



**VNiVERSiDAD  
D SALAMANCA**

CAMPUS DE EXCELENCIA INTERNACIONAL

DEPARTAMENTO DE INGENIERÍA CARTOGRÁFICA Y DEL TERRENO

**TESIS DOCTORAL**

Seguimiento y clasificación de parámetros biofísicos de superficies agrícolas a partir de sensores remotos radar

Rubén Valcarce Diñeiro

Ávila, noviembre 2020



Departamento de Ingeniería Cartográfica y del Terreno

Escuela Politécnica Superior de Ávila

Universidad de Salamanca

AUTOR:

**D. Rubén Valcarce Diñeiro**

DIRECTORES:

**Dr. Benjamín Arias Pérez**

**Dra. María Nilda Sánchez Martín**

**2020**



**Dña. María Nilda Sánchez Martín**, Profesora Titular de Ingeniería Cartográfica, Geodésica y Fotogrametría del Departamento de Ingeniería Cartográfica y del Terreno de la Universidad de Salamanca.

**D. Benjamín Arias Pérez**, Profesor Titular de Ingeniería Cartográfica, Geodésica y Fotogrametría del Departamento de Ingeniería Cartográfica y del Terreno de la Universidad de Salamanca.

CERTIFICAN:

Que la memoria "**Seguimiento y clasificación de parámetros biofísicos de superficies agrícolas a partir de sensores remotos radar**" ha sido realizada por **D. Rubén Valcarce Diñeiro** bajo nuestra codirección desde el Departamento de Ingeniería Cartográfica y del Terreno de la Universidad de Salamanca, y es favorable para obtener el grado de Doctor por la Universidad de Salamanca en el programa de doctorado en Geotecnologías Aplicadas a la Construcción, Energía e Industria.

Para que así conste, firmamos el presente certificado en Salamanca, a 21 de octubre de 2020.



Dña. María Nilda Sánchez Martín



D. Benjamín Arias Pérez



*A mis padres, Felicitas y José María,  
y a mi hermana Soraya*





## Agradecimientos

Quiero dar las gracias a todas las personas que me han guiado y ayudado en la realización del trabajo y lo han hecho más fácil. Personas que de muchas y muy diferentes maneras han sido importantes.

En primer lugar, quiero agradecerles a mis directores de tesis María Nilda Sánchez Martín y Benjamín Arias Pérez por depositar su confianza en mí, sus consejos y el esfuerzo y dedicación que han invertido en esta investigación y los conocimientos que me han transmitido han hecho posible la elaboración de esta Tesis. Espero haber aprendido de su capacidad de trabajo, responsabilidad, constancia y actitud práctica.

También me gustaría extender mi gratitud al Dr. Juan Manuel López Sánchez de la Universidad de Alicante por toda la ayuda y conocimientos que ha proporcionado sobre la temática. Al Dr. José Martínez Fernández del grupo HIDRUS de la Universidad de Salamanca por permitirnos tener acceso a datos de la red REMEDHUS.

A mis amigos en España porque a pesar de la distancia siempre puedes contar con ellos. También a todas aquellas personas que he conocido en Inglaterra que hacen que la distancia sea más amena, especialmente a Oscar, Isa, Manuel y Elvira que me han permitido formar parte de su familia.

Finalmente me gustaría dar las gracias a mi familia por todo el cariño y apoyo que me han dado, especialmente a mis padres Felicitas y José María, y mi hermana Soraya por haber estado ahí cuando uno más lo necesitaba y haberme dado fuerzas para finalizar el viaje. Esta tesis va dedicada a vosotros.



## Resumen

El seguimiento y la clasificación de los cultivos agrícolas tienen una gran importancia en la gestión socio-económica de las sociedades y son esenciales para la gestión sostenible de las actividades agrícolas. Con esta información, autoridades locales, nacionales o internacionales, cooperativas agrícolas o agricultores, pueden tener acceso a información precisa y actualizada para poder llevar a cabo una mejor gestión de los cultivos, además de obtener información sobre el crecimiento de los cultivos o la estimación de su rendimiento.

El empleo de la teledetección, al ser una forma no destructiva de monitorear la vegetación, es una herramienta ideal para ayudar a lograr la información necesaria. Y su cobertura temporal ininterrumpida permite seguir los ciclos fenológicos de las plantas. Aunque la teledetección óptica se ha utilizado con éxito para el seguimiento y clasificación de cultivos agrícolas, estos sistemas se limitan a los datos adquiridos en condiciones de cielo despejado. En este contexto, los datos adquiridos por sensores radar de apertura sintética (SAR) son de gran interés para aplicaciones agrícolas debido a la capacidad de estos sistemas para monitorear los cultivos en todas las condiciones climáticas y la sensibilidad de la señal de microondas a las propiedades dieléctricas y geométricas del objetivo.

Dependiendo de la configuración del sistema, los sensores SAR pueden adquirir datos en diferentes modos. La adquisición de datos en diferentes modos ha establecido técnicas de procesamiento como la polarimetría (PolSAR), interferometría (InSAR) e interferometría diferencial (DInSAR). Para el desarrollo de esta tesis se ha empleado la polarimetría, ya que en el ámbito de la agricultura el empleo de esta técnica se basa en la bien conocida sensibilidad de las microondas a la estructura del cultivo, las propiedades dieléctricas del dosel y las propiedades físicas del suelo subyacente.

Los objetivos de esta tesis han sido varios. Por una parte, ampliar el conocimiento de los observables SAR (más allá de los coeficientes de retrodispersión) para el seguimiento/monitoreo de cultivos; investigar el efecto del ángulo de incidencia en la relación entre los observables polarimétricos y diferentes variables biofísicas; y finalmente, estudiar la viabilidad de los observables SAR para clasificar y distinguir cultivos agrícolas.

Para llevar a cabo el primer y segundo objetivo se empleó una serie temporal de 20 imágenes RADARSAT-2 adquiridas a diferentes ángulos de incidencia (25°, 31° y 36°) durante la temporada de crecimiento de cultivos de secano. A partir de las imágenes se extrajeron 10 observables polarimétricos, mientras que 6 variables biofísicas se estimaron a partir de mediciones *in situ*. Posteriormente, se realizó un análisis descriptivo y de correlación estadística entre ambos conjuntos de datos. Los resultados expuestos en esta tesis muestran correlaciones significativas entre varios observables polarimétricos (HH/VV, HV/VV,  $\gamma_{HHVV}$ ,  $\alpha_1$ ,  $\gamma_{P1P2}$ ) con varias variables biofísicas como la biomasa, la altura y el índice de área foliar para ángulos de incidencia de 31° y 36°.

Para cumplir con el último objetivo, se realizó una clasificación de cultivos aplicando un algoritmo de aprendizaje automático y usando como datos de entrada para el clasificador los 10 observables polarimétricos de la serie temporal de RADARSAT-2 junto con 3 observables más extraídos de una serie temporal de imágenes Sentinel-1. Debido a la gran cantidad de datos, se crearon 7 escenarios distintos para evaluar la clasificación. El empleo de todos los observables e imágenes RADARSAT-2 demostró tener claros beneficios en términos de precisión general a la hora de clasificar. El análisis individual para cubierta mostró la buena separación de los cereales de primavera, típicamente difícil debido a su estructura y fenología similares; mientras que los cultivos de verano mostraron resultados no tan buenos de exactitud debido a la falta de imágenes en esas fechas. En cuanto a las capacidades polarimétricas de RADARSAT-2 (full) y Sentinel-1 (dual) son bastante diferentes, el enfoque multitemporal reforzó el proceso de clasificación y proporcionó resultados satisfactorios similares para los diferentes escenarios de clasificación propuestos.

## Abstract

Monitoring and classification of agricultural crops has substantial importance in the socio-economic management of societies and are essential for the sustainable management of agricultural activities. With this information, local, national or international authorities, agricultural cooperatives or farmers can have access to accurate and up-to-date information to carry out a better crop management, in addition to obtaining information about the crop growth and their yield estimation.

The use of remote sensing, as it is a nondestructive way of monitoring vegetation, it appears as an ideal tool to help achieving the necessary information, and its uninterrupted temporal coverage allows to follow the phenological cycles of plants. Although, optical remote sensing has been successfully used for agricultural crop monitoring and classification, these systems are limited to data acquired under clear sky conditions. In this context, data acquired from synthetic aperture radar (SAR) sensors are of great interest for agricultural applications due to the ability of these systems to monitor crops in all weather conditions and the sensitivity of the microwave signal to the dielectric and geometric properties of the target.

Depending on the system configuration, SAR sensors can acquire data in different modes. The acquisition of data in different modes has established processing techniques such as polarimetry (PolSAR), interferometry (InSAR) and differential interferometry (DInSAR). Polarimetry was used in this thesis. The use of SAR polarimetry (PolSAR) in agriculture applications is based on the known sensitivity of microwaves to crop structure, dielectric properties of the canopy, and the physical properties of the underlying soil.

There are several objectives in this thesis. Firstly, extend the knowledge about the potential of polarimetric SAR observables (i.e. beyond the backscattering coefficients) for crop monitoring and classification. Secondly, investigate the effect of incidence angle on the relationship between polarimetric observables and different biophysical variables, and finally, study the feasibility of SAR observables to classify and distinguish agricultural crops.

To carry out the first and second objectives, a time series of 20 RADARSAT-2 images acquired at different incidence angles (i.e., 25°, 31° and 36°) was used during an entire growing season of rainfed crops. Ten polarimetric observables were derived from the images, whereas six biophysical variables were gathered from *in situ* measurements. Subsequently, a descriptive and statistical correlation analysis between both sets of data was performed. The results presented in this thesis show significant correlations between polarimetric observables (HH/VV, HV/VV,  $\gamma_{HHVV}$ ,  $\alpha_1$ ,  $\gamma_{P1P2}$ ) and several biophysical variables such as biomass, height, or leaf area index (LAI) at incidence angles of 31° and 36°.

To achieve the last objective, a crop classification was carried out applying a machine learning algorithm and using the 10 polarimetric observables of the RADARSAT-2 time series together with 3 more observables derived from a time series of Sentinel-1 images as input data for the classifier. The

use of all polarimetric RADARSAT-2 observables and images produced clear benefits in terms of the overall accuracy when classifying. The analysis of individual covers showed the good separation of spring cereals, typically difficult owing to their similar structure and phenology; while summer crops showed middling results due to the lack of images at that time. As for the polarimetric capabilities of RADARSAT-2 (full) and Sentinel-1 (dual) are quite different, the multitemporal approach strengthened the classification process and provided similar satisfactory results for the different proposed classification scenarios.

# Índice General

Agradecimientos .....	ix
Resumen .....	xi
Abstract.....	xiii
Índice General.....	xv
Acrónimos .....	xix
Lista de Figuras .....	xxi
Lista de Tablas.....	xxv
Capítulo 1: Introducción .....	29
1.1. Motivación.....	29
1.2. Objetivos.....	31
1.3. Organización.....	32
Capítulo 2: Antecedentes.....	37
2.1. Fundamentos SAR.....	37
2.1.1. Geometría de la imagen.....	37
2.1.2. Resolución de la imagen.....	38
2.2. Polarimetría radar .....	39
2.2.1. Ecuación radar.....	39
2.2.2. Matriz de dispersión.....	40
2.2.2.1. Convenciones de los sistemas de coordenadas .....	41
2.2.2.2. Vector objetivo .....	43
2.2.3. Matrices de coherencia y covarianza polarimétricas.....	44
2.2.4. Parámetros polarimétricos .....	45
2.2.4.1. Parámetros estimados a partir de la matriz de covarianza .....	45
2.2.4.2. Parámetros estimados a partir de la matriz de coherencia .....	46
2.3. Observación agronómica .....	49
2.3.1. Seguimiento de cultivos agrícolas.....	49
2.3.2. Variables biofísicas de la vegetación .....	49
2.3.3. Estimación de variables biofísicas .....	51
2.4. Radar aplicado a la agricultura .....	52

2.4.1.	Datos SAR aplicados al seguimiento de cultivos agrícolas .....	54
2.4.2.	Clasificación de coberturas del suelo a partir de datos de radar .....	56
Capítulo 3: Área de estudio .....		63
3.1.	Sustrato geológico y relieve .....	63
3.2.	Clima .....	66
3.3.	Características hidrológicas generales.....	68
3.4.	Edafología y coberturas del suelo .....	70
Capítulo 4: Materiales y Métodos .....		75
4.1.	Campaña de campo para la estimación de parámetros de los cultivos.....	75
4.1.1.	Diseño experimental.....	75
4.1.2.	Mediciones biofísicas .....	76
4.2.	Mapa de referencia para la clasificación .....	79
4.3.	Imágenes de radar .....	81
4.4.	Métodos .....	83
4.4.1.	Pre-procesamiento de los datos SAR .....	83
4.4.1.1.	RADARSAT-2.....	83
4.4.1.2.	Sentinel-1 .....	85
4.4.2.	Estimación de los observables polarimétricos.....	87
4.4.3.	Métodos para la estimación de parámetros biofísicos.....	88
4.4.3.1.	Interpolación temporal de los datos in situ .....	88
4.4.3.2.	Análisis de correlación terreno vs. imágenes .....	89
4.4.4.	Métodos de clasificación: árboles de decisión.....	91
4.4.4.1.	See5 / C5.0 .....	93
4.4.5.	Métodos de clasificación: escenarios de clasificación .....	94
4.4.6.	Métodos de clasificación: evaluación de la exactitud .....	95
Capítulo 5: Resultados y Discusión.....		99
5.1.	Estimación de variables biofísicas.....	99
5.2.	Evaluación de los parámetros SAR y efecto del ángulo de incidencia .....	100
5.2.1.	Coeficientes de retrodispersión .....	100
5.2.2.	Correlación entre HH y VV .....	105
5.2.3.	Diferencia de fase de polarización .....	106
5.2.4.	Entropía y ángulo alfa dominante.....	107



5.2.5. Correlación entre los dos primeros canales en la base de Pauli.....	110
5.3. Análisis de correlación entre los parámetros del radar y las variables biofísicas.....	111
5.4. Clasificación de la cobertura del suelo y evaluación de la exactitud.....	120
5.5. Evaluación de los atributos.....	129
5.5.1. Posibles aplicaciones del análisis de importancia de los atributos.....	133
Capítulo 6: Conclusiones.....	139
Capítulo 7: Perspectivas futuras.....	145
Bibliografía.....	149
Publicaciones.....	169
Anexo A: Influence of Incidence Angle in the Correlation of C-band Polarimetric Parameters with Biophysical Variables of Rain-fed Crops.....	173
Anexo B: Multi-temporal Dual- and Quad-Polarimetric Synthetic Aperture Radar Data for Crop Type Mapping.....	191



## Acrónimos

ANN	<i>Artificial Neural Networks</i>
ALOS	<i>Advanced Land Observing Satellite</i>
ASAR	<i>Advanced Synthetic Aperture Radar</i>
ASCAT	<i>Advanced Scatterometer</i>
BSA	<i>Backward Scattering Alignment</i>
CART	<i>Classification And Regression Trees</i>
CHD	<i>Confederación Hidrográfica del Duero</i>
COSMO-SkyMed	<i>Constellation of Small Satellites for Mediterranean basin Observation</i>
CPD	<i>Co-polarization Phase Difference</i>
CSA	<i>Canadian Space Agency</i>
DInSAR	<i>Differential Interferometric Synthetic Aperture Radar</i>
DLR	<i>Deutsches Zentrum für Luft- und Raumfahrt</i>
DoY	<i>Day of Year</i>
DT	<i>Decision Trees</i>
ECV	<i>Essential Climate Variables</i>
ENVISAT	<i>Environmental Satellite</i>
ESA	<i>European Space Agency</i>
ERS	<i>European Remote Sensing</i>
EW	<i>Extra Wide Swath</i>
fAPAR	<i>Fraction of Absorbed Photosynthetically Active Radiation</i>
FAO	<i>Food and Agriculture Organization</i>
FSA	<i>Forward Scattering Alignment</i>
FVC	<i>Fraction of Vegetation Cover</i>
GCOS	<i>Global Climate Observing System</i>
GRD	<i>Ground Range Detected</i>
InSAR	<i>Interferometric Synthetic Aperture Radar</i>
IPCC	<i>Intergovernmental Panel on Climate Change</i>
ITACyL	<i>Instituto Tecnológico Agrario de Castilla y León</i>
IW	<i>Interferometric Wide Swath</i>
JAXA	<i>Japan Aerospace Exploration Agency</i>
JERS	<i>Japanese Earth Resources Satellite</i>
KELM	<i>Kernel-based Extreme Learning Algorithm</i>
LAI	<i>Leaf Area Index</i>
LoS	<i>Line of Sight</i>
LUT	<i>Look-Up-Table</i>

LU/LC	Mapa de uso/cobertura de suelos
MDA	<i>MacDonald, Dettwiler and Associates Ltd</i>
MDT	Modelo Digital del Terreno
NDVI	<i>Normalized Difference Vegetation Index</i>
NISAR	<i>Synthetic Aperture Radar NASA-ISRO</i>
NN	<i>Neural Networks</i>
OA	<i>Overall Accuracy</i>
PA	<i>Producer's Accuracy</i>
PALSAR	<i>Phased Array type L-band Synthetic Aperture Radar</i>
PNOA	Plan Nacional de Ortofotografía Aérea
PolInSAR	<i>Polarimetric SAR Interferometry</i>
PolSAR	<i>Polarimetric Synthetic Aperture Radar</i>
PolSARpro	<i>Polarimetric SAR data Processing and Education Toolbox</i>
PPD	<i>Polarization Phase Difference</i>
PWC	<i>Percentage Water Content</i>
RAR	<i>Real Aperture Radar</i>
RCM	<i>RADARSAT Constellation Mission</i>
REMEDHUS	Red de Estaciones de Medición de la Humedad del Suelo
RF	<i>Random Forest</i>
RISAT	<i>Radar Imaging Satellite</i>
SAOCOM	Satélite Argentino de Observación con Microondas
SAR	<i>Synthetic Aperture Radar</i>
SIOSE	Sistema de Información de Ocupación del Suelo en España
SLAR	<i>Side-Looking Airborne Radar</i>
SLC	<i>Single Look Complex</i>
SM	<i>Soil Moisture</i>
SM_Sentinel	<i>Stripmap</i>
SNAP	<i>Sentinel Application Platform</i>
SRTM	<i>Shuttle Radar Topographic Mission</i>
SVM	<i>Support Vector Machine</i>
TanDEM-X	<i>TerraSAR-X add-on for Digital Elevation Measurement</i>
UA	<i>User's Accuracy</i>
UNEP	<i>United Nations Environment Programme</i>
UNFCCC	<i>United Nations Framework Convention on Climate Change</i>
UTC	<i>Coordinated Universal Time</i>
VWC	<i>Vegetation Water Content</i>
WV	<i>Wave</i>

## Lista de Figuras

Figura 2.1. Geometría del sistema de imágenes SAR. Fuente: Adaptado de “SAR Imaging” ( <a href="https://eo-college.org/resource/sar-imaging/">https://eo-college.org/resource/sar-imaging/</a> ) .....	38
Figura 2.2. Convención FSA. Fuente: Lopez-Sanchez (1999).....	41
Figura 2.3. Convención BSA. Fuente: Lopez-Sanchez (1999).....	43
Figura 3.1. Mapa de altitud. Fuente: Elaboración propia a partir del Modelo Digital del Terreno (MDT) del ITACyL (Instituto Tecnológico Agrario de Castilla y León), procedente del Plan Nacional de Ortofotografía Aérea (PNOA).....	64
Figura 3.2. Mapa de periodos geológicos. Fuente: Elaboración propia a partir del Mapa Geológico de Castilla y León (1:100.000).....	64
Figura 3.3. Mapa de litología de la cuenca del Duero. Fuente: Elaboración propia a partir de la capa de litología del Mapa Geológico de Castilla y León (1:100.000) .....	65
Figura 3.4. Leyenda del mapa de litología de la cuenca del Duero. Fuente: Elaboración propia a partir de la capa de litología del Mapa Geológico de Castilla y León (1:100.000).....	65
Figura 3.5. Mapa de temperaturas medias anuales de la cuenca del Duero (periodo 1981-2010). Fuente: Elaboración propia a partir de los datos del Atlas Agroclimático de Castilla y León (Nafría et al., 2013).....	66
Figura 3.6. Mapa de precipitaciones medias anuales de la cuenca del Duero (periodo 1981-2010). Fuente: Elaboración propia a partir de los datos del Atlas Agroclimático de Castilla y León (Nafría et al., 2013).....	67
Figura 3.7. Mapa del índice de aridez (clasificación UNEP-FAO ( <i>United Nations Environment Programme – Food and Agriculture Organization</i> )). Fuente: Elaboración propia a partir de los datos del Atlas Agroclimático de Castilla y León (Nafría et al., 2013) .....	68
Figura 3.8. Mapa de ríos de la cuenca del Duero. Fuente: Elaboración propia a partir de los datos de la Confederación Hidrográfica del Duero (CHD) ( <a href="https://www.chduero.es/">https://www.chduero.es/</a> ) .....	69
Figura 3.9. Mapa de suelos de Castilla y León. Fuente: Elaboración propia a partir de los datos del Atlas Agroclimático de Castilla y León (Nafría et al., 2013) .....	71
Figura 3.10. Mapa de coberturas de los suelos de Castilla y León, interpretación simplificada del Sistema de Información de Ocupación del Suelo en España (SIOSE). Fuente: Elaboración propia a partir de los datos del Atlas Agroclimático de Castilla y León (Nafría et al., 2013) .....	71
Figura 4.1. Ubicación de las parcelas de campo y vista general de los diferentes tipos de vegetación. Fuente: Valcarce-Diñeiro et al. (2018) .....	76
Figura 4.2. Escaneo de muestras para estimar el LAI a partir del software ImageJ .....	77
Figura 4.3. Marco de medición empleado para la extracción de las muestras.....	78

Figura 4.4. Izquierda: Fotografía digital tomada en campo. Derecha: Clasificación supervisada a partir de las fotografías digitales .....	79
Figura 4.5. Parcelas seleccionadas, indicando el mapa de usos/coberturas del suelo (LU/LC). Fuente: Valcarce-Diñeiro et al. (2019) .....	81
Figura 4.6. Diagrama de flujo del procesamiento SAR. Fuente: Elaboración propia .....	84
Figura 4.7. Cadena de procesamiento de las imágenes Sentinel-1. Fuente: Elaboración propia .....	85
Figura 4.8. Árbol de decisión. A, B y C representan diferentes atributos por separado en un conjunto de datos. Cada rama a1, a2, b1, b2, c1, c2 representa el valor del atributo dividido. Los nodos terminales (hojas) 1, 2, 3 y 4 representan la clase. Fuente: Elaboración propia .....	92
Figura 5.1. Evolución de la altura (a), biomasa (b), FVC (c), PWC (d), LAI (e), precipitación diaria y contenido de humedad (SM) (f) para las siete parcelas agrícolas. Fuente: Valcarce-Diñeiro et al. (2018).....	100
Figura 5.2. Evaluación temporal del coeficiente de retrodispersión (HH) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018).....	101
Figura 5.3. Evaluación temporal del coeficiente de retrodispersión (VV) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018).....	102
Figura 5.4. Evaluación temporal del coeficiente de retrodispersión (HV) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018).....	103
Figura 5.5. Evaluación temporal del ratio de retrodispersión (HH/VV) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018).....	104
Figura 5.6. Evaluación temporal del ratio de retrodispersión (HV/VV) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018).....	105
Figura 5.7. Evaluación temporal de la correlación entre HH y VV ( $\gamma_{HHVV}$ ) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018) .....	106

Figura 5.8. Evaluación temporal de la diferencia de fase de polarización (PPD) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Elaboración propia.....107

Figura 5.9. Evaluación temporal de la entropía (H) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Elaboración propia.....108

Figura 5.10. Evaluación temporal del ángulo dominante alfa ( $\alpha_1$ ) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018).....109

Figura 5.11. Evaluación temporal de la coherencia entre el primer y segundo canal de Pauli ( $\gamma_{P1P2}$ ) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Elaboración propia .....110

Figura 5.12. Tres subconjuntos del mapa de referencia (arriba, izquierda) y los mapas resultantes después de la clasificación de los escenarios A y D (derecha). Se detectan algunas pequeñas diferencias en el área delimitada. Fuente: Valcarce-Diñeiro et al. (2019).....121

Figura 5.13. Contribución de los atributos en los escenarios A, B y C. Fuente: Valcarce-Diñeiro et al. (2019) .....130

Figura 5.14. Contribución de los atributos en el escenario D. Fuente: Valcarce-Diñeiro et al. (2019)131

Figura 5.15. Contribución de los atributos en los escenarios E, F and G. Fuente: Valcarce-Diñeiro et al. (2019) .....132

Figura 5.16. Atributos principales (20) utilizados para el análisis por pares. Fuente: Valcarce-Diñeiro et al. (2019).....133





## Lista de Tablas

Tabla 4.1. Características de las 7 estaciones de la red REMEDHUS empleadas en el estudio.....	76
Tabla 4.2. Etapas fenológicas.....	77
Tabla 4.3. Descripción general de la verdad-terreno para la clasificación .....	80
Tabla 4.4. Lista de imágenes RADARSAT-2 y Sentinel-1A IW GRD .....	82
Tabla 4.5. Características del RADARSAT-2 y Sentinel-1.....	83
Tabla 4.6. Lista de observables polarimétricos .....	88
Tabla 4.7. Descripción de los siete escenarios explorados con imágenes RADARSAT-2 y Sentinel-195	
Tabla 5.1. Descripción general de los parámetros SAR y variables biofísicas altamente correlacionadas teniendo en cuenta el ángulo de incidencia para todos los cultivos analizados en este estudio. Se utiliza una marca de verificación para mostrar las mejores combinaciones.....	113
Tabla 5.2. Correlación (r Pearson) entre las mediciones de campo y el canal copolar HH, para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas .....	115
Tabla 5.3. Correlación (r Pearson) entre las mediciones de campo y el canal copolar VV, para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas .....	115
Tabla 5.4. Correlación (r Pearson) entre las mediciones de campo y el canal de polarización cruzada HV, para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas .....	116
Tabla 5.5. Correlación (r Pearson) entre las mediciones de campo y el ratio copolar HH/VV, para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas .....	116
Tabla 5.6. Correlación (r Pearson) entre las mediciones de campo y el ratio de polarización cruzada HV/VV, para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas .....	117
Tabla 5.7. Correlación (r Pearson) entre las mediciones de campo y la correlación normalizada (coherencia) entre HH y VV ( $\gamma_{HHVV}$ ), para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas.....	117
Tabla 5.8. Correlación (r Pearson) entre las mediciones de campo y el ángulo dominante alfa ( $\alpha_1$ ), para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas .....	118

Tabla 5.9. Correlación (r Pearson) entre las mediciones de campo y la entropía (H), para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas .....	118
Tabla 5.10. Correlación (r Pearson) entre las mediciones de campo y los dos primeros canales de Pauli ( $\gamma_{P1P2}$ ), para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas .....	119
Tabla 5.11. Correlación (r Pearson) entre las mediciones de campo y la diferencia de fase de polarización (PPD), para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas .....	119
Tabla 5.12. Precisión general y coeficiente <i>kappa</i> .....	121
Tabla 5.13. Muestreo aleatorio: precisión general y coeficiente <i>kappa</i> .....	122
Tabla 5.14. Precisiones del productor (PA) y del usuario (UA) de los tipos de cobertura individuales para los datos del RADARSAT-2 y Sentinel-1 .....	125
Tabla 5.15. Matriz de confusión del escenario A.....	126
Tabla 5.16. Matriz de confusión del escenario B.....	126
Tabla 5.17. Matriz de confusión del escenario C .....	127
Tabla 5.18. Matriz de confusión del escenario D .....	127
Tabla 5.19. Matriz de confusión del escenario E.....	128
Tabla 5.20. Matriz de confusión del escenario F.....	128
Tabla 5.21. Matriz de confusión del escenario G .....	129
Tabla 5.22. Precisiones del productor (PA) y del usuario (UA) de los tipos de cobertura individuales utilizando solo observables seleccionados (escenario H) y todo el conjunto de datos (escenario D) .....	134
Tabla 5.23. Precisiones del productor (PA) y del usuario (UA) de cebada y trigo utilizando todo el conjunto de datos (escenario D), solo observables seleccionados (escenario I) y observables y fechas seleccionados (escenario J) .....	135

CAPÍTULO 1:  
INTRODUCCIÓN



# Capítulo 1: Introducción

## 1.1. Motivación

El desarrollo industrial y el rápido crecimiento de la población mundial, junto con la importancia económica y social del sector agrícola y la incertidumbre en los cambios de producción causados por el cambio climático, hacen necesario el desarrollo de procedimientos y técnicas para el control y gestión eficiente de los recursos naturales de la Tierra.

