H.; Baghdadi, N.; Amin, G.; Fayad, I.; Zribi, M.; Demarez, V.; Belhouchette, H. An Operational Framework for Mapping Irrigated Areas at Plot Scale Using Sentinel-1 and Sentinel-2 Data. *Remote Sens.* **2021**, *13*, 1–28, doi:10.3390/rs13132584.
  24. Gao, Q.; Zribi, M.; Escorihuela, M.J.; Baghdadi, N. Synergetic Use of Sentinel-1 and Sentinel-2 Data for Soil Moisture Mapping at 100 m Resolution. *Sensors (Switzerland)* **2017**, *17*, doi:10.3390/s17091966.
  25. Elwan, E.; Page, M. Le; Jarlan, L.; Baghdadi, N.; Brocca, L.; Modanesi, S.; Dari, J.; Segui, P.Q.; Zribi, M. Irrigation Mapping on Two Contrasted Climatic Contexts Using Sentinel-1 and Sentinel-2 Data. *Water (Switzerland)* **2022**, *14*, doi:10.3390/w14050804.
  26. Lu, Y.; Song, W.; Su, Z.; Lü, J.; Liu, Y.; Li, M. MAPPING IRRIGATED AREAS USING RANDOM FOREST BASED ON GF-1 MULTI-SPECTRAL DATA. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.* **2020**, *43*, 697–702, doi:10.5194/isprs-archives-XLIII-B2-2020-697-2020.
  27. Massari, C.; Modanesi, S.; Dari, J.; Gruber, A.; De Lannoy, G.J.M.; Giroto, M.; Quintana-Seguí, P.; Le Page, M.; Jarlan, L.; Zribi, M.; et al. A Review of Irrigation Information Retrievals from Space and Their Utility for Users. *Remote Sens.* **2021**, *13*, 1–26, doi:10.3390/rs13204112.
  28. *JCRM O Memoria 2020-2021; 2021;*
  29. Benediktsson, A.; Ieee, F.; Sun, Z.; Shen, J.; Zhu, Y. Big Data for Remote Sensing : Challenges and Opportunities. **2016**, *104*.
  30. Ma, Y.; Wu, H.; Wang, L.; Huang, B.; Ranjan, R.; Zomaya, A. Remote Sensing Big Data Computing : Challenges and Opportunities. *Futur. Gener. Comput. Syst.* **2015**, *51*, 47–60, doi:10.1016/j.future.2014.10.029.
  31. Hernández-López, D.; Piedelobo, L.; Moreno, M.A.; Chakhar, A.; Ortega-Terol, D.; González-Aguilera, D. Design of a Local Nested Grid for the Optimal Combined Use of Landsat 8 and Sentinel 2 Data. *Remote Sens.* **2021**, *13*, doi:10.3390/rs13081546.



# XXXIX Congreso Nacional de Riegos ÚBEDA (JAÉN)

18, 19, 20 de octubre de 2023



32. Lastovicka, J.; Svec, P.; Paluba, D.; Kobliuk, N.; Svoboda, J.; Hladky, R.; Stych, P. Sentinel-2 Data in an Evaluation of the Impact of the Disturbances on Forest Vegetation. *Remote Sens.* **2020**, *12*, doi:10.3390/rs12121914.
33. Chakhar, A.; Hernández-López, D.; Ballesteros, R.; Moreno, M.A. Improving the Accuracy of Multiple Algorithms for Crop Classification by Integrating Sentinel-1 Observations with Sentinel-2 Data. *Remote Sens.* **2021**, *13*, 1–21, doi:10.3390/rs13020243.
34. Chakhar, A.; Hernández-López, D.; Zitouna-Chebbi, R.; Mahjoub, I.; Ballesteros, R.; Moreno, M.A. Optimized Software Tools to Generate Large Spatio-Temporal Data Using the Datacubes Concept: Application to Crop Classification in Cap Bon, Tunisia. *Remote Sens.* **2022**, *14*, doi:10.3390/rs14195013.
35. Chakhar, A.; Hernández-López, D.; Ballesteros, R.; Moreno, M.A. Improvement of the Soil Moisture Retrieval Procedure Based on the Integration of Uav Photogrammetry and Satellite Remote Sensing Information. *Remote Sens.* **2021**, *13*, doi:10.3390/rs13244968.
36. El Hajj, M.; Baghdadi, N.; Belaud, G.; Zribi, M.; Cheviron, B.; Courault, D.; Hagolle, O.; Charron, F. Irrigated Grassland Monitoring Using a Time Series of TerraSAR-X and COSMO-SkyMed X-Band SAR Data. *Remote Sens.* **2014**, *6*, 10002–10032, doi:10.3390/rs61010002.