

Sanz Cano, J.; González-Audícana, M.; Álvarez-Mozos, J. Clasificación de cultivos mediante series temporales Sentinel-1: contribución de observables pseudo-polarimétricas

# Clasificación de cultivos mediante series temporales Sentinel-1: contribución de observables pseudo-polarimétricas

Sanz Cano, Judit <sup>1</sup> González-Audícana, María <sup>1</sup> Álvarez-Mozos, Jesús <sup>1</sup>

<sup>1</sup> Universidad Pública de Navarra, España

ORCID: Sanz Cano 0009-0000-4104-5545 González-Audícana 0000-0002-2430-3853 Álvarez-Mozos 0000-0002-6518-2533

Correspondencia: [judit.sanz@unavarra.es](mailto:judit.sanz@unavarra.es) [maria.audicana@unavarra.es](mailto:maria.audicana@unavarra.es) [jesus.alvarez@unavarra.es](mailto:jesus.alvarez@unavarra.es)

## RESUMEN

La utilización de imágenes radar para la clasificación de cultivos se presenta como una alternativa eficaz a las imágenes ópticas, especialmente en regiones con alta nubosidad. Este estudio evalúa el potencial de series temporales de coeficientes de retrodispersión VH y VV de Sentinel-1 para la clasificación de cultivos en una zona agrícola heterogénea y analiza cómo repercute en la fiabilidad de los resultados la incorporación de distintas observables pseudo-polarimétricas propuestas en la literatura (HV/VV, RVI, DpRVI, DpRBI, DpRSI, P<sub>(d-l)</sub>, P<sub>(s-l)</sub>, P<sub>(r)</sub>, Hc,  $\theta_c$  y mc). Los resultados mostraron que ciertas observables, como DpRVI, Hc y RVI están fuertemente correlacionadas mientras que P<sub>(d-l)</sub> y DpRBI aportan información complementaria. Los modelos de Random Forest alcanzaron una fiabilidad global superior al 80 % y valores de F1 similares, con diferencias mínimas respecto al modelo base VH y VV. Ninguna observable pseudo-polarimétrica mejoró la clasificación global. Los principales cultivos de verano y la mayoría de los de invierno, como cebada, trigo y guisante, se clasificaron con alto desempeño ( $F1 \geq 0.9$ ). Sin embargo, los cultivos minoritarios, los permanentes y las mezclas de cultivos se clasificaron peor. En conclusión, las series temporales de coeficiente de retrodispersión de Sentinel-1 en las polarizaciones VV y VH son suficientes para una clasificación robusta y precisa de la mayoría de cultivos. Las observables pseudo-polarimétricas generadas a partir de estas observaciones ofrecen un beneficio limitado para la clasificación de cultivos.




**Palabras clave:** Radar, Random Forest, RVI, fiabilidad, F1score

Fecha de recepción: 18 febrero 2026 · Fecha de aceptación: 18 febrero 2026

# Clasificación de cultivos mediante series temporales Sentinel-1: contribución de observables pseudo-polarimétricas

Sanz-Cano, Judit <sup>(1)</sup>, González-Audicana, María <sup>(1)</sup>, Álvarez-Mozos, Jesús <sup>(1)</sup>

<sup>(1)</sup> Institute for Sustainability & Food Chain Innovation (IS-FOOD), Dpto. Ingeniería, Universidad Pública de Navarra.

 0009-0000-4104-5545, judit.sanz@unavarra.es ;  0000-0002-6518-2533, jesus.alvarez@unavarra.es,  
 0000-0002-2430-3853, maria.audicana@unavarra.es