El monitoreo de la cubierta vegetal es especialmente interesante para la comunidad científica en las actuales condiciones de cambio climático, ya que tanto bosques como cultivos agrícolas se están viendo afectados por los acelerados procesos de calentamiento climático, además de por causas derivadas de la creciente necesidad de alimentos. La biomasa forestal es uno de los principales indicadores de dichos cambios debido a su relevancia en el ciclo del carbón, mientras que el monitoreo de cultivos agrícolas resulta relevante por su impacto social y económico.

En este contexto, la tesis ha sido motivada por la posibilidad de encontrar nuevas formas de explotar eficazmente la información polarimétrica ofrecida por los sensores SAR (*Synthetic Aperture Radar*) en la monitorización y clasificación de cubiertas vegetales, en un intento de explorar nuevas capacidades de estos sensores.

Los sistemas/sensores de teledetección se pueden agrupar en dos tipos dependiendo de la fuente de iluminación: 1) pasiva, cuando la fuente principal de energía proviene del exterior (por ejemplo, el Sol) y 2) activa, cuando usa la energía que proviene de su propio sistema de iluminación. Un ejemplo de detección pasiva son los sensores ópticos, que solo pueden capturar datos durante las horas del día y son muy sensibles a la cobertura nubosa. El radar es un ejemplo de detección activa: el sensor transmite una señal de microondas hacia el objeto, detecta y mide la parte retrodispersada de la señal. Los sensores activos de microondas penetran en la estructura de la vegetación, se pueden usar en cualquier momento (de día o de noche), en casi todas las condiciones climáticas y tienen una alta sensibilidad a los objetivos característicos de los parámetros (por ejemplo, rugosidad, contenido de agua, etc.) que no están presentes en sistemas ópticos de teledetección, haciendo que los sensores activos de microondas sean una herramienta fiable para el monitoreo de la cubierta vegetal.

El uso de los sistemas/sensores de teledetección en el contexto de las aplicaciones agrícolas está muy relacionado con el factor tiempo, ya que los cultivos tienen un calendario fenológico que es crítico para las observaciones. La identificación precisa de los cultivos agrícolas depende de la disponibilidad de imágenes adquiridas dentro de una ventana de tiempo específica a lo largo de la temporada de crecimiento del cultivo, cuando existen marcadas diferencias en la apariencia de determinados tipos de cultivos en las imágenes proporcionadas por los sensores de teledetección. Igualmente, existe la necesidad de obtener imágenes en momentos claves como por ejemplo para

predecir el rendimiento de ciertos cultivos. A pesar del progreso que se está llevando a cabo en aplicaciones operativas, la experiencia muestra que los sistemas/sensores de teledetección pasivos no siempre pueden proporcionar la información deseada debido a las restricciones relacionadas con la cobertura nubosa y los tiempos de revisita.

Según una definición general, el Radar de Apertura Sintética (SAR) es un método de imágenes de microondas empleado para cartografiar las propiedades de dispersión de la superficie de la Tierra. La principal diferencia entre el SAR y el Radar de Apertura Real (RAR, *Real Aperture Radar*) es que el SAR tiene una mayor resolución, lograda mediante la explotación de los cambios Doppler de los ecos electromagnéticos recibidos, como descubrió Wiley en 1951. La tecnología SAR se basa en la iluminación activa de partes de la Tierra y en la grabación coherente del campo disperso. Desde la década de los 80 se han venido desarrollando y lanzando una serie de sensores SAR espaciales con diferentes frecuencias y polarizaciones. Lanzado en 1978 por la NASA/JPL, Seasat (banda L, HH) fue la primera misión de observación de la Tierra, que tenía a bordo el primer radar de apertura sintética (SAR) en el espacio. El éxito de Seasat condujo en los años 90 el lanzamiento de diferentes misiones (a diferentes frecuencias y polarizaciones) como ERS-1/2 (*European Remote Sensing*, banda C, VV), JERS-1 (*Japanese Earth Resources Satellite*, banda L, HH) y RADARSAT-1 (banda C, HH), operados por la ESA (*European Space Agency*), JAXA (*Japan Aerospace Exploration Agency*) y CSA (*Canadian Space Agency*) respectivamente. En 2002, se lanzó ENVISAT/ASAR (*Environmental Satellite / Advanced Synthetic Aperture Radar*, banda C, dual), y se convirtió en el primer sensor SAR que utiliza la tecnología de antena con módulos de transmisión/recepción. Desde entonces el desarrollo de sensores SAR ha aumentado considerablemente. Los sensores basados en la banda C están a bordo de satélites como RISAT-1 (*Radar Imaging Satellite*, quad), Sentinel-1 (dual) y RCM (RADARSAT *Constellation Mission*, quad). Otros sensores funcionan en la banda L, como ALOS/PALSAR-1 y -2 (*Advanced Land Observing Satellite / Phased Array type L-band Synthetic Aperture Radar*), SAOCOM (Satélite Argentino de Observación con Microondas, quad); mientras que los sensores de banda X están a bordo de TerraSAR-X (quad), TanDEM-X (*TerraSAR-X add-on for Digital Elevation Measurement*, quad), COSMO-SkyMed (*Constellation of Small Satellites for Mediterranean basin Observation*, dual) y PAZ SAR (quad). Además, para 2021 y 2023 está programado el lanzamiento de NISAR (*Synthetic Aperture Radar NASA-ISRO*, banda L, quad), BIOMASS (banda P, quad) y TanDEM-L (banda L, quad).

Dependiendo de la configuración del sistema, los sensores SAR pueden adquirir datos en diferentes modos, por ejemplo, utilizando la distancia de tránsito completa para obtener una imagen de una larga franja de terreno, iluminando una franja de terreno en cualquier ángulo con respecto al movimiento de la ruta, o imágenes de una escena con una resolución más fina y en múltiples ángulos de visión. La adquisición de datos en diferentes modos ha establecido técnicas de procesamiento como la polarimetría (PolSAR, *Polarimetric Synthetic Aperture Radar*), interferometría (InSAR, *Interferometric Synthetic Aperture Radar*) e interferometría diferencial (DInSAR, *Differential Interferometric Synthetic Aperture Radar*), así como técnicas emergentes (por ejemplo, interferometría polarimétrica (PolInSAR, *Polarimetric SAR Interferometry*), tomografía). La polarimetría SAR es la técnica que se tratará en esta tesis.

La polarimetría SAR es una técnica ampliamente utilizada para la extracción de información física, cualitativa y cuantitativa, y que cuenta con una larga trayectoria en el ámbito de la clasificación y segmentación de imágenes, así como en la inversión de parámetros físicos (estimación de alturas, biomasa, humedad del suelo, etc.). Está basada en la medición y exploración de las propiedades polarimétricas de dispersores artificiales y naturales.

El uso de la polarimetría SAR en aplicaciones agrícolas se basa en: 1) la conocida sensibilidad de las microondas a la estructura del cultivo (tamaño, forma y orientación de las hojas, tallos, etc.); 2) las propiedades dieléctricas del dosel (relacionadas con el contenido de agua); y 3) las propiedades físicas del suelo subyacente (rugosidad y humedad). La estructura del cultivo y el contenido de agua en la planta varían en función del tipo de cultivo, la etapa de crecimiento y las condiciones agronómicas. Por lo tanto, diferentes tipos de cultivos, o el mismo tipo en diferentes etapas de crecimiento, producen diferentes firmas polarimétricas que pueden emplearse para establecer técnicas de seguimiento/monitoreo o algoritmos de clasificación.

## 1.2. Objetivos

Una vez planteada la idea inicial de la tesis, se definen sus objetivos:

1. Ampliar el conocimiento de los observables obtenidos a partir de la polarimetría SAR (más allá de los simples coeficientes de retrodispersión) para el seguimiento/monitoreo de cultivos.
  - Con el fin de ampliar este conocimiento se explota un conjunto de datos más completo al usualmente empleado en la literatura especializada. Se analizan observables SAR extraídos de una serie temporal de veinte imágenes RADARSAT-2 adquiridas con tres ángulos de incidencia diferentes y que cubren la temporada de crecimiento de los cultivos agrícolas. Aprovechar al máximo la serie temporal de los datos SAR ayuda a comprender cómo los cultivos interactúan con la señal y también a describir las propiedades de dispersión para cada cultivo durante la temporada de crecimiento y de acuerdo con los diferentes ángulos de incidencia.
2. Investigar el efecto del ángulo de incidencia en la relación entre los parámetros polarimétricos y diferentes variables biofísicas.
  - Es importante tener en cuenta que la influencia del ángulo de incidencia es bien conocida en la teledetección SAR, ya que la geometría de observación influye fuertemente en las propiedades de la imagen de un sistema radar. En el caso de cultivos agrícolas, el ángulo de incidencia afecta a la cantidad

relativa de las contribuciones de la vegetación y del suelo subyacente. En general, en datos SAR en la banda C, los ángulos de incidencia pronunciados son más sensibles a las condiciones del suelo y menos a las características de las plantas, mientras que los ángulos menos pronunciados aumentan el efecto de la vegetación sobre la respuesta total del radar, lo que reduce el efecto de las características del suelo. Este efecto fue estudiado en el pasado principalmente con sistemas basados en tierra, pero en la actualidad solo existen algunos ejemplos con datos satelitales. Por lo tanto, la investigación de este efecto podría ayudar a esclarecer la elección del ángulo de incidencia de las imágenes para el monitoreo de cultivos, así como a determinar qué parámetros están menos afectados por los cambios en el ángulo de incidencia. Se permitiría así la combinación de diferentes haces para reducir el intervalo de tiempo entre imágenes, que es clave para aplicaciones de seguimiento.

3. Estudiar la viabilidad de los observables obtenidos de las imágenes SAR para clasificar y distinguir cultivos agrícolas.
  - Es sabido que dos cultivos pueden tener una retrodispersión muy similar. Sin embargo, a medida que cambia la estructura del cultivo (especialmente durante el desarrollo de semillas y frutas), la retrodispersión cambia. Al haber un cambio en la retrodispersión a lo largo del tiempo, la clasificación aprovecha la variación temporal de la retrodispersión para distinguir un cultivo de otro.

### **1.3. Organización**

El material de la tesis está organizado como sigue. En el capítulo 2 se presenta la teoría sobre el radar de apertura sintética, polarimetría radar y un repaso bibliográfico acerca del empleo de los sensores activos de microondas en agricultura. La teoría polarimétrica aquí presentada ha sido ya publicada en otras referencias, pero aquellos aspectos directamente relacionados con la tesis se exponen en este capítulo.

El capítulo 3 muestra el área de estudio que se ha empleado para el desarrollo de la tesis. Los dos capítulos siguientes forman el núcleo de esta tesis. En el capítulo 4 se describen los materiales y métodos empleados. Mientras que en el capítulo 5 se muestran los resultados y discusión de las principales investigaciones llevadas a cabo. En él se muestra un análisis de la evolución temporal de las variables biofísicas, la evaluación de los observables polarimétricos y el efecto del ángulo de incidencia. Se analiza la correlación entre conjuntos de datos para identificar los mejores ángulos de incidencia, así también como los observables SAR que están menos afectados por los cambios en el ángulo de incidencia y, por lo tanto, que se pueden combinar en el mismo conjunto de datos para



aumentar la frecuencia de actualización de la información. También se proporcionan los resultados y discusión del análisis multi-temporal a partir de datos SAR *dual* - y *quad* polarimétricos para la clasificación de cultivos. Una parte importante de esta investigación también incluida en este capítulo fue la evaluación de los atributos empleados en el análisis y su importancia a la hora de diferenciar cultivos agrícolas y otras cubiertas.

Las conclusiones de la tesis aparecen en el capítulo 6. Para terminar, en el capítulo 7 se sugieren varias líneas futuras de investigación como continuación al trabajo presentado aquí. También se ha incluido una lista con las publicaciones en revistas y congresos internacionales que se han ido generando durante el desarrollo de la presente tesis. En los anexos A y B se presentan los artículos publicados en revistas internacionales.



CAPÍTULO 2:  
ANTECEDENTES



## Capítulo 2: Antecedentes

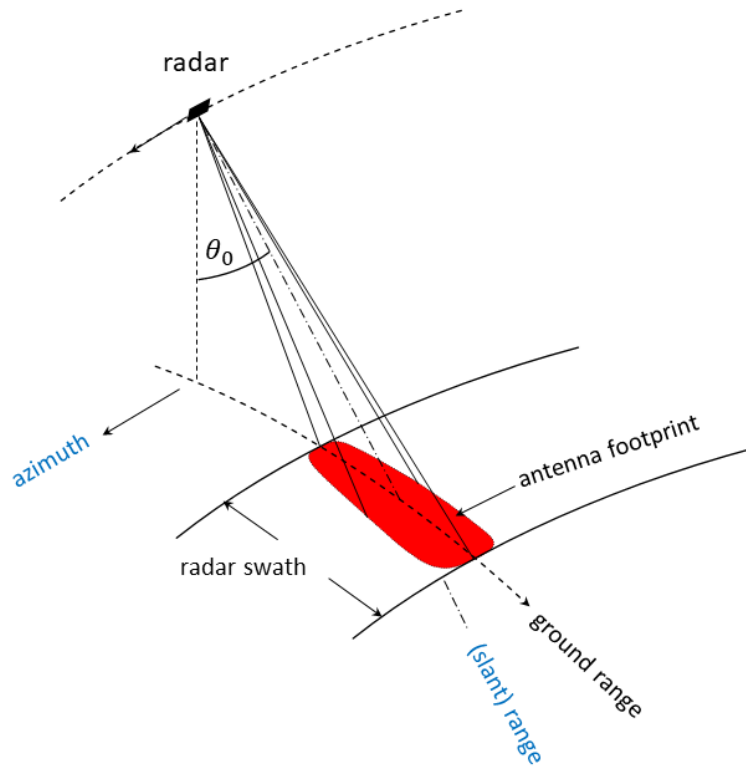
### 2.1. Fundamentos SAR

A mediados del siglo pasado, Carl Wiley (1951, USA) fue el primero en observar que la resolución azimutal de un sistema SLAR (*Side-Looking Airborne Radar*) puede mejorarse significativamente mediante el uso de los cambios Doppler de las señales de retorno. Esta observación es el antecedente de la tecnología SAR actual. Desde entonces numerosos sistemas SAR aerotransportados y espaciales han funcionado con éxito (Cumming and Wong, 2005).

La intención de esta sección es proporcionar una visión general de los conceptos básicos de un sistema SAR. Además de lo expuesto en este capítulo, existe mucha literatura científica que recoge descripciones exhaustivas y detalladas sobre estos sistemas (Curlander and McDonough, 1991; Elachi, 1988; Woodhouse, 2006).

#### 2.1.1. Geometría de la imagen

El radar de apertura sintética, o SAR, es un sistema de radar coherente (preserva información de fase y amplitud) que genera imágenes de teledetección de alta resolución espacial. La geometría del sistema se representa en la Figura 2.1. La antena normalmente está orientada perpendicularmente a la dirección de vuelo (de forma lateral), denominada azimut ( $y$ ) (*azimuth*). El haz de la antena se dirige inclinado hacia el suelo con un ángulo de incidencia  $\theta_0$ . El eje radial o la línea de visión del radar (LoS, *Line of Sight*) se conoce como rango inclinado ( $r$ ) (*slant-range*). El área cubierta por el haz de la antena en las direcciones del rango del terreno ( $x$ ) (*ground-range*) y azimut ( $y$ ) se denomina huella de la antena (*antenna footprint*). Finalmente, el área escaneada por el haz de la antena es la franja del radar (*radar swath*).



**Figura 2.1.** Geometría del sistema de imágenes SAR. Fuente: Adaptado de “SAR Imaging” (<https://eo-college.org/resource/sar-imaging/>).

### 2.1.2. Resolución de la imagen

Uno de los criterios de calidad más importantes de un sistema de imágenes SAR es su resolución espacial. La resolución de una imagen se define en términos de resolución del rango,  $\delta_r$ , y resolución del azimut,  $\delta_x$ , de acuerdo con las dos coordenadas de la imagen.

El procesamiento del rango se realiza correlacionando los ecos devueltos, que son versiones atenuadas y retardadas de la señal transmitida, con una réplica de la señal original. Esta técnica se denomina filtrado combinado (*matched filtering*) y proporciona una resolución de rango en función del ancho de banda de la señal transmitida  $W$  dada por Skolnik (1981) (Ecuación 2.1).

$$\delta_r = \frac{c\tau}{2} = \frac{c}{2W} \quad (2.1)$$

donde  $c$  es la velocidad de propagación y  $\tau = 1/W$  es la longitud del pulso transmitido. Esta relación establece que cuanto más corto es el pulso, mayor es la resolución del rango. En la práctica, aparecen algunas limitaciones de hardware para producir pulsos tan cortos manteniendo también una alta potencia de transmisión. Una manera de superar esta limitación es utilizar pulsos *chirp*. Esto

consiste en generar pulsos de frecuencia modulada que pueden ser más largos en el tiempo, pero que contienen el ancho de banda requerido.

La resolución azimutal está determinada solo por el tamaño físico de la antena del sistema radar y es independiente del rango y la longitud de onda. La idea básica es simular una matriz en fases colocando la antena en diferentes puntos a lo largo de la apertura sintética. El haz de la antena ilumina el objetivo varias veces a medida que la plataforma vuela a lo largo de su camino. La combinación de todos los ecos recibidos en cada posición de la antena produce una resolución azimutal equivalente del orden del tamaño de la antena. La resolución teórica máxima del azimut para un sistema SAR viene dada por la Ecuación 2.2.

$$\delta_x = \frac{D}{2} \quad (2.2)$$

donde  $D$  es el tamaño de la antena.

## 2.2. Polarimetría radar

La polarimetría describe una técnica que incluye la medición, el procesamiento y la interpretación del estado de polarización de una onda electromagnética. La información de polarización de una onda retrodispersada de una superficie natural puede relacionarse con características geométricas como la forma, la rugosidad y la orientación, así también como con sus propiedades geofísicas tales como la humedad y la conductividad de los suelos.

El primer trabajo en polarimetría radar se atribuye a Sinclair (1950) quien introdujo el concepto de matriz de dispersión. Se sabe que la información de un radar totalmente polarimétrico se puede organizar en forma de matriz. La matriz de dispersión es una matriz compleja de  $2 \times 2$  cuyas entradas son las reflectividades medidas para las cuatro combinaciones de polarizaciones transmitidas-recibidas en una base ortogonal. Esta matriz es el punto clave para todos los conceptos relacionados con la polarimetría radar que se definirán a continuación.

### 2.2.1. Ecuación radar

La forma fundamental para describir la interacción de una onda electromagnética con un objetivo dado es a través de la ecuación de radar (Lee and Pottier, 2009). Esta ecuación describe la relación entre la potencia que el objetivo intercepta de la onda electromagnética incidente  $E^i$  y la potencia irradiada por el mismo objetivo en forma de onda dispersa  $E^s$ . La ecuación radar se presenta mediante la Ecuación 2.3.

$$P_R = \frac{P_T G_T(\theta, \phi)}{4\pi r_T^2} \sigma \frac{A_{ER}(\theta, \phi)}{4\pi r_R^2} \quad (2.3)$$

donde  $P_R$  representa la potencia detectada;  $P_T$  la potencia transmitida;  $G_T$  la ganancia de la antena transmisora;  $A_{ER}$  la apertura efectiva de la antena receptora;  $r_T$  la distancia entre el sistema transmisor y el objetivo;  $r_R$  la distancia entre el objetivo y el receptor;  $\theta, \phi$  son los ángulos esféricos que definen la dirección de observación y se corresponden con los ángulos azimutal y de elevación.

La sección transversal del radar o *radar cross section*,  $\sigma$ , se define como la sección transversal de un dispersor isotrópico idealizado que genera la misma densidad de potencia dispersa que el objeto en la dirección observada (Lee and Pottier, 2009). Depende de la geometría (orientación, forma, tamaño) y propiedades (contenido dieléctrico, densidad) del dispersor, así como del sistema y los parámetros de adquisición (longitud de onda, incidencia local). La sección transversal del radar se expresa mediante la Ecuación 2.4.

$$\sigma = 4\pi r^2 \frac{|E^s|^2}{|E^i|^2} \quad (2.4)$$

El coeficiente de dispersión o *sigma nought*,  $\sigma^0$  (Ecuación 2.5), también conocido como la sección transversal promedio del radar, representa la relación entre la densidad de potencia dispersa promediada estadísticamente y la densidad de potencia incidente media sobre la superficie de la esfera de radio  $r$ .  $A_0$  es el área iluminada.

$$\sigma^0 = \frac{\langle \sigma \rangle}{A_0} = \frac{4\pi r^2 \langle |E^s|^2 \rangle}{A_0 |E^i|^2} \quad (2.5)$$

El coeficiente de dispersión es un parámetro adimensional que se emplea para caracterizar la radiación dispersa que genera el radar.

## 2.2.2. Matriz de dispersión

Cuando se trata de la dispersión producida por un objeto de interés, hay que relacionar las características de polarización de dos ondas: una onda generada por el radar para iluminar el objetivo (campo incidente) y una onda dispersada por el objetivo y luego recibida por la antena receptora del radar (campo disperso). Los parámetros de polarización de ambas ondas se pueden organizar como un vector, lo que permite la construcción de matrices para formular una relación entre la polarización del campo incidente y disperso.

Para caracterizar la respuesta polarimétrica de un solo objetivo, es necesario relacionar el campo incidente en el objetivo con el campo disperso por el mismo elemento.



La relación entre el campo eléctrico incidente ( $E^i$ ) y el campo eléctrico disperso ( $E^s$ ) viene dada por la Ecuación 2.6.

$$E^s = \frac{e^{-jkr}}{r} S E^i \quad (2.6)$$

donde  $S$  es la matriz de dispersión que describe el comportamiento de dispersión de un solo objetivo para una frecuencia y dirección determinadas,  $r$  es la distancia entre el dispersor y la antena, y  $k$  es el número de onda del campo de iluminación. El término exponencial explica el retraso de la onda. El coeficiente  $r^{-1}$  representa la naturaleza esférica de la onda y cuantifica la atenuación en el camino de propagación. De acuerdo con un sistema de coordenadas dado, que es el mismo para las antenas de transmisión y recepción, y utilizando una base lineal ortogonal ( $\hat{h}, \hat{v}$ ), la Ecuación 2.6 se puede expresar de la siguiente manera:

$$\begin{bmatrix} E_v^s \\ E_h^s \end{bmatrix} = \frac{e^{-jkr}}{r} \begin{bmatrix} S_{vv} & S_{vh} \\ S_{hv} & S_{hh} \end{bmatrix} \begin{bmatrix} E_v^i \\ E_h^i \end{bmatrix} \quad (2.7)$$

### 2.2.2.1. Convenciones de los sistemas de coordenadas

En las mediciones de radar, existen dos casos generales que dependen de la ubicación de las antenas de transmisión y recepción. Un radar monoestático transmite y recibe ecos con las dos antenas ubicadas en la misma posición. De hecho, se puede usar la misma antena para transmitir y recibir la señal. Por otro lado, un radar biestático utiliza antenas ubicadas en diferentes lugares.




Figura 2.2. Convención FSA. Fuente: Lopez-Sanchez (1999).

Independientemente del caso monoestático o biestático, la descripción de dispersión de los objetos generalmente se representa en dos sistemas de coordenadas: la convención de alineación de dispersión hacia delante (FSA, *Forward Scattering Alignment*) (Figura 2.2) y la convención de alineación de dispersión hacia atrás (BSA, *Backward Scattering Alignment*) (Figura 2.3). Todos los sistemas de coordenadas se definen en términos de un sistema de coordenadas global centrado dentro del disperso (Lee and Pottier, 2009).

La convención FSA se usa comúnmente en problemas con geometrías biestáticas o con dispersión múltiple. La razón es que las direcciones de los vectores unitarios vertical y horizontal siempre se definen con respecto a la dirección de propagación de la onda, es por ello que esta convención también se conoce como coordenadas de onda. Los sistemas de coordenadas  $(\hat{k}, \hat{v}, \hat{h})$  coinciden con el sistema estándar de coordenadas esféricas  $(\hat{r}, \hat{\theta}, \hat{\phi})$ , como se muestra en la Figura 2.2.

Por otro lado, la convención BSA está relacionada con las antenas y se emplea con frecuencia para configuraciones monoestáticas, ya que en este caso se usa el mismo sistema de coordenadas para describir tanto la polarización de las ondas incidentes como las dispersas. La convención BSA también se conoce como coordenadas de la antena, y es la convención preferida en problemas de retrodispersión.

Los campos eléctricos incidentes para ambas convenciones son idénticos (Ecuación 2.8).

$$E_{FSA}^i = E_{BSA}^i \quad (2.8)$$

Mientras que los campos dispersos están relacionados por medio de la Ecuación 2.9.

$$E_{FSA}^s = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} E_{BSA}^s \quad (2.9)$$

proporcionando la siguiente relación para las matrices de dispersión (Ecuación 2.10).

$$S_{FSA} = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} S_{BSA} \quad (2.10)$$

En el caso de la retrodispersión, la propiedad de reciprocidad para campos electromagnéticos conduce a la siguiente igualdad en la convención BSA (Ecuación 2.11).

$$S_{hv} = S_{vh} \quad (2.11)$$

Sin embargo, la misma propiedad en la convención FSA para problemas de retrodispersión se puede expresar mediante la Ecuación 2.12.

$$S_{hv} = -S_{vh} \quad (2.12)$$

Se adopta la convención BSA para el análisis de los problemas de retrodispersión tratados en esta tesis.




Figura 2.3. Convención BSA. Fuente: Lopez-Sanchez (1999).

### 2.2.2.2. Vector objetivo

Con el objetivo de extraer información física de la matriz de dispersión ( $S$ ) de  $2 \times 2$ , se puede desarrollar un nuevo formalismo, el cual consiste en la construcción del llamado vector objetivo, que es simplemente una vectorización de la matriz de dispersión (Cloude and Pottier, 1996). En forma matemática, se puede escribir formalmente como la Ecuación 2.13.

$$\mathbf{k} = V([S]) = \frac{1}{2} \text{Trace}([S]\Psi) \quad (2.13)$$

donde  $V(\cdot)$  es el operador de vectorización,  $\text{Trace}(\cdot)$  es la suma de los elementos diagonales de una matriz, y  $\Psi$  es un conjunto de matrices de bases complejas de  $2 \times 2$  que se construyen como un conjunto ortonormal bajo un producto interior hermitiano. Aunque en la literatura se pueden encontrar varios conjuntos básicos, a menudo se utilizan dos conjuntos: el conjunto básico Lexicográfico  $\Psi_L$ , y el conjunto básico de Pauli  $\Psi_P$ . La expresión matemática de ambos se puede encontrar en Cloude and Pottier (1996) y Lee and Pottier (2009).

En el caso de mediciones de retrodispersión y un objetivo recíproco (convención BSA), la matriz de dispersión y, por lo tanto, el vector objetivo pueden representarse con solo tres elementos, en la base lexicográfica ( $k_L$ ) (Ecuación 2.14) y en la base de Pauli ( $k_P$ ) (Ecuación 2.15).

$$k_L = [S_{hh} \quad \sqrt{2}S_{hv} \quad S_{vv}]^T \quad (2.14)$$

$$k_P = \frac{1}{\sqrt{2}} [S_{hh} + S_{vv} \quad S_{hh} - S_{vv} \quad 2S_{hv}]^T \quad (2.15)$$

### 2.2.3. Matrices de coherencia y covarianza polarimétricas

A partir de los vectores objetivos, se pueden diferenciar otras matrices que caracterizan la similitud de los canales polarimétricos. Si el vector objetivo se define utilizando la base lexicográfica, se obtiene la matriz de covarianza  $C$ . Por otro lado, el uso del vector objetivo obtenido de la base de Pauli proporciona la matriz de coherencia  $T$ .

En el caso de las mediciones de retrodispersión para un objetivo distribuido recíproco en la convención BSA, que es la más común en polarimetría radar, las matrices de coherencia y covarianza se muestran en las Ecuaciones 2.16 y 2.18.

$$C = \langle k_L \cdot k_L^\dagger \rangle = \begin{bmatrix} \langle |S_{hh}|^2 \rangle & \sqrt{2}\langle S_{hh}S_{hv}^* \rangle & \langle S_{hh}S_{vv}^* \rangle \\ \sqrt{2}\langle S_{hv}S_{hh}^* \rangle & 2\langle |S_{hv}|^2 \rangle & \sqrt{2}\langle S_{hv}S_{vv}^* \rangle \\ \langle S_{vv}S_{hh}^* \rangle & \sqrt{2}\langle S_{vv}S_{hv}^* \rangle & \langle |S_{vv}|^2 \rangle \end{bmatrix} \quad (2.16)$$

$$T = \langle k_P \cdot k_P^\dagger \rangle \quad (2.17)$$

$$T = \frac{1}{2} \begin{bmatrix} \langle |S_{hh} + S_{vv}|^2 \rangle & \langle (S_{hh} + S_{vv})(S_{hh} - S_{vv})^* \rangle & 2\langle (S_{hh} + S_{vv})S_{hv}^* \rangle \\ \langle (S_{hh} - S_{vv})(S_{hh} + S_{vv})^* \rangle & \langle |S_{hh} - S_{vv}|^2 \rangle & 2\langle (S_{hh} - S_{vv})S_{hv}^* \rangle \\ 2\langle S_{hv}(S_{hh} + S_{vv})^* \rangle & 2\langle S_{hv}(S_{hh} - S_{vv})^* \rangle & 4\langle |S_{hv}|^2 \rangle \end{bmatrix} \quad (2.18)$$

En 2.16-2.17, † y \* indican la transposición del conjugado y el conjugado complejo.

## 2.2.4. Parámetros polarimétricos

### 2.2.4.1. Parámetros estimados a partir de la matriz de covarianza

A partir de la matriz  $C$  se extraen los coeficientes de retrodispersión en los canales HH, HV y VV, los ratios de polarización y la coherencia entre los canales copolares HH y VV.

Los coeficientes de retrodispersión en las polarizaciones lineales consisten en los elementos diagonales de la matriz  $C$  (2.16). En cuanto a los ratios de polarización, el ratio copolar se define a partir de la Ecuación 2.19.

$$r_{hh/vv} = \frac{\langle |S_{hh}|^2 \rangle}{\langle |S_{vv}|^2 \rangle} = \frac{C_{11}}{C_{33}} \quad (2.19)$$

mientras que el ratio de polarización cruzada se obtiene de la siguiente manera (Ecuación 2.20).

$$r_{hv/vv} = \frac{\langle |S_{hv}|^2 \rangle}{\langle |S_{vv}|^2 \rangle} = \frac{C_{22}}{C_{33}} \quad (2.20)$$

En cuanto a la correlación normalizada (coherencia) entre los canales copolares HH y VV (Ecuación 2.21).

$$\rho_{hhvv} = |\rho_{hhvv}| e^{j\phi_{hhvv}} = \frac{\langle S_{hh} S_{vv}^* \rangle}{\sqrt{\langle |S_{hh}|^2 \rangle \langle |S_{vv}|^2 \rangle}} = \frac{C_{13}}{\sqrt{C_{11} C_{33}}} \quad (2.21)$$

Donde  $\phi_{hhvv}$  es la diferencia de fase entre los canales copolares HH y VV, o la diferencia de fase copolar (CPD, *Co-polarization Phase Difference*) o la diferencia de fase de polarización (PPD, *Polarization Phase Difference*).  $\rho_{hhvv}$  también se conoce como coherencia copolar, el cual para casos de dispersión de la superficie el valor debe ser muy alto, mientras que se espera que sea bajo cuando hay dispersión de volumen, es decir, cuando la dispersión de la capa de vegetación está presente (Skriver et al., 1999).

La disponibilidad de información de fase permite estimar la diferencia de fase de polarización (PPD o  $\Delta\phi$ ) a partir de la matriz de dispersión o matriz de covarianza a partir de las siguientes relaciones (Woodhouse, 2006) (Ecuaciones 2.22-2.23).

$$S_{hh} S_{vv}^* = A_{hh} A_{vv} \exp(\phi_{hh} - \phi_{vv}) = A_{hh} A_{vv} (\cos \Delta\phi + i \sin \Delta\phi) \quad (2.22)$$

$$\tan \Delta\phi = \frac{\text{Im}(S_{hh}S_{vv}^*)}{\text{Re}(S_{hh}S_{vv}^*)} = \frac{\text{Im}(C_{13})}{\text{Re}(C_{13})} \quad (2.23)$$

donde  $S_{hh}$  y  $S_{vv}$  son los elementos diagonales de  $[S]$ , y  $S_{vv}^*$  indica el complejo conjugado de  $S_{vv}$ . En la Ecuación 2.22,  $A_{hh}$  y  $A_{vv}$  son las amplitudes de HH y VV, y  $\phi_{hh}$  y  $\phi_{vv}$  son sus fases.

El PPD ha sido utilizado para clasificar los mecanismos de dispersión presentes en la escena (Ulaby et al., 1987), por lo que un PPD cercano a  $0^\circ$  se interpreta como dispersión de rebote único y un PPD cercano a  $180^\circ$  se interpreta como dispersión de ‘doble rebote’, que se refiere a la interacción entre dos superficies adyacentes, pero perpendiculares. Los valores de PPD entre estos dos extremos se interpretan como dispersión múltiple si la distribución en el rango del ángulo de fase es aproximadamente uniforme.

### 2.2.4.2. *Parámetros estimados a partir de la matriz de coherencia*

Los parámetros polarimétricos obtenidos de la matriz de coherencia que se emplean en esta tesis se agrupan en dos conjuntos: 1) la coherencia o correlación normalizada entre el primer y el segundo canal de Pauli; y 2) los parámetros extraídos de la descomposición de los *eigenvalue/eigenvector* de la matriz de coherencia  $T$  (Cloude and Pottier, 1996).

Los canales de Pauli consisten en los tres elementos complejos del vector objetivo  $k_p$  (Ecuación 2.15). Para muchas aplicaciones, este es un método mucho más útil, ya que ayuda a enfatizar la diferencia de fase entre los canales HH y VV. Los tres elementos pueden considerarse relacionados con tres mecanismos de dispersión elementales: la dispersión directa o dispersión desde una superficie plana está dominada por el primer elemento ( $S_{hh} + S_{vv}$ ); la dispersión doble o par está dominada por el segundo elemento ( $S_{hh} - S_{vv}$ ); y la dispersión múltiple o de polarización cruzada domina el tercer elemento ( $2S_{hv}$ ).

La coherencia o correlación normalizada entre el primer y segundo canal de Pauli, se muestra en la Ecuación 2.24.

$$\rho_p = |\rho_p|e^{j\phi_p} = \frac{\langle (S_{hh} + S_{vv})(S_{hh} - S_{vv})^* \rangle}{\sqrt{\langle |S_{hh} + S_{vv}|^2 \rangle \langle |S_{hh} - S_{vv}|^2 \rangle}} = \frac{T_{12}}{\sqrt{T_{11}T_{22}}} \quad (2.24)$$

#### 2.2.4.2.1. *Descomposición del valor/vector-propio*

Las técnicas de descomposición del objetivo se encargan de la extracción de información física del objetivo mediante el análisis de las matrices de descriptores de dispersión. El objetivo principal de

los teoremas de descomposición del objetivo es descomponer el descriptor promediado en un conjunto de matrices que representan diferentes mecanismos de dispersión física.

La descomposición basada en vectores propios de la matriz de coherencia  $T$  (Ecuación 2.18) establece que puede escribirse como una suma de matrices ortogonales formadas por los vectores propios y ponderados por los valores propios correspondientes. Esta descomposición de tres componentes obedece a la siguiente relación:

$$\langle T \rangle = \langle k_P \cdot k_P^T \rangle \quad (2.25)$$

$$T = U_3 \Sigma U_3^{-1} \quad (2.26)$$

donde

$$\Sigma = \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix} \quad (2.27)$$

es una matriz diagonal de 3 x 3 con elementos reales no negativos,  $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$ , que son los valores propios de la matriz de coherencia; y

$$U_3 = [e_1 e_2 e_3] = \begin{bmatrix} \cos \alpha_1 & \cos \alpha_2 & \cos \alpha_3 \\ \sin \alpha_1 \cos \beta_1 e^{j\delta_1} & \sin \alpha_2 \cos \beta_2 e^{j\delta_2} & \sin \alpha_3 \cos \beta_3 e^{j\delta_3} \\ \sin \alpha_1 \sin \beta_1 e^{j\gamma_1} & \sin \alpha_2 \sin \beta_2 e^{j\gamma_2} & \sin \alpha_3 \sin \beta_3 e^{j\gamma_3} \end{bmatrix} \quad (2.28)$$

es una matriz de 3 x 3 cuyas columnas son los vectores propios de la matriz de coherencia:  $e_1$ ,  $e_2$  y  $e_3$ .

Por lo tanto, la matriz de coherencia se puede expresar como una combinación lineal de los productos externos de los vectores propios. Los pesos de esta combinación lineal son los valores propios (Ecuación 2.29).

$$T = \sum_{i=1}^3 \lambda_i e_i e_i^{*T} = \lambda_1 (e_1 e_1^{*T}) + \lambda_2 (e_2 e_2^{*T}) + \lambda_3 (e_3 e_3^{*T}) \quad (2.29)$$

En la Ecuación 2.29 se ha demostrado que la matriz de coherencia se puede expresar como una combinación lineal de los productos externos de tres vectores propios. Esto quiere decir que la matriz de coherencia se puede descomponer en una suma de tres mecanismos de dispersión independientes, ya que cada vector propio corresponde a una matriz de dispersión y son estadísticamente independientes de las propiedades de cada descomposición de valor propio.

Estos valores propios se pueden combinar para formar diferentes parámetros polarimétricos. El primero es la entropía (Cloude and Pottier, 1997, 1996) (Ecuación 2.30).

$$H = - \sum_{i=1}^3 p_i \log_3 p_i \quad (2.30)$$

donde

$$p_i = \frac{\lambda_i}{\sum_{l=1}^3 \lambda_l} \quad (2.31)$$

La entropía se define en el rango  $0 \leq H \leq 1$ , y se trata de una medida del grado de aleatoriedad del proceso de dispersión. Cuando  $H = 0$ , la matriz de coherencia es una matriz de rango uno con un solo valor propio distinto de cero, lo que implica que existe un único mecanismo de dispersión. Sin embargo, cuando  $H = 1$  implica que se está produciendo un proceso de dispersión completamente aleatorio, caracterizado por valores propios iguales y distintos de cero, que despolariza completamente la onda incidente (Cloude and Pottier, 1996). Hay que tener en cuenta que la mayoría de las dispersiones naturales se encuentran entre estos dos casos extremos, con valores de entropía intermedios.

Otros parámetros polarimétricos se pueden derivar de los vectores propios de  $T$ . Teniendo en cuenta 2.28, también se puede adoptar una parametrización del vector propio de la siguiente forma (Cloude and Pottier, 1997) (Ecuación 2.32).

$$e_i = [\cos \alpha_i \quad \sin \alpha_i \cos \beta_i e^{j\delta_i} \quad \sin \alpha_i \sin \beta_i e^{j\gamma_i}] \quad (2.32)$$

En principio,  $\delta$  y  $\gamma$  son términos de fase sin una interpretación directa, sin embargo,  $\alpha$  y  $\beta$  tienen un significado físico claro, lo que lleva a una interpretación útil de los mecanismos de dispersión presentes en el objetivo. Mientras que  $\beta$  representa una rotación del objetivo alrededor de la línea de visión, el ángulo  $\alpha$  o el ángulo de dispersión ( $0 \leq \alpha \leq 90^\circ$ ), es el parámetro principal capaz de identificar el tipo de mecanismo de dispersión.

La interpretación de  $\alpha$  de los mecanismos de dispersión es la siguiente: cuando  $\alpha = 0$ , el mecanismo de dispersión puede interpretarse como una dispersión de superficie isotrópica, es decir, un tipo de dispersión de superficie con  $S_{vv} = S_{hh}$ . En el otro extremo, si  $\alpha = 90^\circ$ , el mecanismo de dispersión es una dispersión diédrica. Sin embargo, si  $\alpha = 45^\circ$ , corresponde a una dispersión tipo dipolo.

Además, se puede demostrar que la mejor estimación de  $\alpha$  se obtiene a partir del ángulo promedio (Cloude and Pottier, 1997) (Ecuación 2.33).

$$\bar{\alpha} = p_1 \alpha_1 + p_2 \alpha_2 + p_3 \alpha_3 \quad (2.33)$$



donde los ángulos  $\alpha_i$  se obtienen a partir del primer elemento del vector propio en 2.32.  $\bar{\alpha}$  es una medida del mecanismo de dispersión promedio. Para el desarrollo de esta tesis se evaluó el mecanismo de dispersión dominante  $\alpha_1$ , es decir, el correspondiente al mayor valor propio de  $T$ .

## 2.3. Observación agronómica

### 2.3.1. Seguimiento de cultivos agrícolas

La emisión de gases de efecto invernadero debido a factores antropogénicos ha producido una alteración relativamente rápida de nuestro clima, con el aumento de las temperaturas, cambios en el patrón de precipitaciones y una mayor incidencia de sequías que afecta a los ecosistemas agrícolas, disminuyendo el rendimiento de los cultivos, la productividad y la disponibilidad de alimentos (McKersie, 2015). Por ello, el seguimiento de sus etapas de crecimiento, la discriminación entre varios tipos de cultivos y la estimación del rendimiento son fundamentales. Monitorear los cultivos a lo largo de toda la etapa de crecimiento es esencial dentro del sector agrícola ya que permite detectar anomalías y optimizar los costes y recursos (Mulla, 2013).

Todos los cultivos agrícolas presentan un desarrollo continuo, es decir, desde la siembra hasta la cosecha crecen y evolucionan de acuerdo con sus características biofísicas y las prácticas agrícolas empleadas. La fenología indica la sucesión de etapas durante el ciclo del cultivo, y generalmente se expresa en escalas numéricas (Meier, 2001; Zadoks et al., 1974). La información que proporciona la fenología de los cultivos puede ser empleada por ejemplo para operaciones de fertilización y cosecha y gestión de plagas, así como su inclusión en modelos ayuda a la predicción del rendimiento de cultivos y estimación de áreas cultivadas. Como resultado, la fenología ha sido ampliamente monitoreada a partir de cuatro métodos diferentes: 1) observaciones visuales; 2) métodos de unidad térmica (Boschetti et al., 2009; Leroux et al., 2016); 3) observaciones por satélite (Gao et al., 2017; Liu et al., 2018; Lopez-Sanchez et al., 2012; Nasrallah et al., 2019; Xiaoyang Zhang et al., 2017); y más recientemente a partir de vehículos aéreos no tripulados (UAV) (Ostos-Garrido et al., 2019; Yang et al., 2017).

### 2.3.2. Variables biofísicas de la vegetación

El seguimiento a largo plazo de la arquitectura de la cubierta vegetal es esencial para distinguir anomalías y tendencias en las respuestas de la vegetación al cambio climático y mejorar nuestra comprensión sobre la influencia que tiene el cambio climático sobre la dinámica de la vegetación. Variables biofísicas tales como la biomasa, el índice de área foliar (LAI, *Leaf Area Index*), la altura, la humedad del suelo (SM, *Soil Moisture*), el contenido de agua de la vegetación (VWC, *Vegetation Water*

*Content*) y la fracción de cobertura de la vegetación (FVC, *Fraction of Vegetation Cover*) ayudan al seguimiento y descripción de las cubiertas vegetales.

El índice de área foliar y la humedad del suelo son variables clave para la vegetación y han sido reconocidas por el Sistema de Observación Global del Clima (GCOS, *Global Climate Observing System*) (GCOS, 2011) como Variables Climáticas Esenciales (ECV, *Essential Climate Variables*) (Baret et al., 2013; Camacho et al., 2013) y requeridas por la Convención Marco de las Naciones Unidas sobre el Cambio Climático (UNFCCC, *United Nations Framework Convention on Climate Change*) (UNFCCC, 2010) y el Panel Intergubernamental sobre el Cambio Climático (IPCC, *Intergovernmental Panel on Climate Change*) (IPCC, 2013). El LAI se trata de una variable que cuantifica la interfaz entre la vegetación y la atmósfera para intercambiar masa (agua y carbono) y energía (radiación y calor), así como controlar los procesos de fotosíntesis, transpiración e interceptación de lluvia, haciendo de esta variable un componente clave de los ciclos biogeoquímicos en los ecosistemas. Esta variable es clave en la modelización del crecimiento y desarrollo de las plantas (Yu et al., 2018), en la estimación de productividad (Deb Burman et al., 2017) y en el seguimiento de la fenología. Para una revisión más reciente y completa sobre métodos, productos y aplicaciones del índice de área foliar, ver Fang et al. (2019).

La humedad del suelo es una variable clave en la interacción tierra-atmósfera y tiene un papel importante en procesos hidrológicos (Brocca et al., 2017), climáticos (Seneviratne et al., 2010) y agronómicos. Esta variable regula el intercambio de energía en la capa límite atmosférica a través del flujo de calor latente y sensible desde la tierra a la atmósfera, y tiene una gran influencia en el reparto de la precipitación entre la escorrentía y el almacenamiento del agua en el terreno. Además, la humedad del suelo está íntimamente relacionada con la interacción entre el clima y la vegetación, ya que el clima y la vegetación influyen en la humedad del suelo a través de la evapotranspiración, mientras que la humedad del suelo y el clima determinan el tipo de vegetación en una región. El conocimiento de la humedad del suelo en zonas agrícolas conlleva grandes beneficios, entre los que cabría destacar la planificación del riego (Brocca et al., 2018), gestión de enfermedades y plagas, mejora de la predicción del rendimiento de los cultivos (Champagne et al., 2019; White et al., 2020), mejor predicción y seguimiento de sequías (Martínez-Fernández et al., 2017, 2016; Sánchez et al., 2018, 2016; Zhu et al., 2019) y así como su impacto en la producción agrícola.

El contenido de agua de la vegetación, VWC, puede proporcionar importantes implicaciones en la detección del estado fisiológico de la vegetación (Zhang et al., 2018), la decisión del riego agrícola, la evaluación de sequías y la estimación del rendimiento de los cultivos (Holzman et al., 2018; Zhang et al., 2010; Xiaoqiang Zhang et al., 2017). También hay que destacar que el VWC es una de las variables más importantes para la estimación del contenido de humedad del suelo a partir de sensores de microondas activos y pasivos, ya que actúan como un indicador del efecto de la vegetación en los modelos de transferencia radiativa que operan en la estimación de humedad del suelo.

La fracción de cobertura de la vegetación, FVC, es una variable que se utiliza para medir la cobertura vegetal superficial; además se trata de un indicador cuantitativo que explica la calidad de la vegetación y los cambios del ecosistema (Jiapaer et al., 2011), también es una variable controladora en la fotosíntesis, transpiración y otros procesos terrestres (Gutman and Ignatov, 1998; Hirano et al.,

2004). Por otra parte, muestra una gran importancia para la conservación del agua y el suelo, la regulación de la escorrentía y la mejora del microclima forestal. Ya que esta variable refleja los cambios del medio ambiente natural y las actividades humanas, se considera un indicador sensible en regiones áridas y semiáridas degradadas y desiertas.

La estimación de variables fenotípicas del dosel, como la altura de los cultivos, puede emplearse para determinar estrategias de manejo de cultivos (por ejemplo, fertilización de precisión) para maximizar su rendimiento y para evaluar los daños y la reducción del rendimiento como resultado de enfermedades, plagas, desastres climáticos, etc. Esta variable es uno de los indicadores más directos del crecimiento y desarrollo de las plantas y puede estar indirectamente relacionado con la productividad (Wang et al., 2019) y la tasa de crecimiento (Moles et al., 2009); también muestra una estrecha relación con el suministro de nitrógeno del suelo (Gul et al., 2015) y puede mejorar la estimación de biomasa de los cultivos (Tilly et al., 2015; Yue et al., 2017).

Por último, una de las variables más importantes para los ciclos del carbono, la asignación de nutrientes del suelo y la acumulación de combustible es la biomasa. Esta variable refleja el estado de crecimiento de los cultivos y está relacionada con la utilización de energía solar, el rendimiento y la calidad del grano (Hensgen et al., 2016; Huang et al., 2016). Por ello, se considera uno de las variables bioquímicas más importantes, y la estimación correcta de esta variable puede ayudar a mejorar el seguimiento de cultivos y la predicción del rendimiento (Habyarimana et al., 2019), además también ha demostrado ser una variable importante para la investigación ecológica a escala regional y local, estudios del ciclo global del carbono (Houghton et al., 2009) y cambio climático (Ali, 2013).

### **2.3.3. Estimación de variables biofísicas**

La estimación de variables biofísicas y la caracterización de la vegetación pueden realizarse a partir de métodos directos o indirectos. Los directos llevan a cabo mediciones directas sobre el terreno, haciendo medidas sobre la planta o la cobertura. Actualmente existen dos métodos directos para estimar las variables de la vegetación: 1) destructivos; 2) no destructivos. Los primeros recolectan material vegetal sobre el cual llevar a cabo las mediciones. Este método es el más apropiado para ecosistemas donde la estructura de la vegetación es pequeña como pastizales, cultivos agrícolas y tundras. Los segundos aplican ecuaciones alométricas o usan instrumental de adquisición de datos que miden el parámetro.

Los métodos indirectos emplean imágenes satelitales (Lopez-Sanchez et al., 2017; Pasqualotto et al., 2019; Song et al., 2017; Upreti et al., 2019; Xie et al., 2019) o fotografías aéreas (Caruso et al., 2019; Han et al., 2019; Lu et al., 2018; Ramírez-Mejía et al., 2018) y se suelen basar en enfoques estadísticos y probabilísticos de la distribución y disposición de los elementos foliares (o su complemento, fracción de brecha) en el dosel.

Cuando las muestras son lo suficientemente representativas, los métodos directos se consideran más precisos que los métodos indirectos y, por lo tanto, a menudo se utilizan para validar métodos indirectos. Sin embargo, los métodos directos generalmente requieren más tiempo, trabajo, y destruyen la vegetación, lo que limita sus aplicaciones y los hace inviables para mediciones de alta frecuencia temporal y espacial (Jonckheere et al., 2004; Weiss et al., 2004).

## 2.4. Radar aplicado a la agricultura

El uso de sensores de radar para aplicaciones agrícolas se lleva estudiando desde 1970. La capacidad de los sistemas de radar de obtener datos en casi todas las condiciones climáticas y en cualquier momento (de día o de noche) presenta una gran ventaja frente a otros sistemas de teledetección, como los basados en el espectro óptico. Sin embargo, la interacción de la señal del radar con los objetivos agrícolas se ve afectada por una variedad de factores. Las interacciones entre las microondas y la cubierta/cobertura agrícola están influenciadas por las propiedades del sistema radar en sí, es decir, la frecuencia y polarización de las microondas, y los ángulos de incidencia en los que las cubiertas/coberturas agrícolas son visibles (Ulaby, 1975; Ulaby et al., 1975). Las interacciones entre las microondas y el dosel se rigen por las propiedades dieléctricas, el tamaño, la forma, la orientación y la rugosidad de los dispersores individuales, es decir, las hojas, tallos, frutos, etc. (Della Vecchia et al., 2006; Kozlov et al., 2001; Macelloni et al., 2001; Oh and Hong, 2007) y su distribución en el todo el dosel (Karam et al., 1992; Yueh et al., 1992). Las propiedades dieléctricas de los materiales vegetales están muy relacionadas con su contenido de agua, y, en menor medida, con la temperatura y la salinidad. Estas características del dosel varían durante la temporada de crecimiento, están influenciadas por las condiciones ambientales y el estrés (Blaes et al., 2006; Mattia et al., 2003; Moran et al., 1989) y son específicas de cada cultivo.

La magnitud de la retrodispersión del radar depende del efecto de la frecuencia en la interacción entre las microondas y la cubierta/cobertura agrícola debido a diferencias en la constante dieléctrica del contenido de agua en función de la frecuencia; y a la relación entre la longitud de onda y el tamaño de parte de la planta y/o la profundidad de penetración. La frecuencia más baja (banda L, 1-2 GHz) puede penetrar a través del dosel e interactuar con el tallo y debajo del suelo. Las señales de frecuencia de la banda C (4-8 GHz) interactúan más con el dosel, mientras que la banda X, de frecuencia más alta (8-12 GHz), interactúa principalmente con la parte superior del dosel (Balenzano et al., 2011). La vegetación y la rugosidad de la superficie reducen la sensibilidad de las observaciones de microondas a las variaciones en la humedad del suelo. Estos efectos se vuelven más pronunciados a medida que aumenta la frecuencia; por lo tanto, los radares de baja frecuencia en el rango de la banda L o P (0,25-0,5 GHz) son más adecuados para la estimación de la humedad del suelo (Das and Paul, 2015; Karthikeyan et al., 2017). Además, en las frecuencias de microondas más bajas, como la L o la P, la emisión de microondas del suelo se origina desde un perfil del suelo más profundo (unos pocos cm), lo que da como resultado una medición más representativa de las condiciones de humedad debajo de la corteza superficial. Los sistemas de mayor frecuencia, sin embargo, enfatizan la componente del

cultivo, aunque con grandes cantidades de vegetación, la banda L o más bajas son las preferidas ya que minimizan la contribución del cultivo a la retrodispersión (Brown et al., 1992).

La mayoría de los sistemas radar de teledetección están diseñados para transmitir la radiación de las microondas horizontalmente (H) o verticalmente (V). Si un radar de apertura sintética transmite y recibe dos polarizaciones ortogonales como H y V, registra ambas y durante el procesamiento retiene la fase entre estas dos polarizaciones, entonces es posible sintetizar cualquier polarización de transmisión-recepción. Los sistemas que transmiten y reciben ambas polarizaciones lineales se usan comúnmente. Varios estudios han demostrado que la polarización cruzada (HV o VH) es la polarización más importante para identificar la mayoría de los cultivos agrícolas (McNairn et al., 2009a, 2009b; Moran et al., 2012; Skriver, 2012).

En cuanto al efecto del ángulo de incidencia en la interacción de las microondas con objetivos agrícolas, la relación entre la geometría de visualización y la geometría de las características de la superficie juega un papel importante en la forma en la que la energía del radar interactúa con los objetivos. Con un ángulo de incidencia menor, las señales de microondas pueden interactuar con el suelo al pasar por los huecos de las plantas. Mientras que con un ángulo de incidencia mayor, la señal de retorno está más influenciada por la cobertura del cultivo que por las características del suelo. La intensidad de la señal del radar disminuye exponencialmente a medida que aumenta la profundidad del dosel debido a la absorción y dispersión de las microondas. Varios experimentos han demostrado que los datos SAR con ángulos de incidencia bajos son más sensibles a la humedad del suelo (Das and Paul, 2015; Karthikeyan et al., 2017; Petropoulos et al., 2015; Wang, 2018), por lo tanto, estos ángulos de incidencia son los preferidos para aplicaciones de humedad del suelo ya que los efectos de rugosidad y la atenuación de la vegetación se minimizan. Los ángulos de alta incidencia son más sensibles a las características del cultivo (Chakraborty et al., 2005; Kothapalli Venkata et al., 2017; Lopez-Sanchez et al., 2015), y en general, la discriminación de cultivos basada en la retrodispersión del dosel es óptima en ángulos de incidencia mayores. Por el contrario, datos SAR con ángulos de incidencia muy alta no son adecuados para la recuperación de parámetros biofísicos de los cultivos debido a la posibilidad de saturación temprana.