**Resumen:** La utilización de imágenes radar para la clasificación de cultivos se presenta como una alternativa eficaz a las imágenes ópticas, especialmente en regiones con alta nubosidad. Este estudio evalúa el potencial de series temporales de coeficientes de retrodispersión VH y VV de Sentinel-1 para la clasificación de cultivos en una zona agrícola heterogénea y analiza cómo repercute en la fiabilidad de los resultados la incorporación de distintas observables pseudo-polarimétricas propuestas en la literatura (HV/VV, RVI, DpRVI, DpRBI, DpRSI,  $P_{d-l}$ ,  $P_{s-l}$ ,  $P_r$ ,  $H_c$ ,  $\theta_c$  y  $m_c$ ). Los resultados mostraron que ciertas observables, como DpRVI,  $H_c$  y RVI están fuertemente correlacionadas mientras que  $P_{d-l}$  y DpRBI aportan información complementaria. Los modelos de Random Forest alcanzaron una fiabilidad global superior al 80 % y valores de F1 similares, con diferencias mínimas respecto al modelo base VH y VV. Ninguna observable pseudo-polarimétrica mejoró la clasificación global. Los principales cultivos de verano y la mayoría de los de invierno, como cebada, trigo y guisante, se clasificaron con alto desempeño ( $F1 \geq 0.9$ ). Sin embargo, los cultivos minoritarios, los permanentes y las mezclas de cultivos se clasificaron peor. En conclusión, las series temporales de coeficiente de retrodispersión de Sentinel-1 en las polarizaciones VV y VH son suficientes para una clasificación robusta y precisa de la mayoría de cultivos. Las observables pseudo-polarimétricas generadas a partir de estas observaciones ofrecen un beneficio limitado para la clasificación de cultivos.

**Palabras clave:** Radar, Random Forest, RVI, fiabilidad, F1score

## ***Crop classification using Sentinel-1 time series: contribution of pseudo-polarimetric observables***

**Abstract:** The use of radar imagery for crop classification represents an effective alternative to optical imagery, particularly in regions with high cloud cover. This study evaluates the potential of time series of Sentinel-1 VH and VV backscatter coefficients for crop classification in a heterogeneous agricultural area, and analyzes how the inclusion of various pseudo-polarimetric observables proposed in the literature (HV/VV, RVI, DpRVI, DpRBI, DpRSI,  $P_{d-l}$ ,  $P_{s-l}$ ,  $P_r$ ,  $H_c$ ,  $\theta_c$  and  $m_c$ ) affects the accuracy of the results. The results showed that certain observables, such as DpRVI, como DpRVI,  $H_c$  y RVI, are strongly correlated, while  $P_{d-l}$  and DpRBI provide complementary information. Random Forest models achieved overall accuracy values above 80% and similar F1-scores, with minimal differences compared to the baseline VH and VV model. None of the pseudo-polarimetric observables improved the overall classification performance. Major summer crops and most winter crops, such as barley, wheat, and pea, were classified with high performance ( $F1 \geq 0.9$ ), whereas minor crops, permanent crops, and crop mixtures were classified with lower accuracy. In conclusion, time series of Sentinel-1 backscatter coefficients in VV and VH polarizations are sufficient for robust and accurate classification of most crops, and pseudo-polarimetric observables derived from these measurements provide limited benefit for crop classification.

**Keywords:** Radar, Random Forest, RVI, reliability, F1score.

## 1. INTRODUCCIÓN

La clasificación de cultivos mediante teledetección se ha consolidado como una herramienta clave para la planificación y gestión de políticas agrícolas. Esta tecnología proporciona información sobre la distribución espacial de los cultivos y su evolución

campana a campana, lo que facilita la toma de decisiones y mejora la capacidad de respuesta frente a escenarios ambientales y comerciales cada vez más inciertos. En los últimos años, la investigación en clasificación de cultivos ha priorizado el uso combinado de sensores ópticos y radar (o SAR del

inglés *Synthetic Aperture Radar*), junto con la aplicación creciente de algoritmos de *machine learning* y *deep learning* (Pluto-Kossakowska, 2021). La amplia disponibilidad de imágenes SAR, especialmente de Sentinel-1, ha impulsado el interés en desarrollar enfoques basados exclusivamente en esta tecnología. Sentinel-1 ofrece observaciones en la banda C, con polarización doble VH-VV y con una frecuencia de revisita de unos 6 días (dependiendo de la región), lo que permite generar series temporales densas. Esta alta frecuencia de adquisición compensa en parte las limitaciones inherentes a la polarización doble frente a la polarimetría completa y permite un seguimiento continuo del desarrollo vegetal y fenología de los cultivos (Yin *et al.*, 2025). En este contexto, Sentinel-1 se ha consolidado como una alternativa viable incluso como sensor único en la clasificación de cultivos (Arias *et al.*, 2020).