Teniendo en cuenta los factores anteriormente mencionados, existe un potencial significativo para el uso de la teledetección por radar en aplicaciones agrícolas, particularmente clasificación, monitoreo de cultivos y monitoreo de humedad del suelo / vegetación. Gran parte de la información requerida para el seguimiento de cultivos puede ser proporcionada por sistemas de radar que operan en las bandas L y C, en co- y cross- polarizaciones lineales y ángulos de incidencia intermedios (entre 30° - 40°).

En Liu et al. (2019) y Steele-Dunne et al. (2017) se revisa el empleo de datos SAR para aplicaciones agrícolas.

### 2.4.1. Datos SAR aplicados al seguimiento de cultivos agrícolas

Los primeros instrumentos SAR dedicados al seguimiento de cultivos explotaban únicamente el coeficiente de retrodispersión, generalmente en un solo canal de polarización, ya que era la única observación proporcionada por los sensores operativos en ese momento. Desafortunadamente, las diferentes propiedades locales (por ejemplo, rugosidad y humedad del suelo, propiedades de la vegetación) conducen a valores similares y cambios equivalentes en el coeficiente de retrodispersión, por lo que el seguimiento de cultivos con SAR no tuvo demasiado éxito (Steele-Dunne et al., 2017). Esta situación comenzó a cambiar en 2007 con el lanzamiento del ALOS-PALSAR por JAXA (Rosenqvist et al., 2007), RADARSAT-2 por CSA (Morena et al., 2004) y TerraSAR-X por el Centro Aeroespacial Alemán (DLR, *Deutsches Zentrum für Luft- und Raumfahrt*) (Werninghaus, 2004; Werninghaus and Buckreuss, 2009), para los cuales la información polarimétrica (es decir, correlaciones y diferencia de fase entre canales) también está disponible. Las nuevas adquisiciones coherentes polarimétricas abrieron nuevas perspectivas para el seguimiento de cultivos. La misión de la constelación RADARSAT (Thompson, 2015) y Sentinel-1 (Torres et al., 2012) continuarán proporcionando la información polarimétrica necesaria para el seguimiento agrícola.

Para diseñar una aplicación de seguimiento de cultivos que emplee imágenes SAR, es necesario analizar la sensibilidad de los parámetros del radar (es decir, el coeficiente de retrodispersión o cualquier otra variable derivada de las mediciones del radar) con respecto a las variables biofísicas que describen las condiciones del cultivo en cada fecha de adquisición. Algunos ejemplos en la literatura muestran una correlación de los parámetros del cultivo con los observables polarimétricos del radar, tanto para cultivos específicos (Bériaux et al., 2015; Inoue et al., 2014, 2002; Inoue and Sakaiya, 2013; Mandal et al., 2020b), o varios tipos de cultivos simultáneamente (Cable et al., 2014; Liao et al., 2018; Nasirzadehdizaji et al., 2019; Ulaby et al., 1984; Wiseman et al., 2014).

El uso de RADARSAT-2 como sensor con capacidades polarimétricas para el seguimiento de cultivos se inició con campañas de campo en Canadá en 2008, y también fue explorado por la campaña AgriSAR2009 financiada por la ESA (Caves et al., 2011). Uno de los primeros artículos que explota la diversidad de estos datos fue publicado por Moran et al. (2012), en el que los coeficientes de retrodispersión para todos los canales de polarización se obtuvieron de una serie temporal de 57 imágenes de RADARSAT-2 a diferentes ángulos de incidencia desde abril hasta septiembre de 2009 para parcelas de trigo, cebada, avena, maíz, cebolla y alfalfa. El canal de polarización cruzada (HV) se mostró como el coeficiente de retrodispersión más útil para monitorear las condiciones del suelo y del cultivo, mostrando también ser menos sensible a las diferencias en el ángulo de incidencia. Se encontró una correlación positiva entre los coeficientes de retrodispersión y el índice de vegetación de diferencia normalizada (NDVI, *Normalized Difference Vegetation Index*) para cebolla y maíz, mientras que el impacto del ángulo de incidencia en la serie temporal fue mínimo en comparación con la respuesta de la señal en los cultivos y el suelo. Inoue and Sakaiya (2013) y Inoue et al. (2014) estudiaron la correlación de los coeficientes de retrodispersión obtenidos a partir de las imágenes de los satélites COSMO-SkyMed (banda X) y RADARSAT-2 (banda C) para cultivos de arroz, sugiriendo el

potencial que proporcionan estas imágenes para evaluar el rendimiento que tendría el cultivo del arroz y otras variables biofísicas (LAI, biomasa foliar y fracción de radiación fotosintéticamente activa absorbida, fAPAR (*Fraction of Absorbed Photosynthetically Active Radiation*)) a escala regional. Recientemente, Bériaux et al. (2015) emplearon datos satelitales *quad-pol* en banda C para obtener LAI y humedad del suelo en campos de maíz. Este estudio destacó la sensibilidad de la polarización cruzada, especialmente para valores de LAI altos, y también se encontró que la polarización vertical de transmisión y recepción (VV) es más sensible para valores de LAI menores de 2.

Todos los estudios anteriormente mencionados usan únicamente 1 o más canales polarimétricos, por lo que otras observaciones polarimétricas no fueron analizadas. Otros estudios han ampliado el conjunto de parámetros más allá de los coeficientes de retrodispersión. Cable et al. (2014), empleando imágenes del RADARSAT-2 con dos ángulos de incidencia diferentes, analizó como los cambios en el tiempo de adquisición y el ángulo de incidencia afectaron a los parámetros polarimétricos para varios cultivos (cebada, canola, avena, soja y trigo). Los coeficientes de retrodispersión para todos los objetivos fueron mayores cuando se adquirieron en un ángulo de incidencia más pronunciado (26°). Todos los objetivos de cultivos comerciales mostraron un aumento y una caída en la respuesta de retrodispersión durante el transcurso de la temporada de crecimiento, coincidiendo con las etapas cambiantes de crecimiento. Las gráficas de respuesta polarimétrica y las descomposiciones ofrecieron información sobre el mecanismo de dispersión para cada tipo de cultivo y, en general, mostraron un aumento en la dispersión del volumen a medida que los cultivos alcanzan la madurez. Específicamente, el tipo de dispersión primaria cambió de dispersión de superficie a dispersión de volumen a medida que los cultivos maduraban, tanto en lo que respecta a las descomposiciones de Cloude and Pottier (1997) y Freeman and Durden (1998). Wiseman et al. (2014) comparó 21 parámetros polarimétricos derivados de imágenes RADARSAT-2 con biomasa seca de canola, maíz, soja y trigo de primavera. Durante el período de acumulación de biomasa, se observaron correlaciones significativas con la biomasa seca para la mayoría de los parámetros del SAR en el maíz, la canola y la soja, lo que podría resultar útil como indicadores del momento de la cosecha. Adams et al. (2013b) investigó las descomposiciones de Cloude-Pottier y Freeman-Durden a partir de datos de RADARSAT-2 para identificar los campos cosechados. La investigación informó que la descomposición de dispersión polarimétrica aplicada a adquisiciones de ángulos de incidencia menos profundos puede ser útil para el monitoreo agrícola debido a la caracterización de mecanismos únicos de dispersión de suelos y biomasa. Jiao et al. (2011) evaluaron 18 parámetros polarimétricos derivados de imágenes RADARSAT-2 *quad-pol* con ángulos de incidencia a 25° y 40° con el índice de área foliar para cultivos de maíz y soja. Descubrieron que el LAI del maíz y la soja se correlacionaba mejor con los parámetros polarimétricos sensibles a la dispersión de volumen (coeficiente de retrodispersión en el canal de polarización cruzada en la base lineal, es decir, HV, y en el canal de polarización copolar en la base circular, es decir, LL y RR, altura del pedestal y dispersión de volumen de la descomposición de Freeman-Durden) con un ángulo de incidencia más pronunciado. Adams et al. (2013a) empleó un conjunto de parámetros polarimétricos a partir de datos del RADARSAT-2 en diferentes ángulos de incidencia para evaluar la sensibilidad de estos parámetros a las características de la superficie agrícola sin vegetación. Smith and Buckley (2011) obtuvieron tres parámetros de la descomposición de Freeman-Durden de imágenes RADARSAT-2 para monitorear los pastizales y generar mapas de coberturas del suelo.

Recientemente, Liao et al. (2018) estudiaron la sensibilidad de 16 parámetros polarimétricos obtenidos de imágenes RADARSAT-2 con la altura y la fracción de cobertura de la vegetación para cultivos de maíz y trigo. Se demostró que en las etapas de crecimiento inicial del maíz, la altura mostró correlaciones altas con el coeficiente de retrodispersión (HV), el segundo parámetro de la descomposición de Pauli (HH-VV) y el ratio (HV/VV), mientras que para la fracción de cobertura de la vegetación del mismo cultivo destacaron las correlaciones con HV y HV/VV. Para el trigo, se encontró que la sensibilidad de los parámetros con las variables biofísicas fue baja. Estos hallazgos muestran el potencial que tienen los parámetros SAR para la estimación de la altura y el FVC para cultivos de hoja ancha. Nasirzadehdizaji et al. (2019) emplearon imágenes del Sentinel-1 para analizar 10 parámetros polarimétricos con 2 variables biofísicas (altura de los cultivos y cobertura del dosel). Los análisis se llevaron a cabo para cultivos de maíz, girasol y trigo. Se demostró que las variables biofísicas del maíz fueron mejor correlacionadas con los parámetros polarimétricos que para el trigo o girasol.

Otros estudios que utilizan un conjunto variado de parámetros polarimétricos se pueden encontrar en Lopez-Sanchez et al. (2014, 2012). Estos parámetros, calculados en la banda X con datos *dual-pol* de TerraSAR-X y en la banda C con datos *quad-pol* de RADARSAT-2, se utilizaron para rastrear los cambios fenológicos en los campos de arroz.

### **2.4.2. Clasificación de coberturas del suelo a partir de datos de radar**

El conocimiento del cultivo presente en cada parcela agrícola, tanto a escala nacional como regional, proporciona una información muy valiosa para pronosticar su rendimiento (Kogan et al., 2013) y estimar su área (Gallego et al., 2014). Además, a escala mundial, el conocimiento de los usos y las cubiertas de las tierras de cultivo son clave para poder estimar la producción mundial de alimentos, analizar el riesgo de sequía e incluso puede tener un impacto en los estudios sobre eventos climáticos (Becker-Reshef et al., 2010).

La teledetección se trata de una fuente de datos efectiva para clasificar diferentes cubiertas terrestres. Las imágenes ópticas han demostrado que se pueden distinguir los diferentes tipos de vegetación analizando su firma espectral y la etapa fenológica en el momento de adquisición de la imagen (Gómez et al., 2016). Sin embargo, debido a la presencia de nubes, las imágenes ópticas pueden perder períodos importantes durante la temporada de crecimiento, por lo que pueden no ser lo suficientemente precisas para la clasificación de cultivos en algunas situaciones (McNairn et al., 2002). Por otro lado, los sensores de microondas activos están cobrando especial importancia ya que pueden proporcionar datos independientemente de la luz del día, la capa de nubes y las condiciones climáticas, haciendo que las imágenes SAR sean relevantes para aplicaciones agrícolas, como la clasificación de cultivos y las actividades de monitoreo, que son críticas en el tiempo.

En el contexto de la teledetección, aparte de una selección adecuada de las imágenes de satélite, la selección del método de clasificación es también un paso importante hacia una clasificación



exitosa de los diferentes tipos de cultivos. Algunos de los métodos empleados en teledetección para la clasificación de cultivos son: 1) paramétricos; 2) no paramétricos; 3) supervisados; 4) no supervisados; 5) basados en píxeles; o 6) basados en objetos (Orynbaikyzy et al., 2019).

Ciertos estudios iniciales sugieren que las imágenes SAR de una sola frecuencia y polarización podrían integrarse con imágenes de satélite ópticas para lograr precisiones de clasificación de cultivos muy altas, por ejemplo, utilizando imágenes de banda C con al menos una imagen óptica (Ban, 2003; Blaes et al., 2005; Brisco and Brown, 1995; McNairn et al., 2009a; Schotten et al., 1995). Actualmente, el número de estudios que combina el uso de imágenes ópticas y SAR para la clasificación de cultivos ha aumentado considerablemente, ya que por ejemplo los datos SAR muestran un mejor rendimiento para distinguir ciertos cultivos, pero no son tan adecuados para distinguir otros. Lo mismo ocurre con las imágenes ópticas, y esto se debe a que ambos conjuntos de datos reflejan varias propiedades de los cultivos con respecto a sus características espectrales, estructurales, biofísicas o agronómicas. Para una revisión más completa sobre la combinación de datos ópticos y radar para la clasificación de cultivos, ver Orynbaikyzy et al. (2019).

Pensando únicamente en el uso de imágenes SAR para la discriminación de cultivos y la clasificación de la cobertura de la tierra, los investigadores encontraron mayores precisiones de clasificación con datos de frecuencia única, especialmente con datos de banda C, L y P (Chen et al., 2015; Denize et al., 2019; Turkar et al., 2012). Sin embargo, un enfoque de clasificación empleando datos multifrecuencia y multipolarización es también una opción útil para separar los tipos de vegetación, como se ha demostrado utilizando datos adquiridos de múltiples plataformas satélites, por ejemplo, usando ERS (banda C) y JERS (banda L) (Bouman and Uenk, 1992; Dobson et al., 1996), ENVISAT ASAR (banda C) y TerraSAR-X (banda X) (Jia et al., 2012). Como se mencionó en secciones anteriores, las frecuencias más bajas (es decir, la banda L) penetran en cultivos de biomasa más grandes, y la dispersión dentro del dosel, donde la estructura es bastante diferente, ayuda a separarlos (McNairn et al., 2009b). Para cubiertas de biomasa más pequeñas, las frecuencias más bajas pueden penetrar demasiado en la cubierta y depender principalmente de las propiedades del suelo, como el contenido de humedad del suelo (Schmugge et al., 2002). En este caso, la discriminación se consigue utilizando microondas de mayor frecuencia donde la mayor parte de la interacción se limita al dosel y se observa una clara variación en las propiedades de la escena agrícola debido al desarrollo de los cultivos durante la temporada de crecimiento (Skriver et al., 1999). Por lo tanto, las capacidades de discriminación pueden variar a lo largo del año y, en consecuencia, el cartografiado de la cubierta terrestre puede mejorarse significativamente mediante la realización de una clasificación multitemporal (Arias et al., 2020; Larrañaga et al., 2013; Skriver, 2012; Skriver et al., 2011; Sonobe, 2019). La clasificación de imágenes multitemporales no solo mejora la precisión general del clasificador sino que también proporciona una discriminación de cultivos más confiable en comparación con la fecha única (Bargiel, 2017; Hariharan et al., 2018; Kussul et al., 2015; Mandal et al., 2018; Siachalou et al., 2015).

Independientemente del sensor o la frecuencia utilizada, la clave para una clasificación eficiente se basa en comprender qué etapas de crecimiento son las mejores para la discriminación de los cultivos. Al igual que los sensores ópticos, la energía registrada por los sensores SAR podría ser similar para diferentes cultivos en momento dado de su ciclo de crecimiento. Sin embargo, el uso de

conjuntos de datos multitemporales nos permite distinguir más cultivos entre sí debido a sus diferentes ciclos fenológicos (Bargiel, 2017; Canisius et al., 2018; Mascolo et al., 2016).

Teniendo en cuenta la polarización individual a la hora de hacer clasificación de cultivos, el canal de polarización cruzada (HV o VH, que son prácticamente idénticos debido a la reciprocidad) es la polarización única más importante para identificar la mayoría de los cultivos (McNairn and Shang, 2016; Steele-Dunne et al., 2017). Esta polarización responde a la dispersión múltiple del volumen de la vegetación y, dado que las estructuras de la vegetación varían mucho entre las copas, la retrodispersión de la polarización cruzada proporciona la mejor discriminación. La precisión de la clasificación aumenta añadiendo canales polarimétricos adicionales (en forma de coeficientes de retrodispersión), por ejemplo, Lee et al. (2001) observó una mejora significativa en la precisión de la clasificación al añadir un segundo canal de polarización, sin embargo, con el empleo de una tercera polarización únicamente se producen mejoras en la precisión de la clasificación para cultivos específicos (McNairn et al., 2009a).

Generalmente, la explotación de los datos SAR polarimétricos para la clasificación de cultivos se lleva a cabo empleando las matrices de covarianza o coherencia, pero existen diferentes enfoques adicionales: 1) métodos estadísticos basados en la distribución Wishart de los datos; se ha demostrado que tanto la matriz de covarianza como la matriz de coherencia tienen una distribución de Wishart compleja (Lee et al., 1994b), ya que la única diferencia entre estas dos matrices es una transformación lineal. La distancia de Wishart fue propuesta por Lee et al. (1999, 1994a) basándose en la distribución compleja de Wishart de ambas matrices y se considera uno de los logros más destacados en el uso de la distribución estadística de datos polarimétricos. La propiedad estadística de las imágenes polarimétricas se utiliza a menudo junto con mecanismos de dispersión (Guo et al., 2018; Li et al., 2016; Liao et al., 2020; Sun et al., 2015; Yin et al., 2020). 2) elementos de la matriz de covarianza transformados en coeficientes de retrodispersión (Mandal et al., 2020a; McNairn et al., 2014; Zeyada et al., 2016). 3) métodos basados en mecanismos de dispersión tales como la descomposición de Pauli, Freeman-Durden, Huynen, Krogager, Cameron y la entropía (H) y el ángulo alfa ( $\alpha$ ) (Larrañaga and Álvarez-Mozos, 2016; Lee and Pottier, 2009; Srikanth et al., 2016; Ustuner and Sanli, 2019). De todas ellas, la descomposición de la entropía y el ángulo alfa es la más utilizada por su simplicidad y claro significado físico (Chen et al., 2018, 2014). 4) métodos basados en el conocimiento (Chirakkal et al., 2019; Mishra et al., 2017; Verma et al., 2019). En este caso, por ejemplo, la clasificación basada en el conocimiento es un enfoque a nivel de píxeles en el que la clasificación se realiza a través de un conjunto de hipótesis, reglas y variables. Es posible aplicar métodos relativamente robustos y ajustarse fácilmente a diferentes condiciones de crecimiento (Skriver, 2012), incluidos los resultados del modelo de dispersión y el conocimiento común sobre los objetivos. Sin embargo, estos métodos tienen la desventaja de determinar solo un número relativamente pequeño de clases.

La capacidad de los datos SAR polarimétricos para la clasificación de cultivos también se ha demostrado mediante la aplicación de algoritmos de aprendizaje automático como bosques aleatorios (RF, *Random Forest*) (Busquier et al., 2020, 2019; Denize et al., 2019; Dey et al., 2020; Larrañaga and Álvarez-Mozos, 2016; Li et al., 2020), árboles de decisión (DT, *Decision Trees*) (McNairn et al., 2014; Mishra et al., 2017; Xu et al., 2019; Zhang et al., 2015), redes neuronales (NN, *Neural Networks*) (Guo

et al., 2020; Liao et al., 2020; Ndikumana et al., 2018; Skakun et al., 2016; Zhao et al., 2019) y máquinas de soporte vectorial (SVM, *Support Vector Machine*) (Mandal et al., 2020a; Sonobe, 2019; Sonobe et al., 2017; Sun et al., 2019; Zeyada et al., 2016).



CAPÍTULO 3:  
ÁREA DE ESTUDIO



## Capítulo 3: Área de estudio

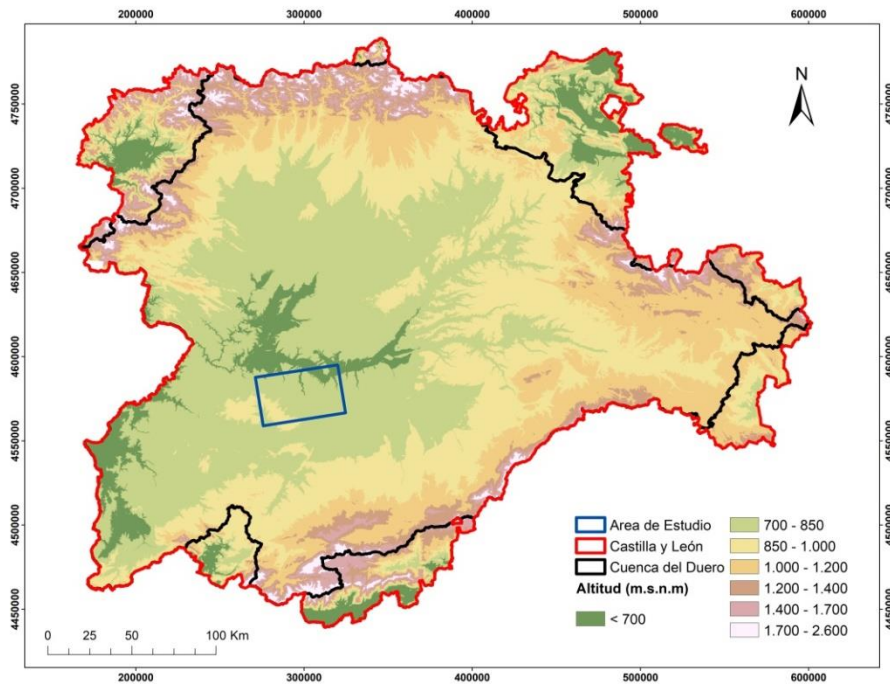
En este capítulo se describen las características generales de la cuenca del Duero, que alberga la zona particular de estudio del seguimiento de cultivos y de la clasificación de usos y coberturas del suelo. Se hablara del clima, geología, litología y suelos, así como de las características hidrológicas de la zona, factores todos ellos condicionantes de la agricultura.

### 3.1. Sustrato geológico y relieve

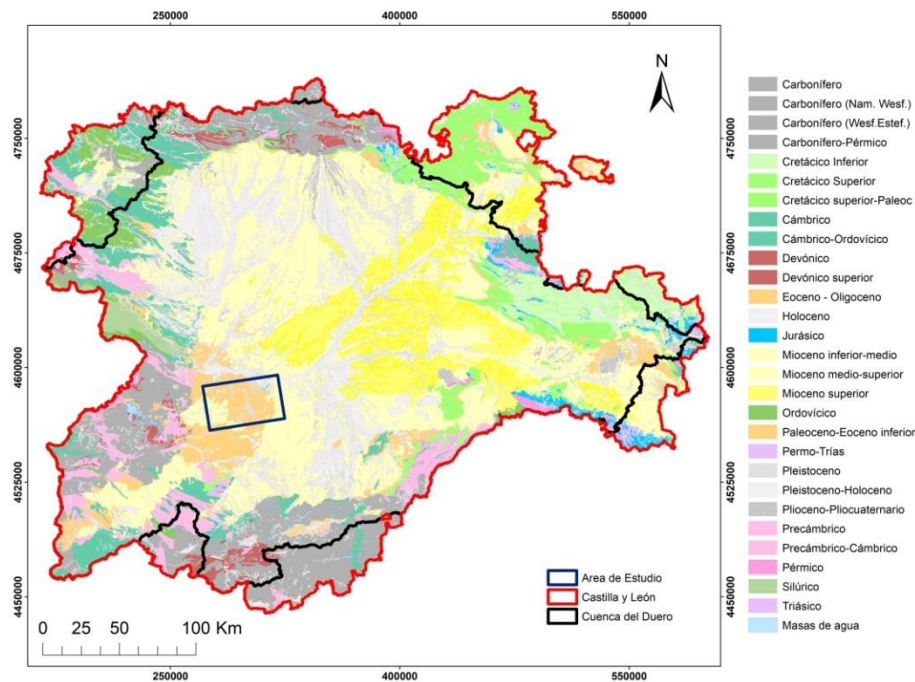
Los límites geográficos de la cuenca están marcados por las divisorias de una serie de sistemas montañosos: al norte limita con la Cordillera Cantábrica, al noroeste con los Montes de León, al sur con el Sistema Central y al este con la cordillera Ibérica. Morfológicamente constituye una zona deprimida formada por llanuras diversas con una elevada altitud media (700-1100 m.s.n.m.) (Figura 3.1). Está formada básicamente por una extensa cuenca neógena de aproximadamente 75000 km<sup>2</sup>, ocupando casi toda la región de Castilla y León. Desde el punto de vista geológico, en la cuenca del Duero se pueden distinguir ciertas unidades bien diferenciadas por sus características estructurales y composición litológica.

El sector occidental pertenece al antiguo zócalo paleozoico y está formado por materiales muy antiguos depositados durante los periodos Cámbrico y Carbonífero (Figura 3.2) en un profundo geosinclinal. Arcillas y areniscas (Figuras 3.3-3.4) son los sedimentos predominantes en la zona, los cuales se vieron sometidos a un metamorfismo regional y de contacto. En este sector, junto a los granitos procedentes del magmatismo, predominan los afloramientos de rocas metamórficas como la pizarra, el gneis y la cuarcita (Figuras 3.3-3.4). Posteriormente, estos relieves fueron sometidos durante un largo periodo de tiempo, hasta que se convirtieron en una extensa planicie, donde la altitud media es de unos 800 m.s.n.m. (Figura 3.1).

En la planicie sedimentaria, desde finales del Mesozoico y, sobre todo, durante el Cenozoico, el zócalo se vio afectado por intensas presiones relacionadas con el plegamiento alpino. Las consecuencias de este último fueron, entre otras, el basculamiento del zócalo hacia el oeste, de manera que el drenaje se dirige desde entonces hacia el Atlántico, el levantamiento de las montañas que rodean el zócalo y la deformación del mismo en ondulaciones que dieron lugar a un sistema de depresiones cerradas.



**Figura 3.1.** Mapa de altitud. Fuente: Elaboración propia a partir del Modelo Digital del Terreno (MDT) del ITACyL (Instituto Tecnológico Agrario de Castilla y León), procedente del Plan Nacional de Ortofotografía Aérea (PNOA).



**Figura 3.2.** Mapa de periodos geológicos. Fuente: Elaboración propia a partir del Mapa Geológico de Castilla y León (1:100.000).



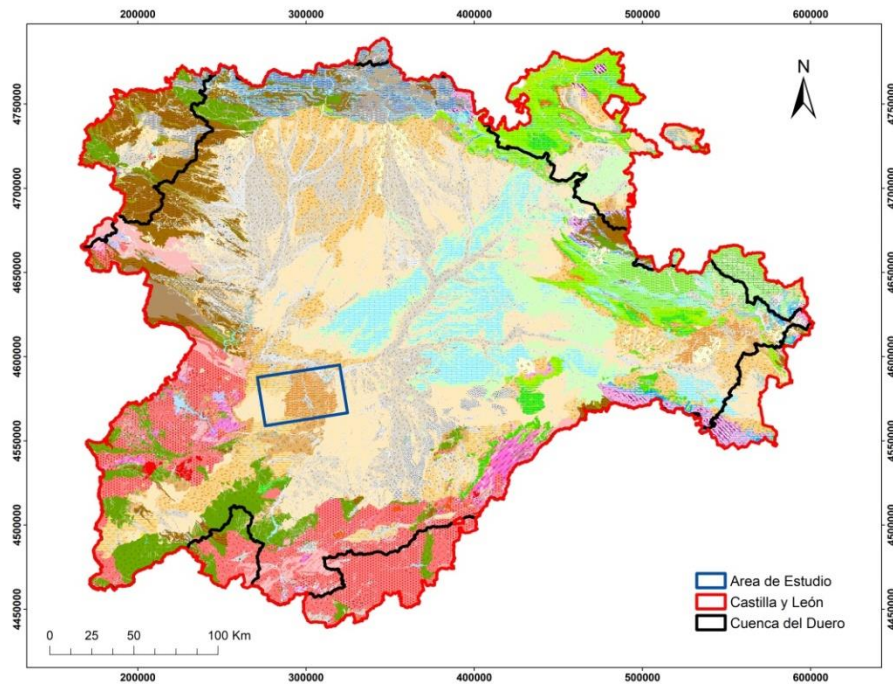


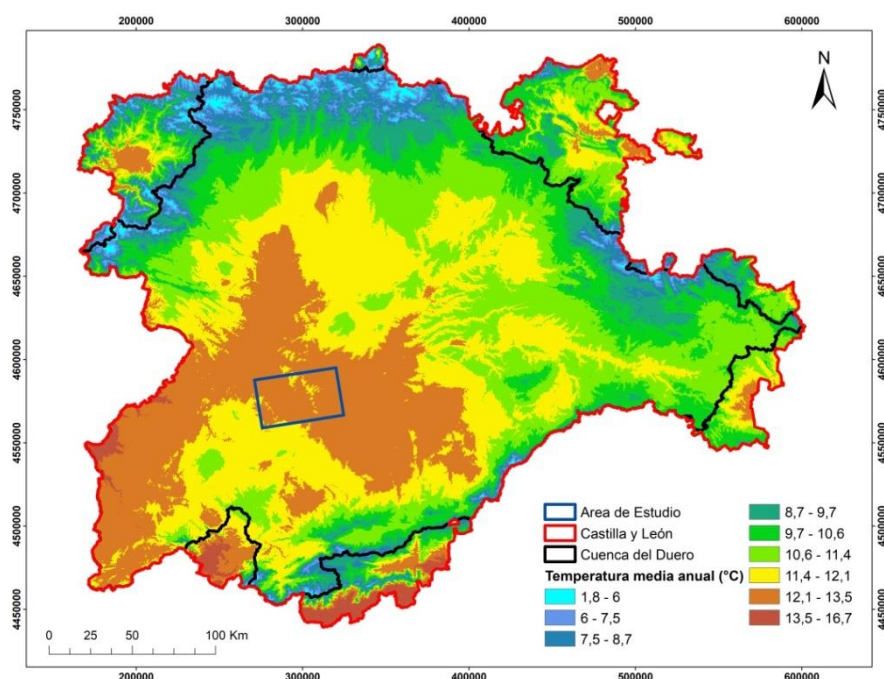
Figura 3.3. Mapa de litología de la cuenca del Duero. Fuente: Elaboración propia a partir de la capa de litología del Mapa Geológico de Castilla y León (1:100.000).



Figura 3.4. Leyenda del mapa de litología de la cuenca del Duero. Fuente: Elaboración propia a partir de la capa de litología del Mapa Geológico de Castilla y León (1:100.000).

## 3.2. Clima

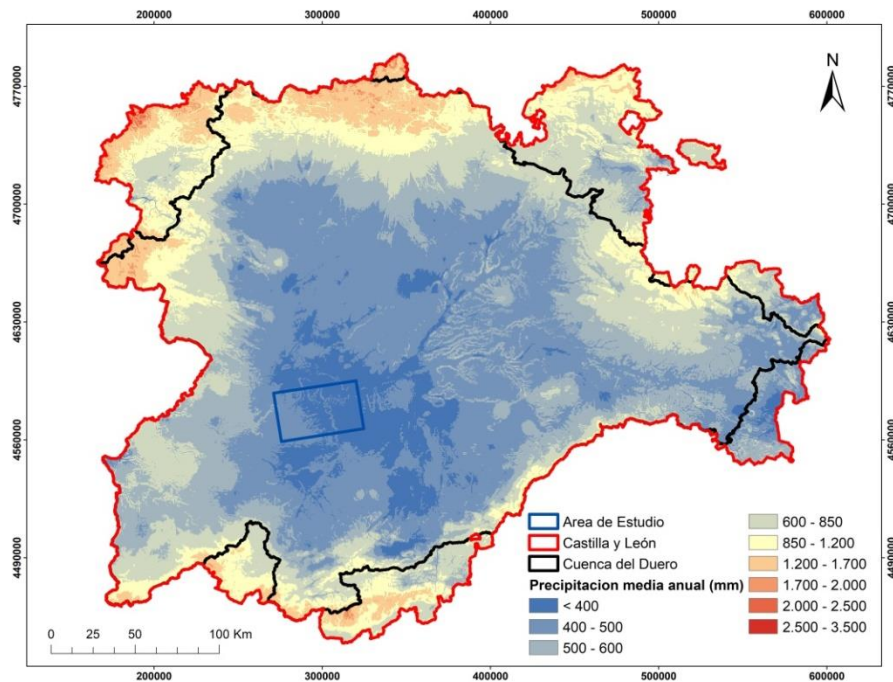
Las condiciones climáticas de la cuenca del Duero responden esencialmente a la interacción de dos factores geográficos: 1) situación (NW de la Península Ibérica) respecto a la dinámica atmosférica, y 2) relieve dual (montañas/llanuras); mientras que los dos rasgos morfológicos que determinan las características climáticas, proporcionando una notable variabilidad espacial sobre la distribución de temperaturas y precipitaciones, son la elevada altitud media de la planicie interior (Figura 3.1), y el cinturón montañoso que cierra la cuenca (Cabo and Manero, 1991). Las montañas retienen la mayor parte de las precipitaciones procedentes del oeste, dejando en el interior de la cuenca condiciones de sequedad que no son propias de la inestabilidad atmosférica en que se produce. Esto provoca un fuerte gradiente pluviométrico desde las montañas, que pueden registrar precipitaciones de más de 1500 mm anuales, hasta el centro de la cuenca, con precipitaciones anuales por debajo de los 400 mm (Figura 3.6). Por otro lado, el aislamiento al que queda sometido el interior de la meseta, unido a su elevada altitud, se ve reflejado en frecuentes condiciones de estabilidad que, impidiendo los movimientos verticales del aire, provocan durante el invierno inversiones térmicas, heladas nocturnas, nieblas y altas amplitudes térmicas diarias (Morán-Tejeda, 2011).



**Figura 3.5.** Mapa de temperaturas medias anuales de la cuenca del Duero (periodo 1981-2010). Fuente: Elaboración propia a partir de los datos del Atlas Agroclimático de Castilla y León (Nafría et al., 2013).

El régimen térmico de la cuenca se caracteriza por grandes oscilaciones entre los meses de invierno y verano, especialmente por la larga duración de los inviernos, la dureza de las temperaturas

mínimas con frecuentes heladas y la suavidad del verano. Las temperaturas más altas se registran en el suroeste (Arribes del Duero) y sur del Sistema Central con valores medios anuales que superan los 15°C, mientras que las mínimas, con valores por debajo de los 5°C de media anual, se sitúan en las zonas montañosas de la Cordillera Cantábrica (Nafría et al., 2013) (Figura 3.5). Estas condiciones determinan cultivos muy adaptados a la dura climatología, especialmente los que se benefician del gradiente de temperaturas diario (el viñedo, por ejemplo) y estacional (los cereales de secano, por ejemplo).

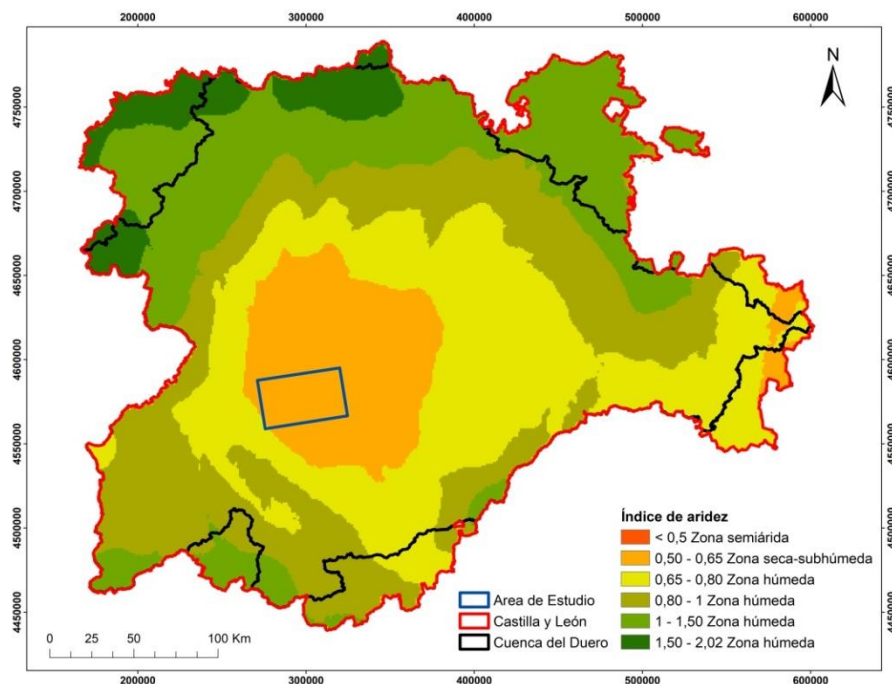


**Figura 3.6.** Mapa de precipitaciones medias anuales de la cuenca del Duero (periodo 1981-2010). Fuente: Elaboración propia a partir de los datos del Atlas Agroclimático de Castilla y León (Nafría et al., 2013).

El régimen pluviométrico registra un periodo húmedo entre el otoño y la primavera y un periodo con escasa pluviosidad en los meses de verano, con precipitaciones inferiores a los 20 mm mensuales, de modo que la aridez estival es más acentuada en la planicie interior (Figura 3.7), como es el caso de la zona de estudio. A la estacionalidad de las precipitaciones hay que añadir el contraste pluviométrico entre el interior y el borde montañoso. La mayor parte de la cuenca se encuentra por debajo de los 700 mm, y un amplio sector central no sobrepasa los 400 mm (González-Zamora et al., 2015; Sánchez et al., 2012a, 2012b), esta baja precipitación y el régimen semiárido de la zona particular de estudio (Figura 3.7) hace que sea necesario estudiar los cultivos en régimen natural, en peligro por el ascenso de la temperatura y el descenso de la precipitación por el calentamiento global. Estas condiciones semiáridas también condicionan el cuadro de cultivos, que es mayoritariamente de secano (Figura 3.10). Por el contrario, las montañas registran mayor humedad, con precipitaciones cercanas a los 1000 mm en toda la orla montañosa y por encima de estos en gran parte de la franja noroccidental,

debido en parte a su exposición a la entrada de perturbaciones atlánticas (Figura 3.5). En estas zonas predominan los bosques atlánticos, mientras que en el interior se encuentran bosques abiertos de tipo mediterráneo entremezclados con cultivos agrícolas (la dehesa, por ejemplo).

En definitiva, se ha definido el clima como Mediterráneo continentalizado o variedad fría del Mediterráneo (García-Fernández, 1986). Debido a la influencia atlántica, en el sector nor-noroeste, el clima pasaría a un tipo sub-atlántico (García-Fernández, 1986).



**Figura 3.7.** Mapa del índice de aridez (clasificación UNEP-FAO (*United Nations Environment Programme – Food and Agriculture Organization*)). Fuente: Elaboración propia a partir de los datos del Atlas Agroclimático de Castilla y León (Nafria et al., 2013).

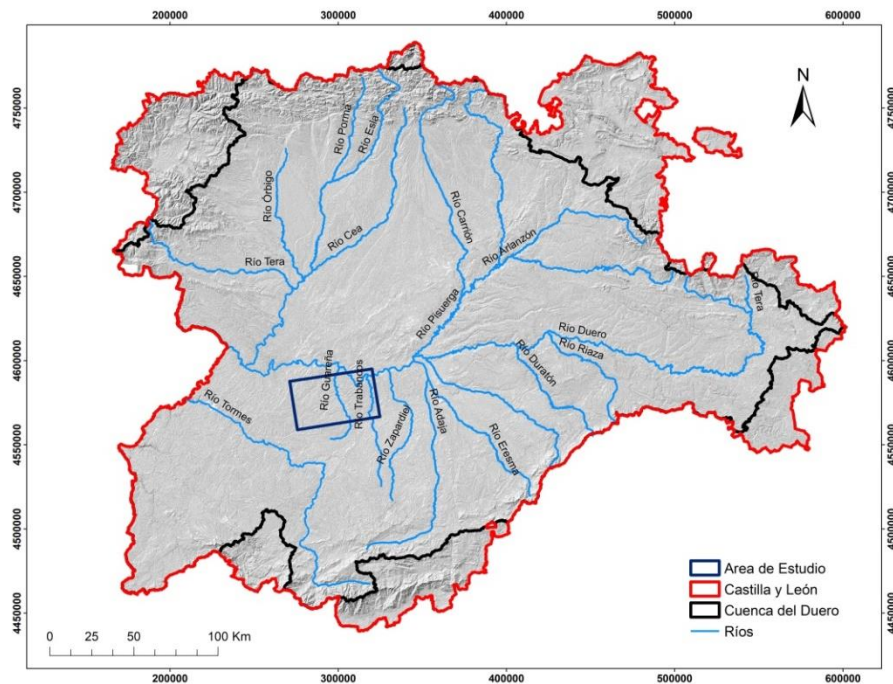
### 3.3. Características hidrológicas generales

Como resultado de la configuración morfológica y de las condiciones climáticas, se presenta una extensa red hidrográfica desde las cabeceras en las zonas de montaña hacia el río Duero, que discurre por el centro de la planicie sedimentaria en dirección este-oeste.

De este modo, la mayor parte de los ríos de la cuenca (Figura 3.8) tienen su origen en las sierras que la bordean y bajan al eje principal del Duero, que a lo largo de sus 744 km en la parte española, divide la cuenca en dos márgenes (derecha e izquierda). La margen derecha (o septentrional) con dos grandes subredes tributarias, la del Pisuega que incluye al Carrión y al Arlanza

con el Arlanzón, y la del Esla que se despliega en abanico para incluir a ríos como Tera, Órbigo, Porma y Cea. La margen izquierda (o meridional) incluye ríos de menor entidad que bajan desde el Sistema Central al Duero, como son Rianza, Duratón, Cega, Adaja con Eresma, Tormes y otros menores (Zapardiel, Trabancos, Guareña, etc.) (Nafría García et al., 2013).

A partir del sustrato litológico y su variedad depende también la presencia de formaciones acuíferas en la cuenca. Materiales silíceos – granitos, pizarras, cuarcitas – (Figuras 3.3-3.4) de las penillanuras occidentales y de las montañas del Sistema Central, y arcillas sedimentarias del interior de la cuenca, son altamente impermeables, por lo que difícilmente se producen infiltraciones que formen importantes masas de agua subterráneas. Esto contrasta con las zonas de calizas tanto paleozoicas como secundarias de la Cordillera Cantábrica y el Sistema Ibérico, y los páramos terciarios donde se producen filtraciones que dan lugar a sistemas de acuíferos, de los que se calcula que pueden acumular cerca de 1500 hm<sup>3</sup> anuales (Cabo and Manero, 1991). En estas zonas es donde se desarrollan las escasas zonas de cultivos de regadío, bien por cercanía a los ríos (Órbigo, Duero, entre otros) o bien por extracción de agua mediante pozos o sondeos desde los acuíferos.



**Figura 3.8.** Mapa de ríos de la cuenca del Duero. Fuente: Elaboración propia a partir de los datos de la Confederación Hidrográfica del Duero (CHD) (<https://www.chduero.es/>).

### 3.4. Edafología y coberturas del suelo

La cuenca del Duero muestra una apreciable diversidad edáfica (Figura 3.9). Esta diversidad está determinada fundamentalmente, por los formadores clima, acción antrópica, vegetación, litología y topografía (García-Rodríguez, 1993). En general, los suelos de la cuenca están afectados por tres procesos edáficos (García-Rodríguez et al., 1979): 1) iluviación; 2) rubefacción; y 3) hidromorfismo.

En el sur de la cuenca (parte del Sistema Central), las mayores extensiones de suelos corresponden a cambisoles y leptosoles. En los primeros, destacan las unidades de cambisol húmico, dístrico, eútrico y gleico; mientras que en los segundos, leptosoles úmbricos y líticos. Los cambisoles húmicos engloban los cambisoles forestales y, en algunos casos, los cubiertos de pastos. La vegetación clímax corresponde al rebollo (*Quercus pyrenaica*), aunque también es habitual encontrar bosques de castaños. Sobre cambisoles dístricos se pueden encontrar diversas especies de pinos (*Pinus L.*). Asociados a cambisoles y en áreas donde el suelo apenas tiene posibilidad de desarrollo, se encuentran leptosoles. Los leptosoles úmbricos se encuentran en zonas de alta montaña y se asocian a vegetación de matorral y pastizal (Figura 3.10).

En el extremo noroeste las unidades de suelo más representativas son leptosoles, cambisoles y gleysoles. Dentro de los cambisoles, la unidad más extensa corresponde a cambisoles dístricos, seguidos de húmicos y gleicos. Sobre los primeros se asientan bosques de rebollo (*Quercus pyrenaica*) y roble común (*Quercus robur*). En los montes del noroeste se encuentran grandes extensiones de matorrales y pastizales, desarrollándose estos últimos sobre todo en gleysoles móllicos y úmbricos.

Al norte y noreste de la cuenca (Cordillera Cantábrica) existen dos litologías claramente diferenciadas, que van a originar tipos de suelos distintos. En el sector occidental y sobre materiales ígneos se desarrollan cambisoles dístricos. Sobre materiales sedimentarios son más frecuentes los cambisoles eútricos y los leptosoles réndricos. En estos últimos y en llanuras al pie de las mismas se encuentran gleysoles móllicos, sobre todo en materiales calcáreos. Sobre los cambisoles se encuentra el haya (*Fagus sylvatica*), y en algunas zonas también aparecen junto a las hayas el roble albar (*Quercus petraea*) y el abedul (*Betula L.*). Debido a la degradación de los suelos en esta zona, el estrato arbóreo puede desaparecer, dan lugar a matorrales (brezales, escobonares, etc.) y pastos pobres. Por repoblación, también se pueden encontrar pinos silvestres (*Pinus sylvestris*) y pinos laricios (*Pinus nigra*).

Los suelos dominantes al este de la cuenca son los cambisoles y leptosoles, aunque aquí la variedad edáfica es mayor, con extensiones más amplias de luvisoles. La mayor parte de los suelos de esta zona son forestales, con presencia de hayas y pinos silvestres.

En la superficie de aplanamiento occidental y sobre materiales ígneos destaca la presencia de cambisoles dístricos, gleicos y húmicos, y cambisoles crómicos y eútricos sobre las rocas metamórficas. La degradación por sobrecultivo y posterior abandono del sistema adhesado facilita la regresión de los cambisoles (en muchos casos a leptosol), haciendo que aparezcan escobonares de papilionáceas (*Cytisus scoparius* y *Cytisus multiflorus*) y jarales (*Cistus ladanifer*).

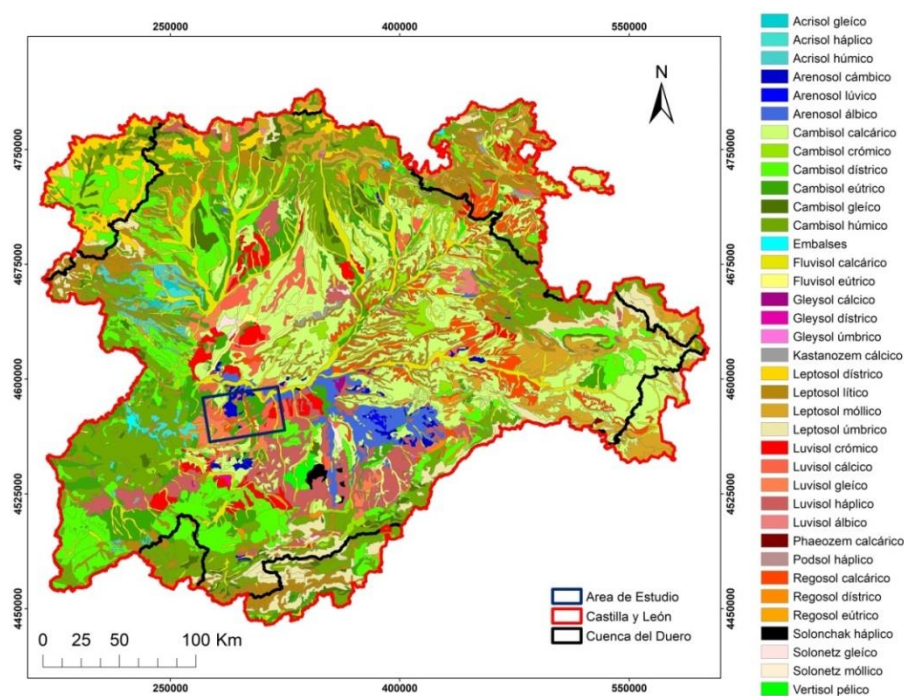


Figura 3.9. Mapa de suelos de Castilla y León. Fuente: Elaboración propia a partir de los datos del Atlas Agroclimático de Castilla y León (Nafría et al., 2013).

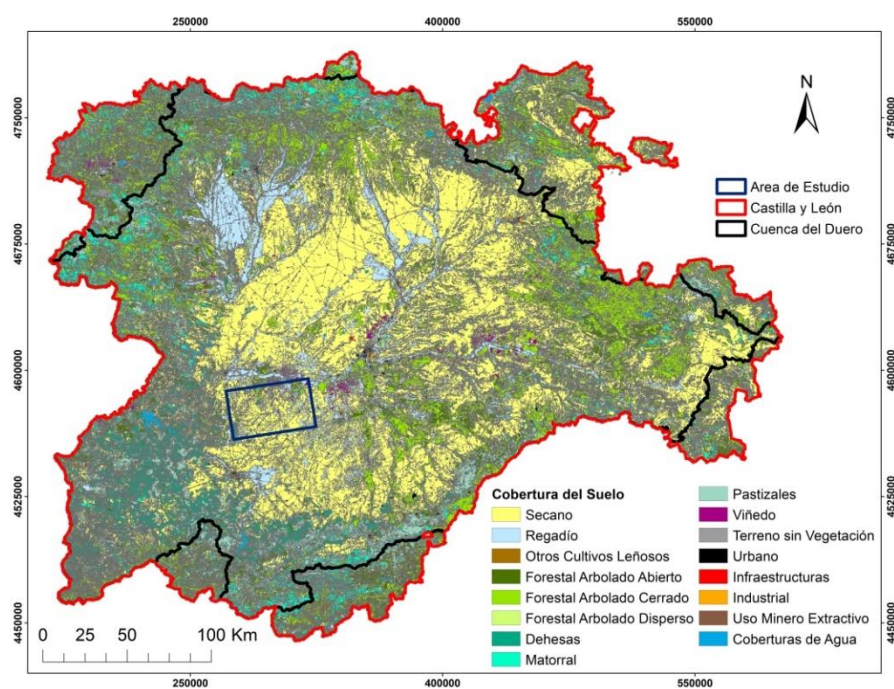


Figura 3.10. Mapa de coberturas de los suelos de Castilla y León, interpretación simplificada del Sistema de Información de Ocupación del Suelo en España (SIOSE). Fuente: Elaboración propia a partir de los datos del Atlas Agroclimático de Castilla y León (Nafría et al., 2013).

La superficie de las tierras de cultivo ocupa aproximadamente 3,6 millones de hectáreas, de las que un 75% se dedica a los cultivos herbáceos, un 2,5% a los cultivos leñosos y el resto a barbechos y tierras no ocupadas; mientras que el regadío supone alrededor de medio millón de hectáreas de la superficie cultivable (16%) (Nafría et al., 2013). Del total de la superficie dedicada a los cultivos herbáceos, los cereales para grano ocupan aproximadamente el 72%, destacando la cebada y el trigo (Nafría et al., 2013). La coincidencia de las altas temperaturas con la ausencia de las lluvias del verano da lugar a las condiciones de déficit hídrico condicionando a que la producción agrícola del interior de la cuenca sea predominantemente cerealista. Entre los cultivos herbáceos de regadío, el maíz es el más importante en superficie, seguido en relevancia por la remolacha azucarera y la patata. En cuanto a los cultivos leñosos, la vid representa un cultivo importante en la zona (Figura 3.10). Pese a esta aparente sencillez del cuadro de cultivos, la complejidad de la realidad agronómica es mucho mayor, ya que se está produciendo una búsqueda de cultivos adaptados al progresivo cambio climático y una especialización de las prácticas agrícolas para mejorar la producción. El objetivo de conseguir una clasificación de cultivos y coberturas en esta investigación parte de esta necesidad creciente de mapas detallados de usos y coberturas de suelo.



CAPÍTULO 4:  
MATERIALES Y MÉTODOS



## Capítulo 4: Materiales y Métodos

### 4.1. Campaña de campo para la estimación de parámetros de los cultivos

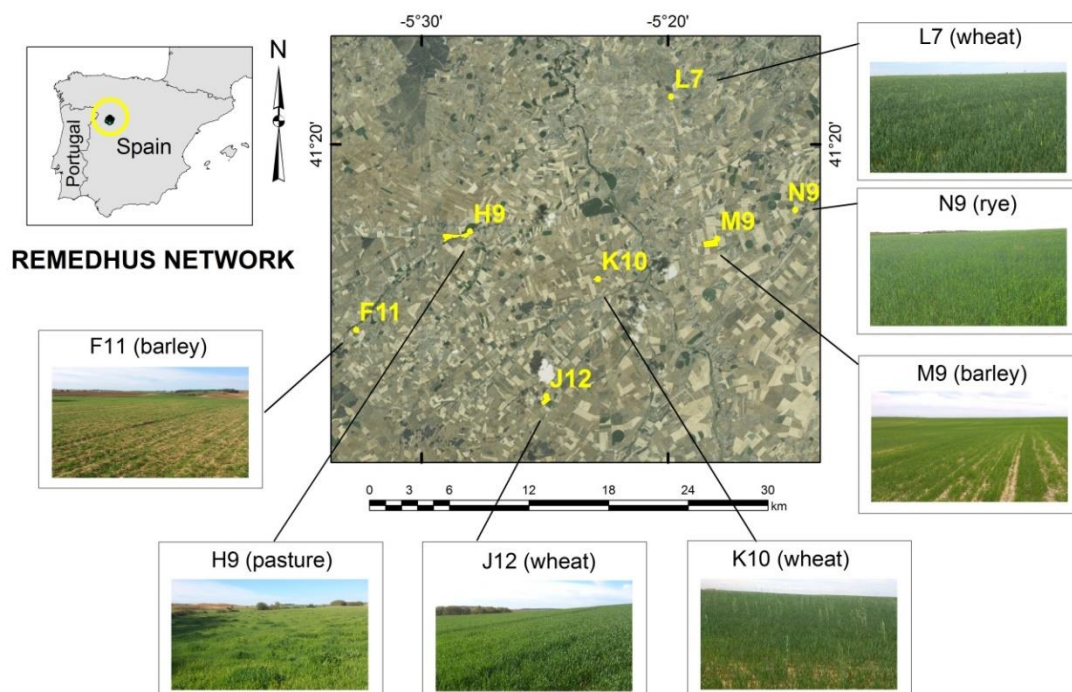
Uno de los objetivos expuesto en esta tesis trata de investigar la correlación existente entre los observables polarimétricos de las imágenes SAR y diferentes variables biofísicas. Para poder tener éxito en la consecución de este objetivo fue necesaria la realización de una campaña de campo para la estimación de las variables biofísicas. Los siguientes apartados desarrollan el diseño experimental que se llevó a cabo, así como las mediciones biofísicas para la estimación directa de las variables.

#### 4.1.1. Diseño experimental

Para demostrar la eficacia de las imágenes de radar, y particularmente para ampliar el conocimiento del empleo de observables polarimétricos en el seguimiento y estimación de los cultivos, se planteó una campaña de campo, la cual tuvo lugar en 2015 durante la temporada de crecimiento de cultivos de secano en un área agrícola en la parte central de la cuenca del Duero en España (Figura 4.1). En esta zona está implantada desde 1999 la Red de Estaciones de Medición de la Humedad del Suelo (REMEDHUS) de la Universidad de Salamanca) (Sánchez et al., 2012b), que sirvió de marco experimental para hacer las mediciones.

REMEDHUS proporciona rutinariamente la humedad del suelo y otros datos agroclimáticos que se han utilizado extensivamente tanto en aplicaciones de sensores remotos como de modelado hidrológico. Por esta razón, REMEDHUS es un área de validación para varios sensores pasivos de microondas (Colliander et al., 2017; González-Zamora et al., 2016). Además, también se han probado datos de sensores activos, desde los dispersómetros a bordo de los satélites de detección remota (ERS) y su sucesor, el dispersómetro avanzado (ASCAT, *Advanced Scatterometer*) (Brocca et al., 2011; Ceballos et al., 2005).