La mayoría de los estudios de clasificación de cultivos con imágenes SAR se han basado en el coeficiente de retrodispersión (o intensidad) en las polarizaciones directa (VV o HH) y/o cruzada (VH o HV) como variables de entrada al clasificador. No obstante, en los últimos años se han propuesto otras observables SAR, incluyendo índices y descriptores pseudo-polarimétricos, que proporcionan características adicionales sobre el comportamiento retrodispersivo de las cubiertas observadas sin la complejidad propia de la polarimetría completa. Estas observables han mostrado resultados prometedores para el seguimiento de distintos cultivos (Bhogapurapu *et al.*, 2021, 2022; Nasirzadehdizaji *et al.*, 2019; Verma *et al.*, 2024). El objetivo de este trabajo es evaluar el rendimiento de un modelo de clasificación de cultivos basado en Random Forest (RF) utilizando datos Sentinel-1 (intensidad en VV y VH), y analizar si la incorporación de observables pseudo-polarimétricas aporta información adicional relevante que mejore la precisión de la clasificación.

## 2. MATERIAL Y MÉTODOS

### 2.1. Zona de estudio

La zona de estudio está situada en el suroeste de la Comunidad Foral de Navarra (España) y se corresponde con la comarca agraria VI-Ribera Alta de Aragón. En esta zona, el clima es mediterráneo, con una precipitación media anual de ~350 mm y una temperatura media de 14 °C. La altitud oscila entre 259 y 652 m s. n. m. Se trata de una de las zonas con mayor diversidad de cultivos de Navarra, destinándose alrededor del 70 % de su superficie al uso agrícola.

### 2.2. Imágenes satelitales

Para el desarrollo de este trabajo se utilizaron todas las imágenes Sentinel-1 A y B adquiridas entre el 1/09/2016 al 31/12/2017. Las imágenes se descargaron en modo *Interferometric Wide Swath* (IW) dual-pol VV-VH, como productos de nivel 1 *Ground Range Detected* (GRD). En total se utilizaron 78 imágenes de la órbita 8DESC. Los ángulos de incidencia local en la zona de estudio fueron entre 43

y 45° y la hora de adquisición de las imágenes en torno a las ~6:00 UTC.

Todas las imágenes se procesaron utilizando el *Graph Processing Toolbox* (GPT) de *SNAP Sentinel-1 Toolbox*, aplicando los siguientes pasos (Arias *et al.*, 2020); 1) eliminación de ruido térmico; 2) ensamblaje de cortes; 3) actualización de órbitas; 4) calibración a  $\beta^0$ ; 5) filtrado de moteado (Gamma-MAP 3×3); 6) corrección topográfica a  $\gamma_{TF}^0$  (TF del inglés *Terrain Flattening*) y 7) Ortorrectificación. Como variables de salida se obtuvieron las imágenes coeficiente de retrodispersión  $\gamma_{TF}^0$  en las polarizaciones VV y VH para un tamaño de pixel de 20 m.

### 2.3. Observables pseudo-polarimétricas

A partir de las imágenes Sentinel-1 ya procesadas se calcularon las observables pseudo-polarimétricas propuestas en la literatura (Tabla 1).

**Tabla 1.** Observables pseudo-polarimétricas.

Símbolo	Nombre	Referencia
VH/VV	Ratio de polarización cruzada	
RVI	Radar Vegetation Index	(Nasirzadehdizaji <i>et al.</i> , 2019)
DpRVI	Dual-pol Radar Vegetation Index	(Bhogapurapu <i>et al.</i> , 2022)
DpRBI	Dual-polarimetric Radar Built-up Index	
DpRSI	Dual-polarimetric Radar Surface Index	(Verma <i>et al.</i> , 2024)
$P_{d-l}$	Dihedral-like scattering power	
$P_{s-l}$	Surface-like scattering power	
$P_r$	Residue scattering power	
Hc	Pseudo scattering entropy	(Bhogapurapu <i>et al.</i> , 2021)
$\theta_c$	Pseudo scattering-angle	
mc	Co-pol purity parameter	

### 2.4. Datos de entrenamiento y validación

Para entrenar y validar el algoritmo de clasificación se empleó una base de datos geográfica proporcionada por Gobierno de Navarra, que incluye las declaraciones PAC correspondientes a la campaña agrícola 2016-2017, así como las inspecciones de campo realizadas en dicha campaña.