Las mediciones de campo para este experimento se realizaron en las parcelas correspondientes a 7 estaciones REMEDHUS; J12, K10 y L7 (trigo), F11 y M9 (cebada), N9 (centeno) y H9 (pasto natural) (Tabla 4.1), durante la temporada de crecimiento de los cultivos, es decir, de Febrero a Julio de 2015, cada quince días ( $n=9$ ) y se tomó una muestra promediada por parcela en un marco de 1 m<sup>2</sup>. La parcela de pasto (H9) es un área natural sin uso agrícola ni ganadero, se trata de una mezcla aleatoria de diferentes pastos.



**Figura 4.1.** Ubicación de las parcelas de campo y vista general de los diferentes tipos de vegetación. Fuente: Valcarce-Diñeiro et al. (2018).

**Tabla 4.1.** Características de las 7 estaciones de la red REMEDHUS empleadas en el estudio.

Nombre	Clave	Altitud (m)	Uso del Suelo	Textura (%)			Materia Orgánica (%)
				Arena	Limo	Arcilla	
Zamarrón	F11	851	Cereales de secano	81.52	11.97	6.51	0.82
Guarratino	H9	742	Forestal-Pradera	19.78	44.99	35.23	5.84
Eritas	J12	839	Cereales de secano	60.94	16.85	22.21	1.62
Carretoro	K10	742	Cereales de secano	91.16	5.71	3.13	0.27
Llanos	L7	802	Cereales de secano	46.80	20.78	32.42	3.31
Cruz Elías	M9	796	Cereales de secano	49.83	24.89	25.28	1.42
Concejo Mte.	N9	763	Cereales de secano	62.46	16.78	20.76	0.95

#### 4.1.2. Mediciones biofísicas

Para cada parcela anteriormente mencionada, se midió directamente la altura del dosel y se tomaron fotografías cenitales antes del muestreo. La altura del dosel se determinó como el promedio de la muestra de plantas individuales. Las etapas fenológicas de los cereales se establecieron de acuerdo

a un código decimal adoptado de Zadoks et al. (1974) (Tabla 4.2). Se utilizó la misma escala para el pasto.

**Tabla 4.2.** Etapas fenológicas.

Estados Fenológicos	Ciclo Vegetativo	Escala Zadoks
1. Germinado		Z0.0 a Z0.9
2. Pre-ahijamiento	Estado vegetativo	Z1.0 a Z1.9
3. Ahijamiento		Z2.0 a Z2.9
4. Encañado	Estado reproductivo	Z3.0 a Z4.9
5. Espigado		Z5.0 a Z5.9
6. Maduración (estado lechoso del grano)	Maduración	Z6.0 a Z8.9
7. Senescencia (endurecimiento del grano)	Senescencia	Z9.0 a Z9.9

Adaptado de Zadoks et al. (1974).

Posteriormente en el laboratorio, se estimó el LAI, el FVC, los pesos frescos y secos, el VWC y el porcentaje de contenido del agua (PWC, *Percentage Water Content*). Estos parámetros se han utilizado con frecuencia en la literatura relacionada de estimaciones sobre la vegetación para aplicaciones de teledetección (Jackson et al., 2004; Jiang et al., 2006). Los protocolos de medición siguen las pautas de Sánchez et al. (2012a) y se describen a continuación.



**Figura 4.2.** Escaneo de muestras para estimar el LAI a partir del software *ImageJ*.

El índice de área foliar relaciona la superficie que ocupan las hojas (verdes) de las plantas sobre 1 m<sup>2</sup> de suelo, y es un parámetro muy útil para analizar el desarrollo de los cultivos. El LAI verde

se estimó mediante un método destructivo en el que se extrajeron hojas fotosintéticamente activas de la muestra, que luego se escanearon y escalaron para recuperar el valor del área empleando el software libre *ImageJ* (Abràmoff et al., 2004) (Figura 4.2).

El peso fresco (Ecuación 4.3) se estimó pesando la muestra *in situ*. Posteriormente, la muestra se secó hasta alcanzar un peso constante en un horno a 70° C durante al menos 24 h. El VWC se estimó como la diferencia entre los pesos secos y húmedos (Ecuación 4.1), considerando la cantidad total de agua en los tallos y las hojas.

El VWC es una variable de entrada importante para estimar la humedad del suelo (Kim et al., 2014) y determinar el estrés hídrico. La retrodispersión de microondas de las superficies con vegetación está influenciada por la estructura de la vegetación y el VWC, los cuales varían con las condiciones meteorológicas y la humedad en la zona de la raíz (Van Emmerik et al., 2015). Además se consideró el PWC como la relación (en %) entre el VWC y el peso fresco (Ecuación 4.2).

$$VWC (g/m^2) = (peso_{fresco} - peso_{seco}) * 8 \quad (4.1)$$

$$PWC (\%) = \frac{VWC}{peso_{fresco}} * 100 \quad (4.2)$$


$$Biomasa fresca (g/m^2) = peso_{fresco} * 8 \quad (4.3)$$



**Figura 4.3.** Marco de medición empleado para la extracción de las muestras.

Hay que tener en cuenta que el marco de medición empleado en campo para la extracción de las muestras es  $1/8$  de  $m^2$  ( $0,125 m^2$ ) (Figura 4.3). Por lo tanto, para la estimación en  $m^2$  de ciertas variables biofísicas es necesario multiplicar por 8.

Finalmente, el FVC se estimó a partir de las fotografías digitales siguiendo el procedimiento de Calera et al. (2001). El porcentaje de cobertura de vegetación verde y seca se extrajo del suelo desnudo mediante un procedimiento de clasificación supervisada en *PCI Geomatica 10.1* (Figura 4.4).



**Figura 4.4.** Izquierda: Fotografía digital tomada en campo. Derecha: Clasificación supervisada a partir de las fotografías digitales.

Para obtener los datos de humedad del suelo, se emplearon las estaciones automáticas de medición de la humedad del suelo de la red REMEDHUS coincidiendo con la fecha y la hora de las mediciones. Las estaciones de humedad del suelo cuentan con sondas de capacitancia (*Hydra Probes Soil Sensors, Stevens® Water Monitoring System Inc.*) instaladas a una profundidad de 5 cm en cada parcela para el propósito de esta tesis.

Estas sondas fueron previamente calibradas y miden la humedad del suelo con una precisión de  $\pm 0,003 m^3m^{-3}$ . Estas sondas fueron instaladas horizontalmente en la pared inalterada del perfil y paralelas a la dirección de la máxima pendiente de la ladera. El contenido de humedad del suelo se registra cada hora en un recolector de datos (*datalogger CR200, Campbell Scientific*) y la información es recibida vía modem en un servidor mediante un sistema de transmisión remoto de datos (*módems General Packet Radio Service, GPRS*).

## 4.2. Mapa de referencia para la clasificación

Uno de los objetivos planteados se basa en emplear parámetros obtenidos a partir de las imágenes de radar para clasificar y distinguir cultivos agrícolas. Para llevar a cabo este objetivo es necesario el uso de un mapa de referencia para entrenar el modelo y evaluar la precisión de la

clasificación resultante. Esto se realizó empleando un mapa de uso/cobertura de suelos (LU/LC) de toda la región de Castilla y León de 2015 como la verdad terreno de la LU/LC para cada parcela.

El servicio de mapas del ITACyL (<http://mcsncyl.itacyl.es/en/descarga>) actualiza anualmente desde 2011 los mapas LU/LC. Estos mapas se basan en la clasificación de imágenes ópticas satelitales (Landsat 8, Deimos 1 y 2 y Sentinel-2) y representan los cambios anuales en los cultivos herbáceos, así como los cultivos permanentes y las áreas de vegetación natural. Su resolución espacial es de 20 m. La precisión general de la clasificación de estos mapas es del 82% en promedio (coeficiente *kappa* de alrededor de 0,78), que es mucho mayor para las categorías de cultivos que para las tierras naturales (Nafría et al., 2017).

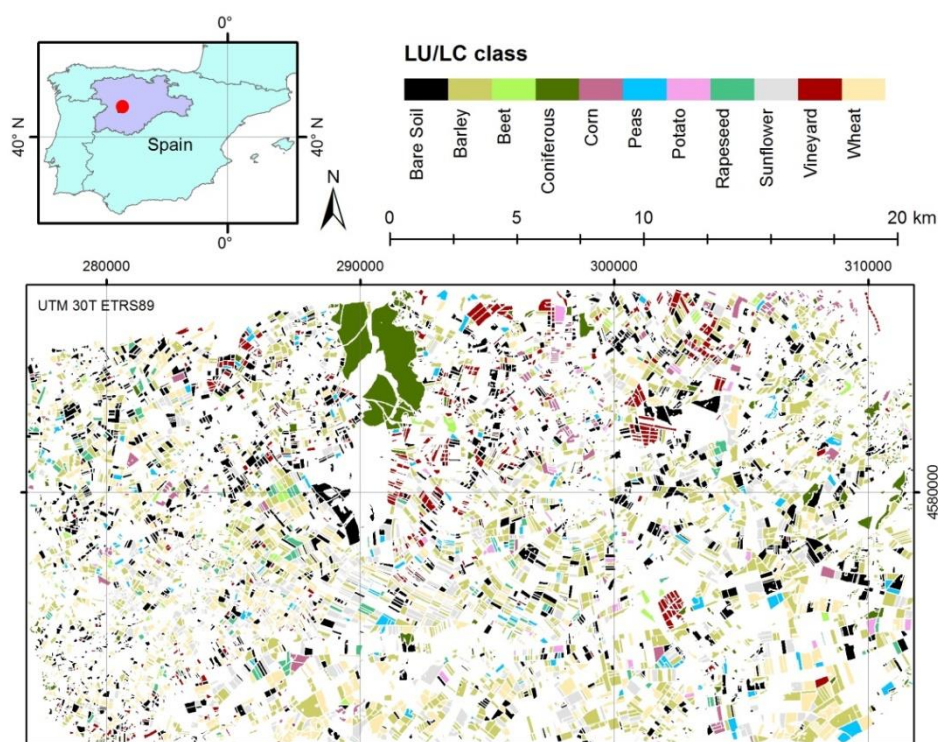
Basándose en el mapa LU/LC para 2015 y los estudios de campo, los cultivos seleccionados para clasificar fueron: trigo (*Triticum aestivum* L.), girasol (*Helianthus annuus* L.), cebada (*Hordeum vulgare* L.), guisantes (*Pisum sativum* L.), colza (*Brassica napus* L.), maíz (*Zea mays* L.), remolacha (*Beta vulgaris* L.), patatas (*Solanum tuberosum* L.), viñedo (*Vitis vinifera*) y otras dos cubiertas: suelo desnudo y conífera. La temporada de crecimiento de estos cultivos se puede agrupar en dos grupos: ciclo largo, desde otoño hasta el final de la primavera (trigo, cebada, guisantes y colza) y ciclo corto, desde la primavera hasta el comienzo del otoño (girasol, maíz, remolacha y patatas). Viñedo y coníferas son cubiertas permanentes.

La Tabla 4.3 muestra el número de parcelas (7580 en total) y su área promedio; su distribución geográfica se muestra en la Figura 4.5. Para fines de clasificación, se seleccionaron aleatoriamente el 60% de las parcelas como datos de entrenamiento y el 40% como datos de validación. Antes de la clasificación y para evitar seleccionar píxeles de entrenamiento de los límites del campo, se realizó un buffer de 20 m hacia adentro a las parcelas del conjunto de datos de entrenamiento, siguiendo el enfoque de Sonobe et al. (2015).

**Tabla 4.3.** Descripción general de la verdad-terreno para la clasificación.

Tipo de cultivo	Numero de parcelas	Área total (ha)	Área media de las parcelas (ha)
Trigo	967	3994,86	4,13
Cebada	1914	7422,48	3,88
Girasol	897	3717,53	4,14
Colza	165	614,92	3,73
Guisante	206	849,48	4,12
Maíz	142	632,80	4,46
Remolacha	90	310,65	3,45
Patata	57	271,24	4,76
Viñedo	788	1763,29	2,24
Coníferas	401	1843,09	4,60
Suelo desnudo	1953	6170,19	3,16





**Figura 4.5.** Parcelas seleccionadas, indicando el mapa de usos/coberturas del suelo (LU/LC). Fuente: Valcarce-Diñeiro et al. (2019).

### 4.3. Imágenes de radar

Se utilizaron imágenes de los satélites RADARSAT-2 y Sentinel-1. RADARSAT-2, lanzado por la Agencia Espacial Canadiense (CSA) y *MacDonald, Dettwiler and Associates Ltd.* (MDA) en Diciembre de 2007. Tiene un sensor SAR de banda C (5,405 GHz), con un ciclo de repetición de órbita de 24 días, pero sus diferentes modos de haz permiten una revisión más frecuente. Sentinel-1A es el primero de los dos satélites Sentinel-1. Fue lanzado en Abril de 2014 por la ESA. Opera en la misma banda que el RADARSAT-2, tiene un ciclo de repetición de órbita de 12 días, y cuatro modos operativos diferentes: *Interferometric Wide Swath* (IW), *Wave* (WV), *Stripmap* (SM\_Sentinel) y *Extra Wide Swath* (EW). Todos los modos están disponibles en polarización simple (HH o VV) o dual (HH y HV o VV y VH), excepto WV, que está disponible solo en polarización simple (Torres et al., 2012).

Para evaluar la influencia del ángulo de incidencia se adquirieron tres conjuntos de imágenes *Fine Quad-Pol* RADARSAT-2 *Single Look Complex* (SLC) con ángulos de incidencia promedio de 25°, 31° y 36° (Tabla 4.5). La selección del modo *Fine Quad-Pol* se debe a que proporciona una alta resolución espacial y a la capacidad de poder extraer observables polarimétricos. En total se adquirieron veinte imágenes sobre el área de estudio entre Febrero y Julio de 2015. Estas imágenes se

pueden agrupar en tres series, que comprenden 7 imágenes a 36°, 7 a 31° y 6 a 25° (Tabla 4.4). De Sentinel-1A, se emplearon imágenes IW de nivel 1, alta resolución, GRD (*Ground Range Detected*) y doble polarización (VV y VH). De acuerdo con las especificaciones del producto, los productos GRD de nivel 1 ya están proyectados en el rango del terreno utilizando un modelo de elipsoide terrestre. En las Tablas 4.4 y 4.5, se muestra información básica sobre las imágenes de RADARSAT-2 y Sentinel-1A, así como una lista de los datos de adquisición disponibles.

**Tabla 4.4.** Lista de imágenes RADARSAT-2 y Sentinel-1A IW GRD.

RADARSAT-2				Sentinel-1A			
Fecha de Adquisición	Día del Año (DoY)	Modo del Haz	Media del Ángulo de Incidencia (°)	Mediciones de Campo	Fecha de Adquisición	Día del Año (DoY)	Modo del Haz
16-02-2015	47	FQ16W	36		13-02-2015	44	IW
23-02-2015	54	FQ11W	31	17-02-2015	25-02-2015	56	IW
12-03-2015	71	FQ16W	36	03-03-2015	09-03-2015	68	IW
19-03-2015	78	FQ11W	31	19-03-2015	21-03-2015	80	IW
26-03-2015	85	FQ6W	25		02-04-2015	92	IW
05-04-2015	95	FQ16W	36		26-04-2015	116	IW
12-04-2015	102	FQ11W	31	08-04-2015	08-05-2015	128	IW
19-04-2015	109	FQ6W	25		20-05-2015	140	IW
29-04-2015	119	FQ16W	36	21-04-2015	01-06-2015	152	IW
06-05-2015	126	FQ11W	31	06-05-2015	13-06-2015	164	IW
13-05-2015	133	FQ6W	25		25-06-2015	176	IW
23-05-2015	143	FQ16W	36	19-05-2015	07-07-2015	188	IW
30-05-2015	150	FQ11W	31		19-07-2015	200	IW
06-06-2015	157	FQ6W	25	02-06-2015	31-07-2015	212	IW
16-06-2015	167	FQ16W	36	16-06-2015			
23-06-2015	174	FQ11W	31				
30-06-2015	181	FQ6W	25				
10-07-2015	191	FQ16W	36				
17-07-2015	198	FQ11W	31				
24-07-2015	205	FQ6W	25				

Tabla 4.5. Características del RADARSAT-2 y Sentinel-1A.

RADARSAT-2					
Modo del haz	Ángulo de incidencia promedio (°)	Orbita	Tiempo de adquisición (UTC)	Espaciado del píxel (m) (slant-range)	Espaciado de píxel (m) (azimut)
FQ16W	36,2	Ascendente	18:16	4,73	5,49
FQ11W	31,1		18:12		4,61
FQ6W	25,4		18:08		4,70
Sentinel-1A					
Modo del haz	Rango del ángulo de incidencia (°)	Orbita	Resolución (m) (rango x azimut)	Espaciado del píxel (m) (rango x azimut)	Numero de vistas
IW	29,1 - 46	Descendente	20 x 22	10 x 10	5 x 1

## 4.4. Métodos

### 4.4.1. Pre-procesamiento de los datos SAR

#### 4.4.1.1. RADARSAT-2

El procesamiento de las imágenes se llevó a cabo usando el software libre SNAP (*Sentinel Application Platform*, <http://step.esa.int/main/toolboxes/snap/>) desarrollado por la Agencia Espacial Europea. La Figura 4.6 refleja el flujo de trabajo para el tratamiento de datos.

Las imágenes RADARSAT-2 son proporcionadas con una calibración radiométrica ya aplicada, por lo que únicamente se empleó la tabla de consulta (LUT, *Look-Up-Table*) para convertirlas radiométricamente para representar los coeficientes de retrodispersión. A continuación se generó la matriz de coherencia polarimétrica (Cloude and Pottier, 1996). Una justificación más detallada sobre esta matriz se describe en el Capítulo 2.

Las imágenes SAR muestran un ruido granular característico, que es inherente a todo tipo de sistemas de imágenes que operan en longitudes de onda más pequeñas que la resolución espacial. Este fenómeno se conoce como moteado, y es una consecuencia de la interferencia de las señales recibidas de dispersores ubicados de manera diferente dentro de la celda de resolución (Goodman, 1976). Como no se conoce la estructura detallada dentro de cada celda de resolución, las propiedades del fenómeno del moteado se describen estadísticamente (Goodman, 1976). Este fenómeno puede modelarse mediante un modelo de ruido multiplicativo (Lee and Pottier, 2009) y reducirse mediante *multi-looking* o técnicas de filtrado para mejorar la resolución radiométrica (Lee and Pottier, 2009).

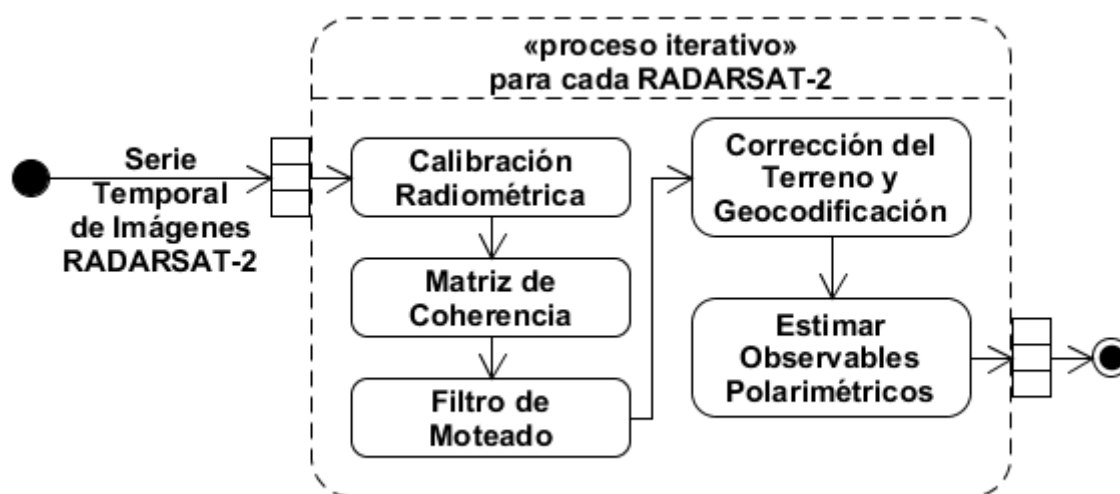


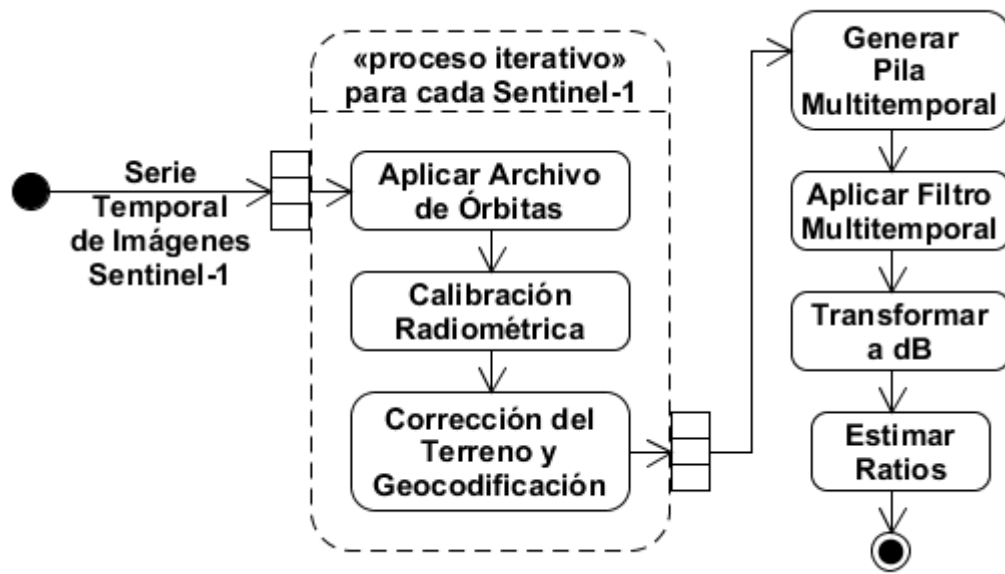
Figura 4.6. Diagrama de flujo del procesamiento SAR. Fuente: Elaboración propia.

Para el procesamiento de las imágenes RADARSAT-2 se empleó un filtro *boxcar* de 9 x 9. Lo que hace es reemplazar el pixel central en una ventana móvil de tamaño 9 x 9 o mayor con el promedio de píxeles en dicha ventana. Este filtro tiene las siguientes ventajas: 1) es fácil de aplicar; 2) es eficaz en la reducción del ruido de moteado en áreas homogéneas, y 3) preserva el valor medio. Según el documento de especificaciones técnicas de las imágenes RADARSAT-2, el número equivalente de vistas proporcionado por dicho filtrado (9 x 9) es superior a 48, que es lo suficientemente grande como para obtener una estimación fiable de todos los observables polarimétricos en el análisis posterior. Para los parámetros derivados de la descomposición en valores propios de la matriz de coherencia, se sabe que el número de vistas necesarias puede ser mayor de 48 (Lee et al., 2008), pero no se encontraron diferencias significativas cuando el tamaño de la ventana se incrementó por encima de 9 x 9. Por lo tanto, se empleó el mismo tamaño de ventana para todos los parámetros.

Generalmente las distancias en las imágenes SAR se pueden distorsionar debido a las variaciones topográficas de una escena y la inclinación del sensor del satélite. Las correcciones del terreno están destinadas a compensar estas distorsiones para que la representación geométrica de la imagen sea lo más cercana al mundo real. El método de ortorrectificación (*Range Doppler*) disponible en SNAP se aplicó para la corrección del terreno y la geocodificación, utilizando el modelo digital de elevaciones del SRTM (*Shuttle Radar Topographic Mission*). El espaciado final de las imágenes geocodificadas fue de 5 m. Antes de estimar los observables SAR a nivel de campo, se llevó a cabo una erosión de 5 píxeles en todos los campos para evitar la influencia de los bordes de las parcelas adyacentes, ya que el filtro anteriormente mencionado difumina los bordes de las parcelas y mezcla las respuestas del exterior de la parcela con las partes internas. La implementación de este proceso se realizó mediante la concatenación de diferentes funciones de MATLAB (<https://mathworks.com/products/matlab.html>).

#### 4.4.1.2. Sentinel-1

Al igual que para el procesamiento de las imágenes del RADARSAT-2, el software empleado para el procesamiento de las imágenes del Sentinel-1 fue también el SNAP. Los pasos llevados a cabo se muestran en la Figura 4.7. A continuación se detalla brevemente cada uno de los pasos involucrados en el proceso.



**Figura 4.7.** Cadena de procesamiento de las imágenes Sentinel-1. Fuente: Elaboración propia.

Los vectores de estado orbital, proporcionados por los productos SAR en sus metadatos, generalmente no son precisos. Las órbitas precisas de los satélites se determinan después de varios días y están disponibles de días a semanas después de la generación del producto. El empleo de archivos de efemérides de órbitas precisas permite actualizar los vectores de estado orbital en los metadatos del producto, proporcionando una información precisa de la posición y velocidad del satélite. Por ello, para una mejor precisión de geolocalización se recomienda utilizar archivos de órbitas precisas (Schubert et al., 2015).

La calibración es el procedimiento por el cual se obtienen imágenes en las que los valores de los píxeles se puedan relacionar directamente con la retrodispersión del radar de la escena. Las imágenes de nivel 1 (aplicadas en esta tesis) proporcionan cuatro tablas de consulta (LUT) para obtener *sigma nought* ( $\sigma^0$ ), *beta nought* ( $\beta^0$ ), *gamma nought* ( $\gamma^0$ ) o recuperar el número digital.

Además estas tablas aplican un desplazamiento constante y una ganancia dependiente del rango, incluida la constante de calibración absoluta.

Para convertir el número digital de un pixel en una imagen de Sentinel-1 SAR a un valor calibrado radiométricamente, se debe aplicar la Ecuación 4.4 (Piantanida et al., 2016).

$$value(i) = \frac{|DN_i|^2}{A_i^2} \quad (4.4)$$

donde, dependiendo de la tabla de consulta seleccionada:

$$value(i) : \beta_i^0, \sigma_i^0, \gamma_i^0 \text{ o } DN_i^{orig}$$

$$A_i : lutBeta0(i), lutSigma0(i), lutGamma0(i) \text{ o } lutDN(i)$$

En este caso la calibración radiométrica se llevó a cabo para obtener el coeficiente de retrodispersión *sigma nought* ( $\sigma^0$ ).

El siguiente paso en el procesamiento de las imágenes fue aplicar el método de ortorectificación (*Range Doppler*) disponible en SNAP para la corrección del terreno y la geocodificación, utilizando el modelo digital de elevaciones del SRTM.

Una vez que todas las imágenes fueron geocodificadas se generó una pila temporal para superponer espacialmente todos los productos empleando la primera imagen de la serie temporal como maestra y el resto como esclavas. Esto quiere decir que los valores de los píxeles de un producto (esclavo) se re-muestra nuevamente en el ráster geográfico del otro (maestro).

Dentro del filtrado multitemporal, además de la consideración de un filtro de moteado específico, se introduce un filtro de ponderación óptimo para equilibrar las diferencias en la reflectividad entre imágenes en diferentes momentos temporales. Debe señalarse que el filtrado multitemporal se basa en la suposición de que el mismo elemento de resolución en el suelo está iluminado por el haz del radar de la misma manera y se corresponde con las mismas coordenadas en el plano de la imagen en todas las imágenes de la serie temporal. La reflectividad puede cambiar de vez en cuando debido a un cambio en las propiedades dieléctricas y geométricas de las dispersiones elementales, pero no debe cambiar debido a una posición diferente del elemento de resolución con respecto al radar. Por lo tanto, la ventaja del filtrado multitemporal es que se reduce el moteado de las imágenes sin degradar la resolución espacial. Para el procesamiento de las imágenes de Sentinel-1 se aplicó un filtro *boxcar* de 7 x 7.

Finalmente se llevó a cabo la transformación de los coeficientes de retrodispersión (VV y VH) corregidos por el terreno a dB y se estimó el ratio entre ambos canales.

### 4.4.2. Estimación de los observables polarimétricos

Los datos SAR completamente polarimétricos provenientes del satélite RADARSAT-2 proporcionan más información en comparación con los datos polarimétricos dual (Sentinel-1), ya que la información polarimétrica se registra en las bandas HH, VV, HV y VH. En total, se han extraído diez observables polarímetros de las imágenes de RADARSAT-2 a partir de las matrices de covarianza y coherencia, y métodos de descomposición polarimétrica. Siete de los diez observables polarimétricos (Tabla 4.6) extraídos se calcularon a partir de la matriz de covarianza. Todos los parámetros se obtuvieron utilizando el software libre PolSARpro (*Polarimetric SAR data Processing and Education Toolbox*) (<https://earth.esa.int/web/polsarpro>) proporcionado por la ESA. Los símbolos que se usan a continuación para definir los parámetros se muestran en la Tabla 4.6.

El primer grupo de observables seleccionados corresponde a los que pueden obtenerse directamente de la matriz de covarianza polarimétrica  $C$ , que se deriva de los datos recopilados en la base lineal (polarizaciones horizontal y vertical) y organizados utilizando la base lexicográfica (Cloude and Pottier, 1996). Estos observables son los coeficientes y ratios de retrodispersión, obtenidos de la diagonal de la matriz de covarianza  $C$ , y las correlaciones entre canales (es decir, las amplitudes y fases) obtenidas del resto de las entradas de la matriz  $C$ . La expresión matemática de estos observables es la siguiente (ver la Tabla 4.6 para la notación empleada en esta tesis doctoral):

$$\sigma_{HH}^0 = 10 \log_{10}(C(1,1)) \quad (4.5)$$

$$\sigma_{HV}^0 = 10 \log_{10}(C(2,2)) \quad (4.6)$$

$$\sigma_{VV}^0 = 10 \log_{10}(C(3,3)) \quad (4.7)$$

$$HH/VV = 10 \log_{10}(C(1,1)/C(3,3)) \quad (4.8)$$

$$HV/VV = 10 \log_{10}(C(2,2)/C(3,3)) \quad (4.9)$$

$$\gamma_{HHVV} = C(1,3)/\text{sqrt}(C(1,1) \times C(3,3)) \quad (4.10)$$

$$PPD = \text{arg}(C(1,3)) \quad (4.11)$$

$$\gamma_{P1P2} = T(1,2)/\text{sqrt}(T(1,1) \times T(2,2)) \quad (4.12)$$

Es importante tener en cuenta que las correlaciones entre el canal de polarización cruzada y los canales copolares, es decir,  $\gamma_{HHHV}$  y  $\gamma_{HVVV}$ , no se consideran en el estudio porque para las superficies naturales son muy pequeños debido a la simetría de reflexión (Cloude and Pottier, 1996). El ángulo alfa dominante ( $\alpha_1$ ) y la entropía (H) también se probaron porque son ampliamente utilizados en la literatura sobre polarimetría SAR y proporciona una interpretación física clara de los datos. Además, dado que se extraen de la descomposición de los valores propios de la matriz de coherencia, explotan el espacio de observación polarimétrico completo. Finalmente, se añadió la coherencia entre los dos primeros canales de Pauli porque fue útil en un estudio previo sobre el arroz (Lopez-Sanchez et al.,

2014). Para obtener este último parámetro, los datos se expresan en la base de Pauli, lo que proporciona canales con una clara interpretación física. Parámetros adicionales, como el nivel de retrodispersión en la base de Pauli o las salidas de descomposiciones basadas en modelos (Freeman and Durden, 1998), no se incluyen en la presente tesis para limitar su longitud y el número final de resultados. En la misma línea, podrían realizarse análisis adicionales cambiando la base polarimétrica (por ejemplo, polarizaciones circulares) o seleccionando modos de medición específica (por ejemplo, polarimetría compacta). Todas estas opciones son una línea futura de investigación.

**Tabla 4.6.** Lista de observables polarimétricos.

Observable polarimétrico	Símbolo
Coeficiente de retrodispersión en los canales HH, HV y VV	HH, HV, VV
Ratio de los coeficientes de retrodispersión en los canales HH, HV y VV	HH/VV, HV/VV
Correlación normalizada (coherencia) entre los canales copolares (HH y VV)	$\gamma_{HHVV}$
Diferencia de fase de polarización entre los canales copolares (HH y VV)	PPD
Entropía y ángulo dominante alfa (a partir de los eigen vectores de la matriz de coherencia)	H, $\alpha_1$
Correlación normalizada (coherencia) entre los dos primeros canales en la base de Pauli (HH+VV y HH-VV)	$\gamma_{P1P2}$

### 4.4.3. Métodos para la estimación de parámetros biofísicos

#### 4.4.3.1. Interpolación temporal de los datos *in situ*

La interpolación se llevó a cabo para hacer coincidir las fechas de adquisición de las mediciones *in situ* con los datos satelitales (Tabla 4.4), lo que se conoce como interpolación temporal. Obviamente, el desajuste entre las mediciones de campo y las fechas de adquisición de imágenes puede ser una fuente de incertidumbre en las correlaciones, especialmente cuando los datos *in situ* muestran cambios de tendencia o cambios rápidos.

Los métodos fundamentales de interpolación se presentan en Scherer (2013) y Stoer and Bulirsch (2002), sin embargo, la intención de esta sección es presentar una visión general del método de interpolación empleado.

Cuando se diseña un experimento generalmente se producen un conjunto discreto de puntos de datos  $(x_i, f_i)$  que representan el valor de una función  $f(x)$  para un conjunto finito de argumentos  $\{x_0 \dots x_n\}$ . Si es necesario obtener puntos de datos adicionales, por ejemplo, para dibujar una curva continua, es necesaria la interpolación.



La interpolación es un método para construir nuevos puntos de datos, dentro del rango de un conjunto discreto de puntos de datos conocidos. Es un método importante para aplicaciones como el procesamiento de señales, de imágenes y visualización de datos. Los datos medidos pueden ajustarse mediante una línea discontinua o una curva más suave. Las funciones de interpolación más importantes son polinomios, splines y funciones racionales.

Considerando que se dan  $n + 1$  puntos de muestra  $(x_i, f_i)$ ,  $i = 0 \dots n$  y una función de  $x$  que depende de  $n + 1$  parámetros  $a_i$  (Ecuación 4.13).

$$\Phi(x; a_0 \dots a_n) \quad (4.13)$$

Los parámetros deben determinarse de manera que la función de interpolación tenga los valores adecuados en todos los puntos de la muestra (Ecuación 4.14).

$$\Phi(x_i; a_0 \dots a_n) = f_i \quad i = 0 \dots n \quad (4.14)$$

Un problema de interpolación se llama lineal si la función de interpolación es una combinación lineal de funciones (Ecuación 4.15).

$$\Phi(x; a_0 \dots a_n) = a_0 \Phi_0(x) + a_1 \Phi_1(x) + \dots + a_n \Phi_n(x) \quad (4.15)$$

Ejemplos importantes son polinomios, funciones trigonométricas o funciones spline, que son polinomios por partes, por ejemplo la spline cúbica. Para el desarrollo de la tesis se empleó una interpolación spline cubica que se da en el intervalo  $x_i \leq x \leq x_{i+1}$  (Ecuación 4.16).

$$s(x) = \alpha_i + \beta_i(x - x_i) + \gamma_i(x - x_i)^2 + \delta_i(x - x_i)^3 \quad (4.16)$$

La interpolación de los datos se realizó empleando el software matemático MATLAB (<https://mathworks.com/products/matlab.html>), el cual proporciona un algoritmo spline que realiza una interpolación cubica.

#### **4.4.3.2. Análisis de correlación terreno vs. imágenes**

Uno de los objetivos es la investigación del efecto del ángulo de incidencia entre los parámetros obtenidos de las imágenes SAR y diferentes variables biofísicas, para ello se realizó un análisis de correlación. El análisis de correlación es un método estadístico utilizado para evaluar la fuerza de la relación entre dos variables cuantitativas. Una relación alta significa que dos o más variables tienen una relación fuerte entre sí, mientras que una correlación débil significa que las variables apenas están relacionadas.

El coeficiente de correlación  $r$ , también llamado coeficiente de correlación producto-momento de Pearson, mide la relación lineal entre dos variables continuas (Press et al., 2007). Siendo  $x$  e  $y$  las medidas cuantitativas de dos variables aleatorias en la misma muestra de  $n$ . La fórmula para calcular el coeficiente de correlación  $r$  de Pearson se obtiene a partir de la Ecuación 4.17.

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4.17)$$

donde

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (4.18)$$

y

$$\bar{y} = \frac{1}{n} \sum_{j=1}^n y_j \quad (4.19)$$

son las medias de las variables  $x$  e  $y$  (Ecuaciones 4.18 y 4.19).

El coeficiente de correlación de Pearson  $r$  varía entre -1 y +1. Si la correlación lineal entre  $x$  e  $y$  es positiva ( $r > 0$ ) indica que los niveles más altos de una variable están asociados con los niveles más altos de la otras, mientras que si la correlación lineal entre  $x$  e  $y$  es negativa ( $r < 0$ ), expresa que los niveles más altos de una variable están asociados con los niveles más bajos de la otra.

Cuando  $r = 0$ , hay una ausencia de cualquier asociación (positiva o negativa) entre las variables  $x$  e  $y$ . Si el coeficiente de correlación es igual a +1, las variables tienen una correlación positiva lineal perfecta. Esto quiere decir que si una variable aumenta, la segunda aumenta proporcionalmente en la misma dirección (el signo del coeficiente indica la dirección de la asociación). Sin embargo, si el coeficiente es igual a -1, las variables están perfectamente correlacionadas negativamente y se mueven en oposición entre sí, es decir, si una variable aumenta la otra disminuye proporcionalmente. Si el valor de  $r$  es cero, no existe relación entre las variables.


El número de muestras utilizadas para calcular el valor  $r$  fue de 9. La significación estadística se evaluó a un nivel de confianza del 95%. Se utilizó un  $p$ -valor = 0.05 de nivel de confianza en todos los casos. Se reconoce que el conjunto de datos empleado es pequeño, pero es lo suficientemente robusto como para garantizar este nivel de importancia. Para una mejor comprensión de los resultados de las correlaciones en el Capítulo 5, se establecieron diferentes umbrales para clasificar  $r$ : moderado (+/- 0.66 a 0.75), alto (+/- 0.75 a 0.85) y muy alto (+/- 0.85 a 1). Se empleó el software matemático MATLAB (<https://mathworks.com/products/matlab.html>) para realizar el análisis de correlación.

#### 4.4.4. Métodos de clasificación: árboles de decisión

Un árbol de decisión expresa los patrones que existen en un conjunto de datos, a partir de una estructura de árbol similar a un diagrama de flujo. Cada ruta del diagrama de flujo representa una regla lógica que se puede utilizar para extraer información de la base de datos. Los árboles de decisión son métodos no paramétricos muy eficientes que pueden usarse tanto para clasificación (árbol de clasificación) como para regresión. En esta tesis, los árboles de decisión se utilizaron para clasificación. A diferencia de algunos clasificadores como redes neuronales artificiales (*Artificial Neural Networks*, ANN) o SVM, los árboles de decisión son fácilmente aplicables tanto en datos categóricos como numéricos que aumentan aún más su dominio de aplicación.

La inducción de un árbol de decisión comienza seleccionando un atributo sin clase  $A_i$  para dividir un conjunto de datos de entrenamiento  $D$  en un conjunto separado de particiones horizontales (Han et al., 2012; Quinlan, 1992). El propósito de esta división es crear una distribución más pura de los valores de la clase en las particiones siguientes que la distribución en  $D$ . La pureza de la distribución de clases en las particiones siguientes se verifica para todos los atributos no pertenecientes a la clase y el atributo que proporciona una distribución de clase más pura que otros se selecciona como el atributo de división. El proceso de selección del atributo de división continúa de forma recursiva en cada partición posterior  $D_i$  hasta que cada partición obtiene la distribución de clase más pura o se cumple un criterio de detención. Por distribución de clase más pura se entiende la presencia de un único valor de clase para todos los registros. Mientras que un ejemplo de criterio de detención puede ser el número mínimo de registros que debe contener una partición; lo que significa que si un evento de división crea una o más particiones sucesivas con menos de la cantidad mínima de registros, la cantidad no se considera. De forma resumida, los árboles de decisión predicen la pertenencia a clases dividiendo conjuntos de datos en subconjuntos progresivamente homogéneos y mutuamente excluyentes a través de un sistema ramificado de divisiones de datos.

Un árbol de decisión se compone de nodos internos (decisión o reglas aplicadas), ramas (conexiones que unen dos nodos) y nodos terminales (hojas) que representan las etiquetas de clase (Figura 4.8). Los nodos internos del árbol de decisión simbolizan un evento de división donde el atributo de división divide el conjunto de datos en subconjuntos hasta que se alcanza el nodo hoja del árbol de decisión. La hoja del árbol representa un segmento horizontal de un conjunto de datos donde no se realiza ninguna división adicional. De esta manera, los registros de un conjunto completo de datos de entrenamiento se distribuyen entre los segmentos de datos. La ruta desde el nodo raíz (nodo superior) hasta una hoja, constituye una regla lógica (es decir, un patrón) que identifica una relación entre los atributos que no pertenecen a una clase, división de atributos a lo largo de la ruta, y los valores de clase.



**Figura 4.8.** Árbol de decisión. A, B y C representan diferentes atributos por separado en un conjunto de datos. Cada rama a1, a2, b1, b2, c1, c2 representa el valor del atributo dividido. Los nodos terminales (hojas) 1, 2, 3 y 4 representan la clase. Fuente: Elaboración propia.

Los diferentes algoritmos de inducción del árbol de decisión difieren en el uso de diferentes tipos de medidas, como medidas basadas en la impureza, en la distancia, en estadísticas, etc., para calcular la pureza de la distribución del valor de clase. Entre los diferentes tipos de medidas, las medidas de impureza se emplean mayoritariamente para inducir árboles de decisión. Por ejemplo, C4.5 (Quinlan, 1992) emplea la Relación de Ganancia, mientras que CART (*Classification And Regression Trees*) (Breiman et al., 1984) usa el índice de Gini como medida de impurezas (Maimon and Rokach, 2010).

Los atributos utilizados para dividir el conjunto de datos se determina utilizando un método conocido como la Relación de Ganancia (Quinlan, 1992). Esta relación es una versión avanzada de la Ganancia de Información (Quinlan, 1986). La Ganancia de Información es una medida de ganancia en entropía, según la cual una mayor entropía indica una mayor desviación de los datos (en este caso, una mayor desviación en los valores de clase).

El atributo que genera la menor desviación (menor entropía) en las siguientes particiones, a su vez logra la mayor ganancia en la reducción de la entropía, llamada Ganancia de Información. La entropía de un segmento de datos ( $D$ ) antes de dividirse por un atributo que no pertenece a ninguna clase, se calcula a partir de la Ecuación 4.20.

$$Entropía(D) = \sum_{j=1}^{|C|} p(c_j, D) \times \log_2(p(c_j, D)) \quad (4.20)$$

El conjunto de datos  $D$  se puede dividir en  $S$  particiones basado en los valores de dominio de un atributo  $A_i$  que no es de clase. La entropía de todas las particiones siguientes se agregan según la Ecuación 4.21.

$$Entropía(A_i, D) = \sum_{i=1}^S \frac{|D_i|}{|D|} \times Entropía(D_i) \quad (4.21)$$

La Ganancia de Información del atributo  $A_i$  se calcula empleando la Ecuación 4.22.

$$GananciaInformación(A_i, D) = Entropía(D) - Entropía(A_i, D) \quad (4.22)$$

La Relación de Ganancia se trata de una modificación de la Ganancia de Información que corrige el sesgo mediante la introducción de un factor de normalización llamado 'Información Dividida'. La modificación para calcular la Relación de Ganancia del atributo  $A_i$  se muestra en la Ecuación 4.23.

$$RelaciónGanancia(A_i, D) = \frac{GananciaInformación(A_i, D)}{InformaciónDividida(A_i, D)} \quad (4.23)$$

La Información Dividida del atributo  $A_i$  se calcula a partir de la Ecuación 4.24:

$$InformaciónDividida(A_i, D) = \sum_{i=1}^S \frac{|D_i|}{|D|} \times \log_2 \left( \frac{|D_i|}{|D|} \right) \quad (4.24)$$

#### 4.4.4.1. See5 / C5.0

Otro algoritmo de clasificación utilizado fue el árbol de decisión C5.0 (también llamado See5). La elección se basa principalmente en que los árboles de decisión han demostrado ser consistentes y adecuados para los datos SAR utilizados en la clasificación de cultivos (McNair et al., 2009a, 2009b). C5.0 se basa en árboles de decisión y se desarrolló a partir del conocido y ampliamente utilizado algoritmo C4.5 (Quinlan, 1992).

El uso de C5.0 para clasificación implica generar una serie de archivos a priori. Dos archivos son esenciales para todas las aplicaciones C5.0: un archivo de "nombre" que describe los atributos y las clases, y un archivo de "datos", que proporciona información sobre el caso de entrenamiento. El software se lanzó seleccionando *boosting* y *pruning* como opciones para construir el clasificador. Ambas técnicas se detallan brevemente a continuación.

Cuando se construye un árbol de decisión, muchas de las ramas reflejarán anomalías en los datos de entrenamiento debido al ruido o a valores atípicos. Los métodos de *pruning* abordan este

problema de *overfitting* de los datos. Tales métodos suelen emplear medidas estadísticas para eliminar las ramas menos fiables.

El proceso de *pruning* utilizado por C5.0 se llama *pessimistic pruning* (Han et al., 2012) y evalúa cada subárbol individualmente para decidir si el árbol en su conjunto debe simplificarse. *Pessimistic pruning* utiliza el conjunto de datos de entrenamiento para estimar las tasas de error. Hay que recordar que una estimación de precisión o error basada en el conjunto de entrenamiento es demasiado optimista y, por lo tanto, está fuertemente sesgada. Por lo tanto, el método *pessimistic pruning* ajusta las tasas de error obtenidas del conjunto de entrenamiento agregando una penalización, para contrarrestar el sesgo incluido.

Para C5.0, el *pessimistic pruning* sirve como un enfoque menos matemático pero a menudo más práctico que la validación cruzada, ya que es bastante eficaz y mucho más eficiente para determinar el tamaño del árbol. Por lo tanto para evitar el *overfitting*, el árbol de decisión se ejecutó utilizando un *pruning* del 25% del modelo (Champagne et al., 2014; McNairn et al., 2014; Powers et al., 2012).

*Boosting*, que fue propuesto por Freund and Schapire (1996), es otra característica en C5.0. Es una técnica donde se generan múltiples iteraciones de clasificadores de árbol de decisión que ayudan a mejorar la precisión de la clasificación. En este caso, se emplea todo el conjunto de datos de entrenamiento para generar el árbol de decisión. Para cada iteración del árbol de decisión se asigna un peso a cada observación de entrenamiento. A las observaciones mal clasificadas en la iteración anterior se les asigna un peso mayor. Por lo tanto, el clasificador se ve obligado a centrarse en aquellas observaciones que se clasificaron erróneamente en la iteración anterior, haciendo que el clasificador final se genere a partir de los clasificadores individuales. La votación de los clasificadores individuales del árbol se pondera por la precisión del clasificador. Para una explicación más detallada sobre *boosting* y el algoritmo AdaBoost.M1 implementado en C5.0, leer Freund and Schapire (1996) y Friedl et al. (1999). En este caso, el software se ejecutó mediante el *boosting* sobre 5 de 10 ensayos, siguiendo el procedimiento utilizado en Champagne et al. (2014) y McNairn et al. (2014).

#### **4.4.5. Métodos de clasificación: escenarios de clasificación**

Para la clasificación de LU/LC se consideraron siete conjuntos diferentes de observables utilizados como entradas para la clasificación (Tabla 4.7), para evaluar la viabilidad de los observables polarimétricos extraídos a partir de las imágenes del RADARSAT-2 y Sentinel-1 en la clasificación de cultivos. A partir de los datos proporcionados por el RADARSAT-2 se probaron seis escenarios (A-F), que combinan la configuración totalmente polarimétrica de este satélite y el rango disponible de ángulos de incidencia. Debido a que Sentinel-1 es *dual-pol*, para el desarrollo de esta tesis únicamente se exploró un escenario (G). El escenario E se creó después de una investigación previa (Valcarce-Diñeiro et al., 2018), donde se descubrió que las diferencias en la correlación entre los observables SAR y las variables biofísicas de los diferentes tipos de cultivos sugerían la posibilidad de realizar una

clasificación a partir de los ratios de los coeficientes de retrodispersión, la correlación normalizada entre los canales copolares y el ángulo dominante alfa. El escenario F se generó para comparar los datos de doble polarización de RADARSAT-2 con Sentinel-1. Para llevar a cabo el análisis de este último escenario, solo se seleccionaron las imágenes de RADARSAT-2 más cercanas a las fechas de Sentinel-1.

**Tabla 4.7.** Descripción de los siete escenarios explorados con imágenes RADARSAT-2 y Sentinel-1.

Escenario	Observable polarimétrico	Imágenes
A	HH, HV, VV, HH/VV, HV/VV, $\gamma_{HHVV}$ , PPD, H, $\alpha_1$ , $\Upsilon_{P1P2}$	RDS-2 a 36°
B	HH, HV, VV, HH/VV, HV/VV, $\gamma_{HHVV}$ , PPD, H, $\alpha_1$ , $\Upsilon_{P1P2}$	RDS-2 a 31°
C	HH, HV, VV, HH/VV, HV/VV, $\gamma_{HHVV}$ , PPD, H, $\alpha_1$ , $\Upsilon_{P1P2}$	RDS-2 a 25°
D	HH, HV, VV, HH/VV, HV/VV, $\gamma_{HHVV}$ , PPD, H, $\alpha_1$ , $\Upsilon_{P1P2}$	Todas las RDS-2
E	HH/VV, HV/VV, $\gamma_{HHVV}$ , $\alpha_1$	RDS-2 a 31° y 36°
F	HV, VV, HV/VV	RDS-2 más cercanas a Sentinel-1
G	VH, VV, VH/VV	Sentinel-1

#### 4.4.6. Métodos de clasificación: evaluación de la exactitud

La evaluación de la precisión se llevó a cabo a escala de parcela utilizando el ya mencionado mapa de usos y coberturas del suelo del ITACyL como referencia. Una de las formas más comunes para evaluar la precisión de una clasificación de datos de detección remota es a través de la matriz de confusión. Esta matriz se deriva de una comparación del mapa de referencia (columnas) con el mapa clasificado (filas). A partir de la matriz de confusión se pueden obtener varias técnicas estadísticas tales como la exactitud media (OA, *Overall Accuracy*), exactitud del productor (PA, *Producer's Accuracy*), exactitud del usuario (UA, *User's Accuracy*) y el coeficiente *kappa* (Congalton, 1991). La precisión general relaciona los campos correctamente clasificados de la diagonal principal con el número total de campos en la matriz de confusión. La exactitud del productor se calcula para una clase específica dividiendo el número total de campos correctos en esa clase por el número total de campos derivados de los datos de referencia, es decir, la probabilidad de que una clase de referencia se clasifique correctamente. Sin embargo, si el campo correctamente clasificado en una clase es dividido por el número total de campos que fueron clasificados en esa clase, esta medida se llama exactitud del usuario (Story and Congalton, 1986) y es una medida de la fiabilidad del mapa. Finalmente, el coeficiente *kappa* (Cohen, 1960) se calcula a partir de la Ecuación 4.9.

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} x_{+i})} \quad (4.9)$$

donde  $r$  es el número de filas de la matriz,  $x_{ii}$  es el número de observaciones en fila  $i$  y columna  $i$ ,  $x_{i+}$  y  $x_{+i}$  son el total marginal de la fila  $i$  y columna  $i$  y  $N$  es el número total de observaciones.



CAPÍTULO 5:  
RESULTADOS Y DISCUSIÓN



## Capítulo 5: Resultados y Discusión

### 5.1. Estimación de variables biofísicas

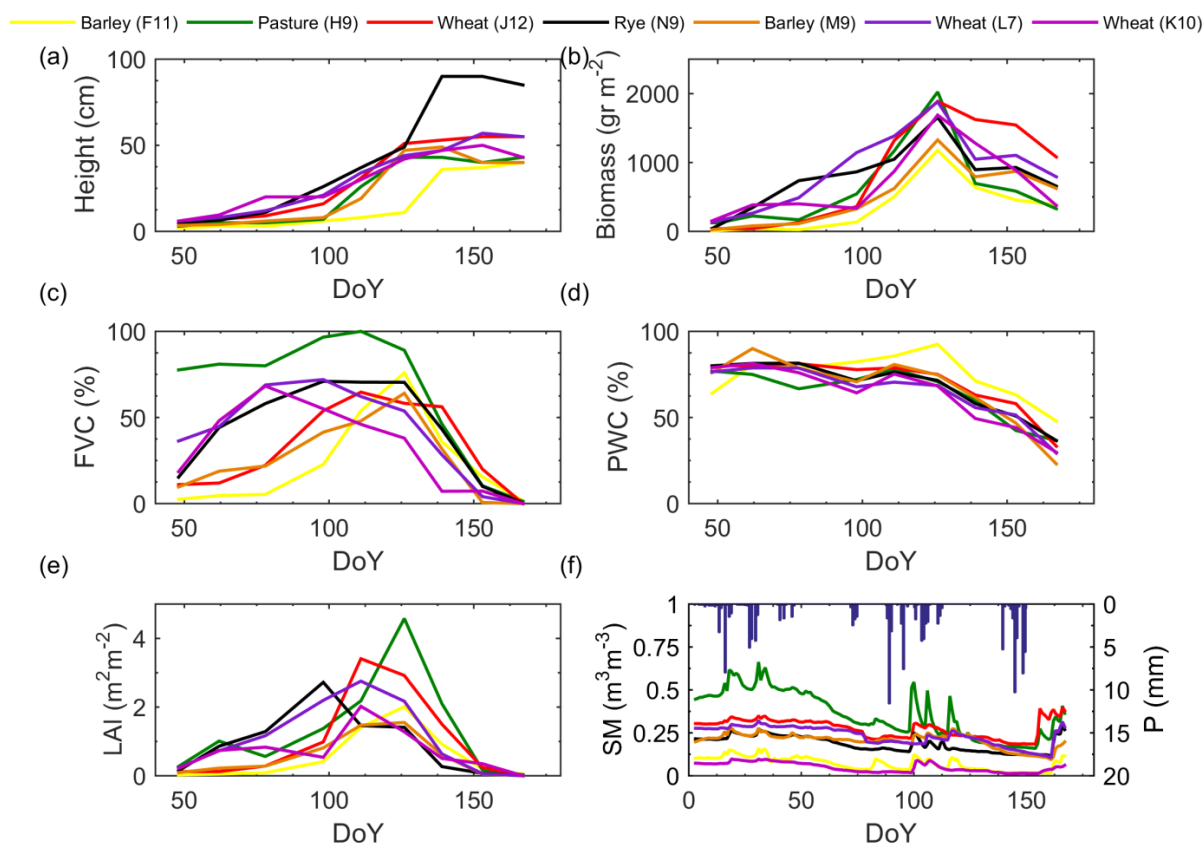
La evolución temporal de cada parámetro para cada tipo de cultivo se derivó de las mediciones *in situ* (Figura 5.1). La altura del cultivo (Figura 5.1a) mostró un patrón de crecimiento similar para trigo, pasto y cebada (excepto para F11, con algún retraso), con máximos al comienzo de la fase de madurez (DoY=126), que permanecieron hasta la senescencia. Los datos muestran claramente que el centeno (N9) es mucho más alto que los otros tipos de cobertura del suelo evaluados.

La densidad más alta para el FVC (Figura 5.1c) fue para el pasto (H9), que tuvo valores más altos durante el invierno, ya que el pasto natural tiene un ciclo anual. Por el contrario, los cereales mostraron una tendencia creciente al comienzo de la campaña, alcanzando un máximo de FVC aproximadamente en la fase de maduración (DoY=126), seguido de un comportamiento en forma de meseta para el centeno y el trigo, y un pico para la cebada. Es importante aclarar que el parámetro FVC solo considera la cubierta verde. En las últimas fechas (DoY=160), los cultivos todavía están de pie, pero las plantas están totalmente secas (en la etapa de senescencia), por lo tanto, el valor de FVC es cero a pesar de que la vegetación aun muestra valores grandes para las alturas.