El conjunto de entrenamiento se generó a partir de una selección de parcelas representativas de cada cultivo, 36903 parcelas, según el procedimiento descrito por González-Audicana *et al.* (2020). Como conjunto de validación se utilizaron las 3687 parcelas inspeccionadas en campo, lo que permitió evaluar los resultados de la clasificación con datos no incluidos en el entrenamiento. Las parcelas de validación suponen aproximadamente el 9% de la superficie agrícola total de la comarca de estudio y se corresponden con los siguientes cultivos (indicándose entre paréntesis el número de parcelas por cultivo): avena (53), cebada (1210), trigo (502), veza (9), guisante (23), mezclas con cereal (30), arroz (105), maíz (194), tomate (33), girasol (15), alfalfa (87), espárragos (18), almendros (26), frutales (89), olivar (79), viña (185), pastos (531), superficies forestales (7) y barbecho (491).

## 2.5. Extracción y análisis de datos

Para cada parcela del conjunto de entrenamiento y validación se extrajeron las series temporales completas correspondientes a todas las observables analizadas. Posteriormente, se calcularon las series temporales promedio por cultivo con el fin de evaluar la correlación temporal entre observables mediante el coeficiente de correlación de Spearman ( $\rho$ ).

## 2.6. Clasificación RF

En primer lugar, se implementó un modelo base utilizando como variables de entrada únicamente los coeficientes de retrodispersión VH y VV. Posteriormente, se generaron 11 modelos adicionales incorporando de manera individual cada observable al modelo base, con el fin de evaluar su contribución específica a la clasificación. El clasificador RF se configuró con una profundidad máxima de 40 niveles y un número de 300 estimadores, siguiendo las recomendaciones del proyecto Sen4CAP (Bontemps *et al.*, 2024). Para equilibrar el número de parcelas de entrenamiento entre clases, se aplicó el método de balanceo SMOTE-Tomek (Batista *et al.*, 2003). Para evaluar el rendimiento de los modelos se calcularon las métricas de fiabilidad global (FG) y el F1-score por cultivo para el conjunto de validación.

## 3. RESULTADOS Y DISCUSIÓN

### 3.1. Correlación entre observables

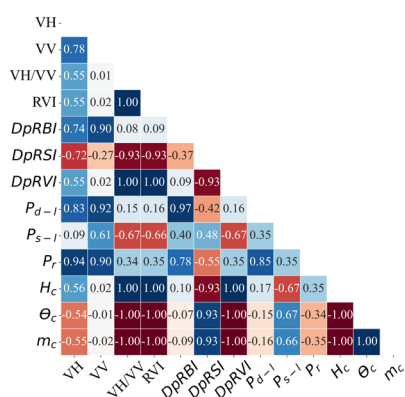


Figura 1. Matriz de correlación de Spearman.

A nivel general, la matriz de correlación (Figura 1) revela la existencia de agrupaciones de observables radar con un comportamiento muy similar o incluso idéntico. Se observan correlaciones perfectas positivas o negativas (1 o -1) entre VH/VV, RVI, DpRVI,  $H_c$ ,  $\theta_c$  y  $m_c$ , lo que indica redundancia en la información temporal recogida por estas observables, que básicamente aportan la misma información. Por otro lado, las observables  $P_r$ ,  $P_{d-l}$  y DpRBI presentan fuertes correlaciones positivas con las intensidades VH (0.94, 0.83 y 0.74) y VV ( $\geq 0.9$ ). En contraste con el resto de observables,  $P_{s-l}$  y DpRBI, presentan correlaciones promedio más bajas, indicando patrones de relación diferentes y pudiendo aportar información complementaria y menos redundante al modelo base de clasificación. Las demás observables

tienen correlaciones intermedias entre ellas, en el rango de 0.5–0.7. La intensidad en VV mostró la correlación promedio más débil de todo el conjunto global.

### 3.2. Resultados de la clasificación RF

Tabla 2. Resultados de fiabilidad global (FG) de las clasificaciones, y su diferencial respecto al modelo base ( $\Delta FG$ )


Modelo	FG	$\Delta FG$	Modelo	FG	$\Delta FG$
VV, VH	82.89	-	$P_{d-l}$	82.89	0.00
VH/VV	82.59	-0.30	$P_{s-l}$	82.40	-0.49
RVI	82.70	-0.19	$P_r$	82.42	-0.47
DpRVI	82.21	-0.68	$H_c$	82.42	-0.47
DpRBI	82.75	-0.14	$\theta_c$	82.42	-0.47
DpRSI	82.56	-0.33	$m_c$	82.67	-0.22

Los resultados obtenidos por el modelo base (VV, VH) fueron muy positivos con una FG de casi el 83% (Tabla 2), en comparación con el 70% reportado por Eisfelder *et al.* (2024). La adición de observables pseudo-polarimétricas a este modelo base no produjo mejoras en el rendimiento del modelo de referencia, mostrando variaciones mínimas que indican un comportamiento prácticamente equivalente o ligeramente inferior. Estos resultados muestran que la información contenida en las series temporales de intensidad en VV y VH ya captura la mayor parte del poder discriminante necesario para la clasificación. El modelo que incluyó  $P_{d-l}$  fue el que obtuvo mejores resultados, manteniendo la misma FG que el modelo de referencia. Por el contrario, DpRVI mostró la mayor caída en el rendimiento ( $\Delta FG = -0.68$ )

### 3.3. Resultados específicos por cultivo

La mayoría de los cultivos alcanzaron un alto desempeño con el modelo base, con  $F1 \geq 0.8$ . Tomate y arroz lograron  $F1 = 1.00$ , mientras que maíz, girasol y cebada presentaron valores entre 0.91 y 0.93. Otros cultivos, como trigo y guisante, tuvieron  $F1$  de 0.86, respectivamente, mientras que barbecho, pastos, viña y alfalfa mostraron valores moderados (entre 0.76 y 0.79). Algunos cultivos, como la veza, olivar, espárrago, frutales y avena, presentaron rendimientos bajos ( $F1 = 0.37, 0.49, 0.56, 0.60$  y  $0.63$ ) así como las superficies forestales, con  $F1$  de 0.14, almendros y mezclas con cereal obtuvieron valores nulos. Tendencias similares se observaron para la mayoría de cultivos en otros estudios (Arias *et al.*, 2020; Ioannidou *et al.*, 2022). En general, el modelo de referencia mostró un alto nivel de desempeño en la identificación de la mayoría de los cultivos principales. La Figura 2 muestra que los cultivos de invierno, particularmente avena y veza, alcanzaron mejoras moderadas respecto al modelo base al incluir alguna de las observables pseudo-polarimétricas. La veza presentó los mayores incrementos con  $\theta_c$  (0.20) y RVI o  $H_c$  (0.11), mientras que la avena mostró su principal mejora con DpRVI (0.11). En contraste, almendros, guisante y mezclas con cereal únicamente evidencian incrementos puntuales en algunos modelos  $P_{d-l}$ ,  $P_r$  y  $\theta_c$  respectivamente, mostrando en general diferencias mínimas con respecto al modelo base. Por el

contrario, algunos cultivos mostraron descensos más acusados al incorporar determinadas observables pseudo-polarimétricas. En particular, los guisantes presentaron las mayores reducciones de rendimiento especialmente con DpRVI (-0.14), VH/VV y RVI (-0.11), y con  $H_c$  (-0.10). La veza también evidenció ligeras disminuciones en varios modelos (-0.07) como DpRBI y  $P_{d-l}$ . Estos resultados sugieren que la contribución de cada observable pseudo-polarimétrica a la clasificación depende en gran medida del tipo de cultivo y de cómo este interactúa con la señal radar.



**Figura 2.**  $\Delta F1$ -score por cultivo respecto al modelo base (VH y VV). Solo se incluyen cultivos con mejoras  $\geq 0.05$ .

#### 4. CONCLUSIÓN

Los resultados demuestran el potencial de las series temporales de los coeficientes de retrodispersión VV y VH de Sentinel-1 para la clasificación de cultivos, ya que estas polarizaciones contienen la mayor parte de la información discriminante. La señal principal de VH y VV es suficiente para lograr una clasificación robusta y precisa, con un rendimiento superior al 80 % utilizando RF. Las observables pseudo-polarimétricas derivadas, que se generan a partir de VH y VV, aportan un valor limitado para la clasificación, sin mejorar la fiabilidad global ni el F1-score, dado que esencialmente contienen información ya presente en las polarizaciones originales. No obstante, estas observables adicionales pueden contribuir puntualmente a una mejor detección de algunos cultivos concretos, como veza, avena, almendros o guisante, ofreciendo información complementaria aunque con un impacto reducido en términos globales.

#### 5. AGRADECIMIENTOS

Este trabajo ha sido financiado por los proyectos PID2019-107386RB-I00 y PID2023-152885OB-I00 / AEI / 10.13039/501100011033 y el contrato predoctoral FPI PRE2020-092161.

#### 6. REFERENCIAS

Arias, M., Campo-Bescós, M. Á., & Álvarez-Mozos, J. (2020). Crop Classification Based on Temporal Signatures of Sentinel-1 Observations over Navarre Province, Spain. *Remote Sensing*, 12(2), Article 2. <https://doi.org/10.3390/rs12020278>

Batista, G., L. C. Bazzan, A., & Monard, M. C. (2003). *Balancing training data for automated annotation of keywords: A case study*. 10-18.

Bhogapurapu, N., Dey, S., Bhattacharya, A., Mandal, D., Lopez-Sanchez, J. M., McNairn, H., López-

Martínez, C., & Rao, Y. S. (2021). Dual-polarimetric descriptors from Sentinel-1 GRD SAR data for crop growth assessment. *ISPRS Journal of Photogrammetry and Remote Sensing*, 178, 20-35. <https://doi.org/10.1016/j.isprsjprs.2021.05.013>

Bhogapurapu, N., Dey, S., Mandal, D., Bhattacharya, A., Karthikeyan, L., McNairn, H., & Rao, Y. S. (2022). Soil moisture retrieval over croplands using dual-pol L-band GRD SAR data. *Remote Sensing of Environment*, 271, 112900. <https://doi.org/10.1016/j.rse.2022.112900>

Bontemps, S., Bajec, K., Cara, C., Defourny, P., De Vendictis, L., Heymans, D., Kucera, L., Malcorps, P., Milcinski, G., Nicola, L., Slacikova, J., Taymans, M., Tutunaru, F., & Udriou, C. (2024). *Sen4CAP - Sentinels for Common Agricultural Policy System Software User Manual (Sen4CAP\_SUM\_v4.0)* (Ref Issue 4.0). ESA. <http://creativecommons.org/licenses/by-sa/4.0/>

Eisfelder, C., Boemke, B., Gessner, U., Sogno, P., Alemu, G., Hailu, R., Mesmer, C., & Huth, J. (2024). Cropland and Crop Type Classification with Sentinel-1 and Sentinel-2 Time Series Using Google Earth Engine for Agricultural Monitoring in Ethiopia. *Remote Sensing*, 16(5), 866. <https://doi.org/10.3390/rs16050866>

González-Audicana, M., López, S., Sola, I., & Álvarez-Mozos, J. (2020). Estrategia para la verificación de declaraciones PAC a partir de imágenes Sentinel-2 en Navarra. *Revista de Teledetección*, (56), 69. <https://doi.org/10.4995/raet.2020.14128>

Ioannidou, M., Koukos, A., Sitokonstantinou, V., Papoutsis, I., & Kontoes, C. (2022). Assessing the Added Value of Sentinel-1 PolSAR Data for Crop Classification. *Remote Sensing*, 14(22), 5739. <https://doi.org/10.3390/rs14225739>

Nasirzadehdzaji, R., Balik Sanli, F., Abdikan, S., Cakir, Z., Sekertekin, A., & Ustuner, M. (2019). Sensitivity Analysis of Multi-Temporal Sentinel-1 SAR Parameters to Crop Height and Canopy Coverage. *Applied Sciences*, 9(4), Article 4. <https://doi.org/10.3390/app9040655>

Pluto-Kossakowska, J. (2021). Review on Multitemporal Classification Methods of Satellite Images for Crop and Arable Land Recognition. *Agriculture*, 11(10), 999. <https://doi.org/10.3390/agriculture11100999>

Verma, A., Bhattacharya, A., Dey, S., López-Martínez, C., & Gamba, P. (2024). Rice Crop Monitoring Using Dual-Pol Sentinel-1 SLC and GRD Scattering Power Components. *IGARSS 2024 - 2024 IEEE International Geoscience and Remote Sensing Symposium*, 10826-10829. <https://doi.org/10.1109/IGARSS53475.2024.10641403>

Yin, Q., Du, Y., Li, F., Zhou, Y., & Zhang, F. (2025). Multi-Temporal Dual Polarimetric SAR Crop Classification Based on Spatial Information Comprehensive Utilization. *Remote Sensing*, 17(13), 2304. <https://doi.org/10.3390/rs17132304>