La evolución del LAI (Figura 5.1e) mostró los valores más altos para el pasto, en relación con su mayor densidad; mientras que la cebada mostró valores de LAI más pequeños así también como un ligero retraso en comparación con el trigo y el centeno, que comenzaron antes (especialmente el centeno).

Todas las curvas de biomasa (Figura 5.1b) tienen un patrón similar, sin embargo, el pasto mostró la variación de biomasa más alta (de  $1 \text{ kg m}^{-2}$  a  $2 \text{ kg m}^{-2}$ ), seguido del trigo, centeno y cebada. Este comportamiento de la biomasa representa la curva típica de crecimiento del cultivo y es similar al comportamiento del LAI.

El PWC (Figura 5.1d) es muy diferente del resto de los parámetros de vegetación; se observa una tendencia general descendente, aunque con cierta fluctuación. El consumo de agua disminuye hacia el final a medida que las plantas se secan. Esta tendencia se confirma por el comportamiento de la humedad del suelo (Figura 5.1f), ya que el contenido de agua del suelo disminuyó durante todo el ciclo de crecimiento, incluso con pequeños eventos de lluvia. Estos resultados fueron similares a los obtenidos en un estudio de campo previo en REMEDHUS para cultivos de cebada y pasto (Sánchez et al., 2012a).



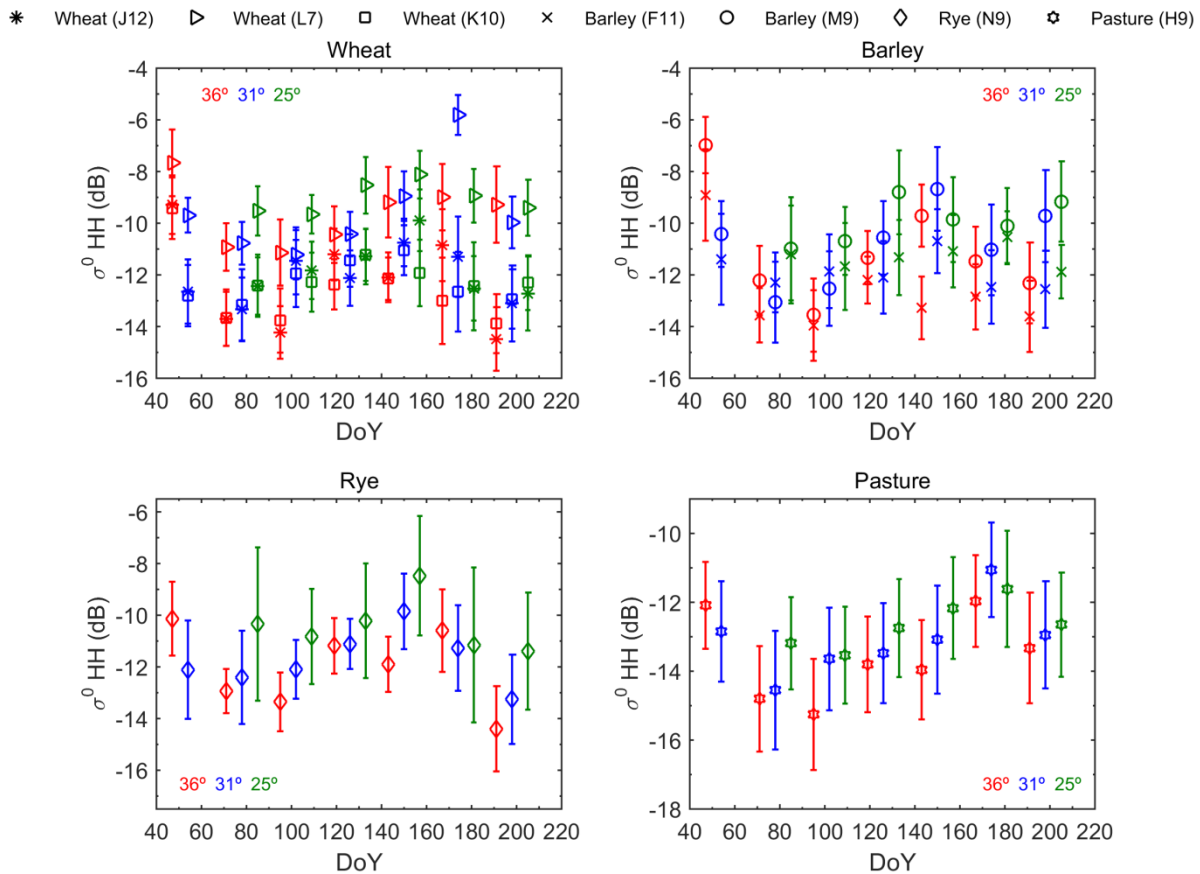
**Figura 5.1.** Evolución de la altura (a), biomasa (b), FVC (c), PWC (d), LAI (e), precipitación diaria y contenido de humedad (SM) (f) para las siete parcelas agrícolas. Fuente: Valcarce-Diñeiro et al. (2018).

## 5.2. Evaluación de los parámetros SAR y efecto del ángulo de incidencia

### 5.2.1. Coeficientes de retrodispersión

Las evoluciones temporales de los coeficientes de retrodispersión (HH, HV y VV) y los ratios (HH/VV y HV/VV) se muestran en la Figuras 5.2-5.7 para los diferentes tipos de cultivo y ángulos de incidencia. En un fase vegetativa temprana (DoY=45-70), los tres coeficientes de retrodispersión mostraron una tendencia decreciente desde valores muy grandes; esto se debe a que en ese momento la vegetación era muy baja, y la única explicación de esta respuesta del radar podría ser debido a los eventos de lluvia que ocurrieron durante ese periodo de tiempo seguido por un clima más seco (Figura 5.1). HH (Figura 5.2) y VV (Figura 5.3) tienen valores muy similares (es decir, HH/VV está cerca de 0 dB), y HV está entre 5 y 12 dB por debajo de los canales copolares, como se esperaba de la dispersión

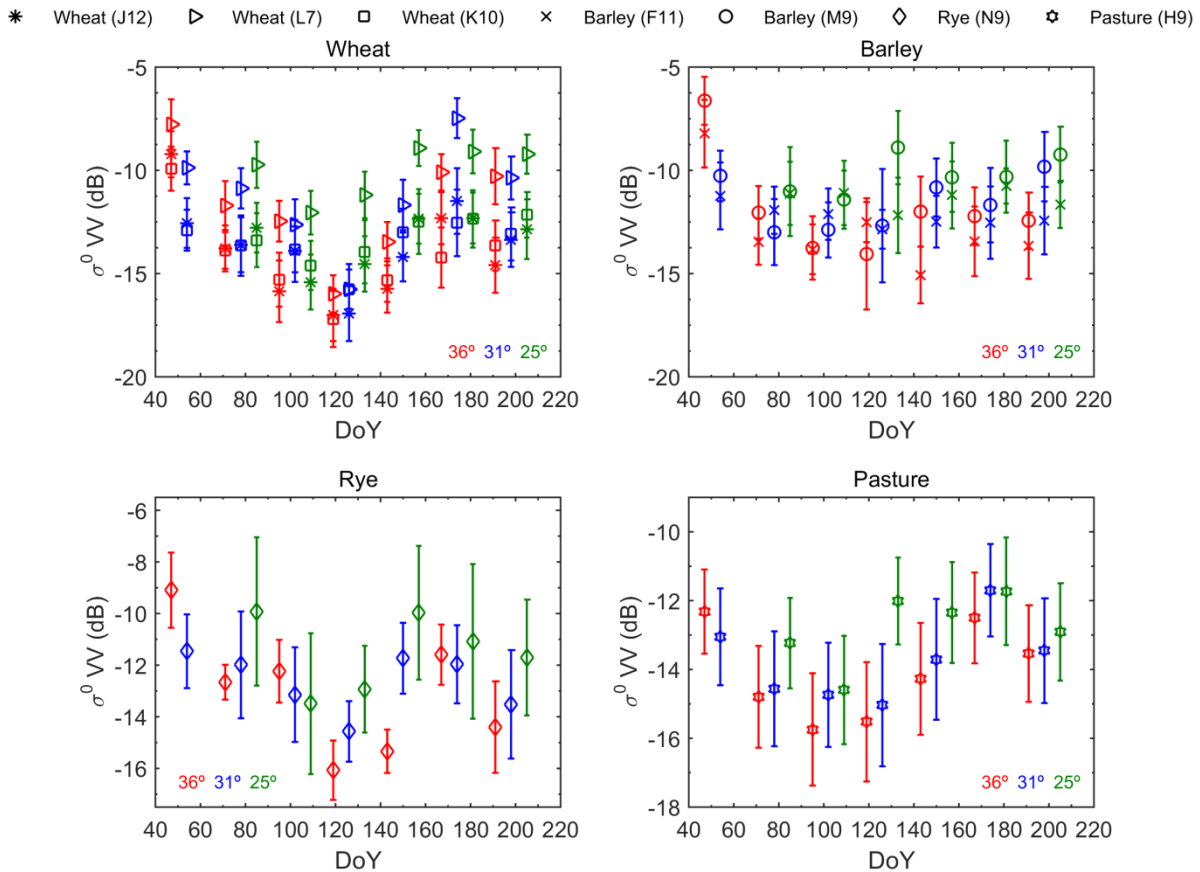
de superficie dominante. De hecho, el modelo de perturbación pequeña y el modelo de dispersión de Bragg para superficies rugosas predicen que VV será ligeramente más alto que HH, en un rango de 0 a 3 dB, dependiendo de la rugosidad, la humedad y el ángulo de incidencia (Chen and Fung, 1988; Fung, 1994; Hajnsek et al., 2003). En este estudio, sin embargo, se midió un nivel de retrodispersión muy similar para ambos canales lineales, algo que también fue observado al comienzo de la temporada del cultivo por otros investigadores (Bouvet et al., 2009; Satalino et al., 2009).



**Figura 5.2.** Evaluación temporal del coeficiente de retrodispersión (HH) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018).

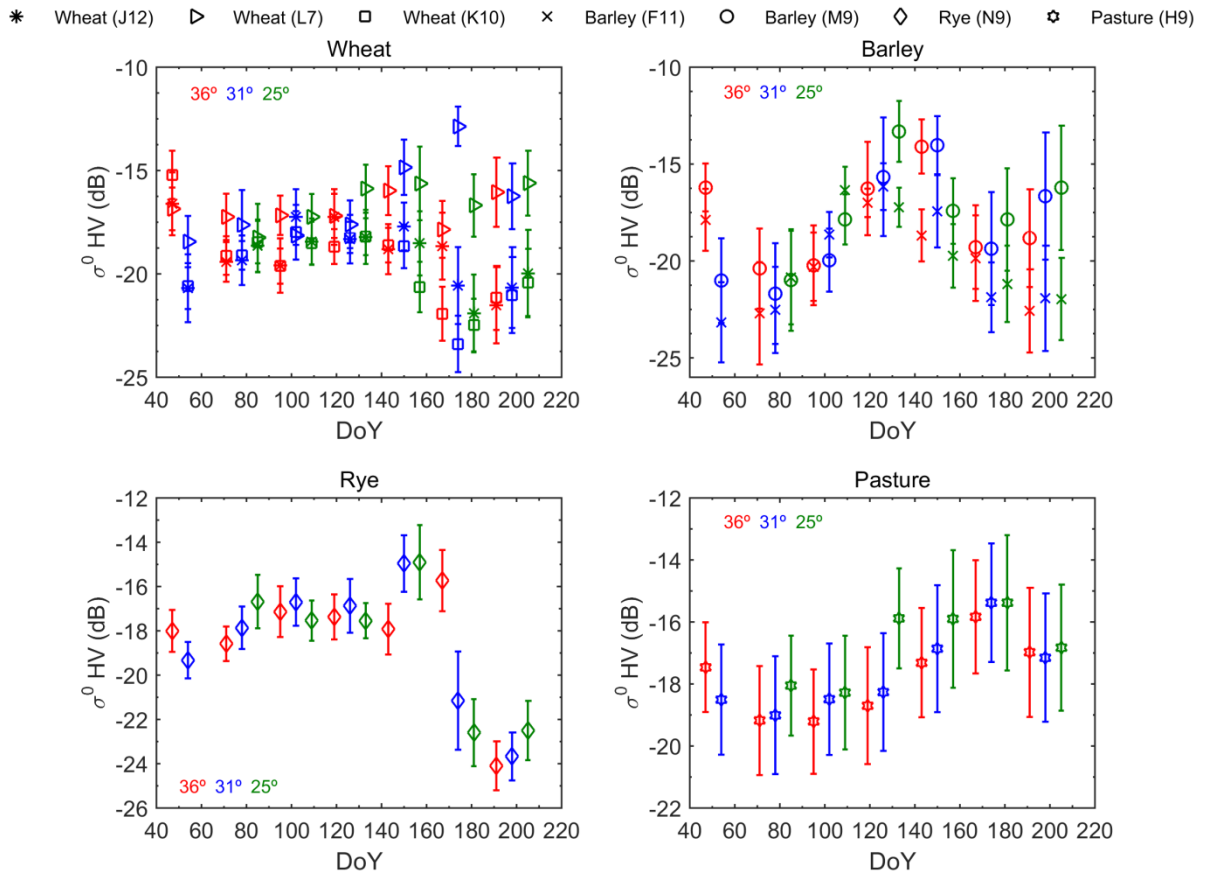
A partir de fechas intermedias (DoY=71-135) se produce el crecimiento de las plantas, haciendo que la respuesta de HH aumente significativamente debido a la presencia de tallos verticales y brotes. Sin embargo, la respuesta de VV disminuyó para todos los cultivos, especialmente cuando se emplearon las imágenes de 36° y 31°, porque la polarización vertical fue más atenuada que la horizontal. El ratio HH/VV describe muy bien este patrón. Al final del ciclo, desde DoY=140 hasta el final, las plantas pierden su verticalidad y se orientan al azar, por lo que la diferencia entre los dos canales de polarización es mucho menor, es decir, dentro de +/- 1.5 dB a 36° para la mayoría de los

cultivos. Se produjo un efecto similar para el ángulo de incidencia de 25°, aunque en este caso se pudieron observar valores altos de ambos canales copolares para el trigo (L7) durante las fechas tardías para este ángulo, posiblemente porque una mayor cantidad de biomasa estaba presente durante estas etapas, como se muestra en la Figura 5.1.



**Figura 5.3.** Evaluación temporal del coeficiente de retrodispersión (VV) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018).

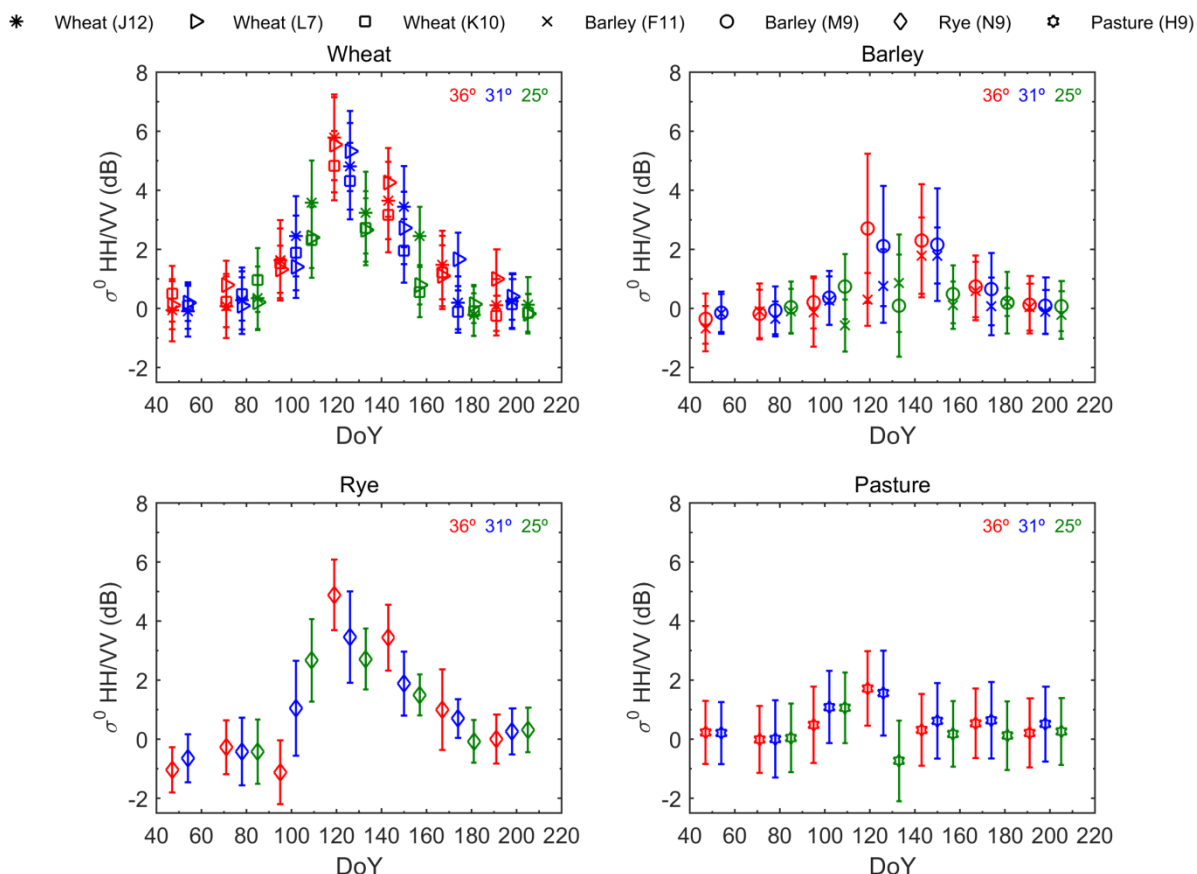
La Figura 5.4 muestra que el canal de polarización cruzada (HV) fue controlado principalmente por la presencia del volumen de vegetación, ya que está compuesto de elementos orientados al azar. Como se mencionó anteriormente, el retorno de la polarización cruzada fue muy bajo en todos los ángulos de incidencia durante las primeras fechas, pero la dispersión del volumen aumentó en fechas intermedias (DoY=71-135) debido al desarrollo de la planta, por lo que HV aumentó para todos los cultivos y los tres ángulos de incidencia. Los valores máximos (entre -13 y -14 dB) en esta etapa se encuentran para la cebada (M9) en todos los ángulos de incidencia. Disminuyó para algunos cultivos en las fechas tardías, pero en otros casos aumentó ligeramente debido a la morfología de volumen aleatorio de los cultivos.



**Figura 5.4.** Evaluación temporal del coeficiente de retrodispersión (HV) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018).

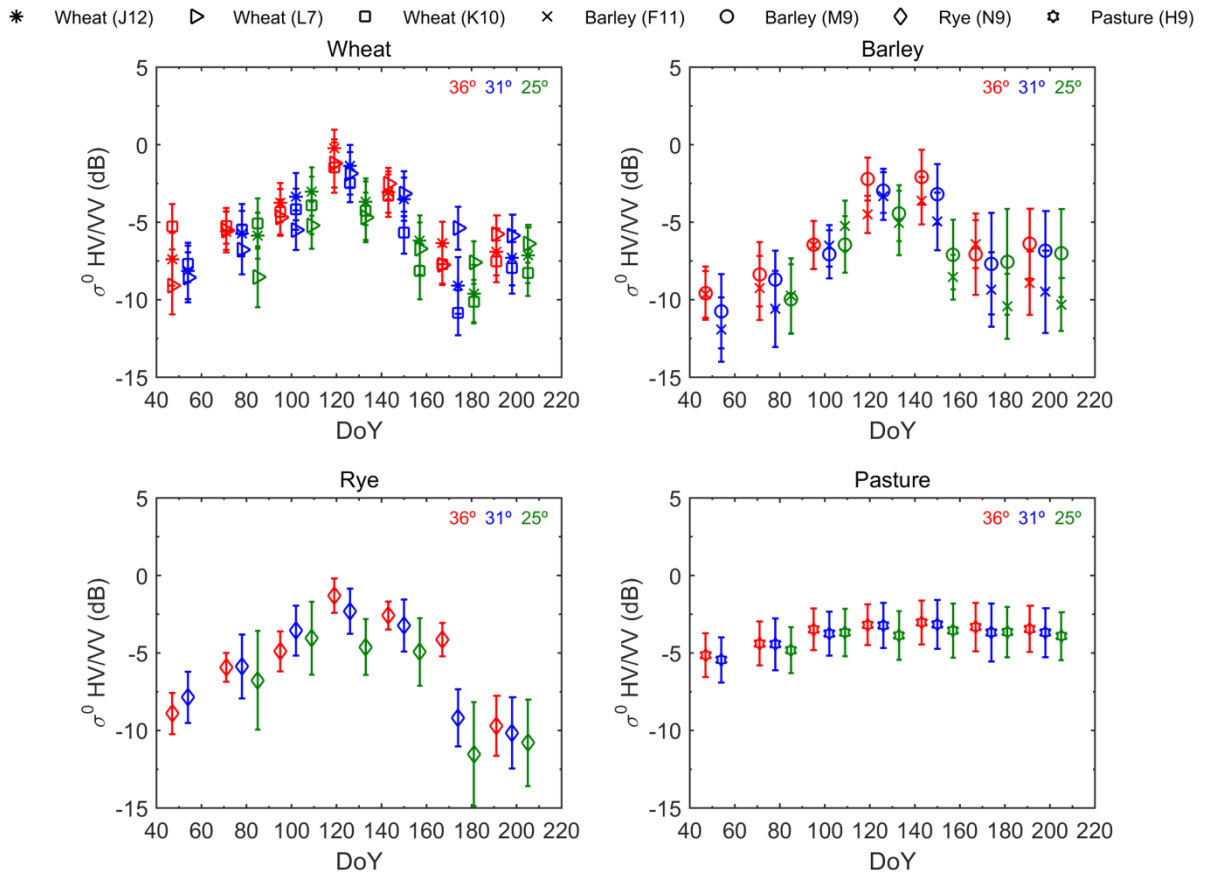
El ratio copolar (HH/VV) es muy sensible al ciclo de crecimiento del trigo, cebada y centeno, mientras que mostró una respuesta bastante uniforme para el pasto (Figura 5.5). Los valores máximos de este ratio se alcanzan a mediados de la temporada de crecimiento y dependen claramente del tipo de cultivo y el ángulo de incidencia. Los valores extremos para el trigo y el centeno son aproximadamente 5 dB a 31° y 36°, y 2-3 dB a 25°, pero el ratio de cebada alcanza solo 2 dB para 31° y 36° y no muestra ningún pico a 25°.

Finalmente, el ratio HV/VV (Figura 5.6) también mostró un comportamiento creciente-decreciente con el tiempo como el ratio HH/VV, pero los valores en cada fecha son diferentes para diferentes cultivos y ángulos de incidencia. El ángulo más superficial (36°) produjo los valores más altos en cada fecha y el más inclinado (25°) los más pequeños, con una diferencia entre 2 y 4 dB. La cebada es el tipo de cultivo con los valores más bajos de HV/VV, y tanto el centeno como el trigo se comportan de manera similar. Además, ambos ratios tienen un patrón temporal similar al del LAI y la biomasa (Figura 5.1), lo que sugiere su viabilidad para monitorear el vigor del cultivo.



**Figura 5.5.** Evaluación temporal del ratio de retrodispersión (HH/VV) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018).



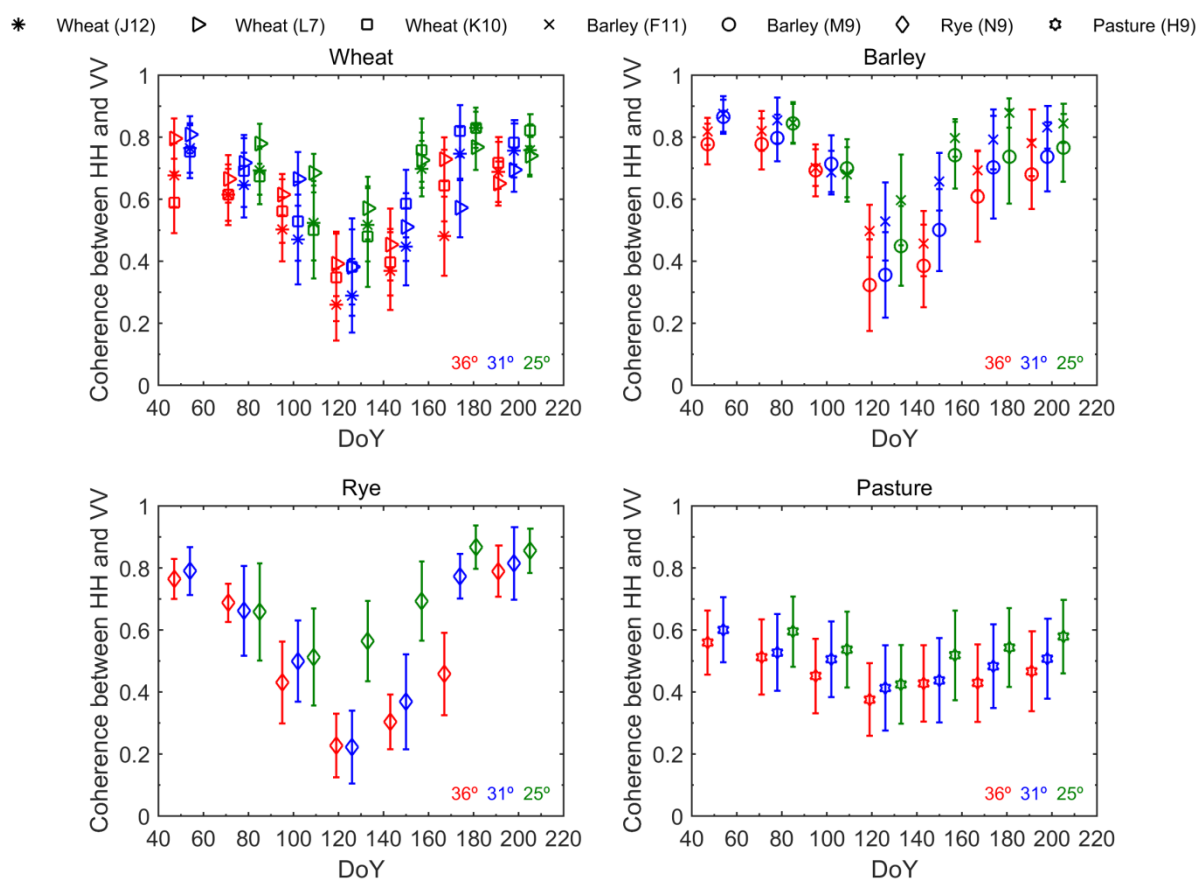


**Figura 5.6.** Evaluación temporal del ratio de retrodispersión (HV/VV) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018).

### 5.2.2. Correlación entre HH y VV

La Figura 5.7 representa la correlación normalizada, o coherencia, entre HH y VV ( $\gamma_{HHVV}$ ) para todas las parcelas a diferentes ángulos de incidencia. Durante las primeras etapas, cuando la dispersión de la superficie es la contribución más importante, se encuentra una alta correlación, con valores entre 0.6 y 0.9. A medida que se desarrolla el follaje de la planta,  $\gamma_{HHVV}$  disminuye entre 0.2 y 0.6, dependiendo del tipo de cultivo y el ángulo de incidencia. En general, la caída es menos pronunciada a 25° que a 31° y 36°, conforme a la contribución más pronunciada del suelo en ángulos pronunciados que en ángulos poco profundos. Al final, coincidiendo con la etapa más seca de las plantas y la cosecha, el valor de  $\gamma_{HHVV}$  vuelve a ser alto, similar al comienzo de la campaña. La causa del alto valor de  $\gamma_{HHVV}$  en estas etapas tardías es debido al dominio de la dispersión de la superficie, ya que la retrodispersión de la vegetación se reduce debido a las condiciones secas de las plantas. El

patrón temporal de  $\gamma_{HHVV}$  es opuesto al de las relaciones HH/VV y HV/VV, lo que sugiere una relación inversa con el LAI y la biomasa (Figura 5.1).



**Figura 5.7.** Evaluación temporal de la correlación entre HH y VV ( $\gamma_{HHVV}$ ) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Valcarce-Diñeiro et al. (2018).

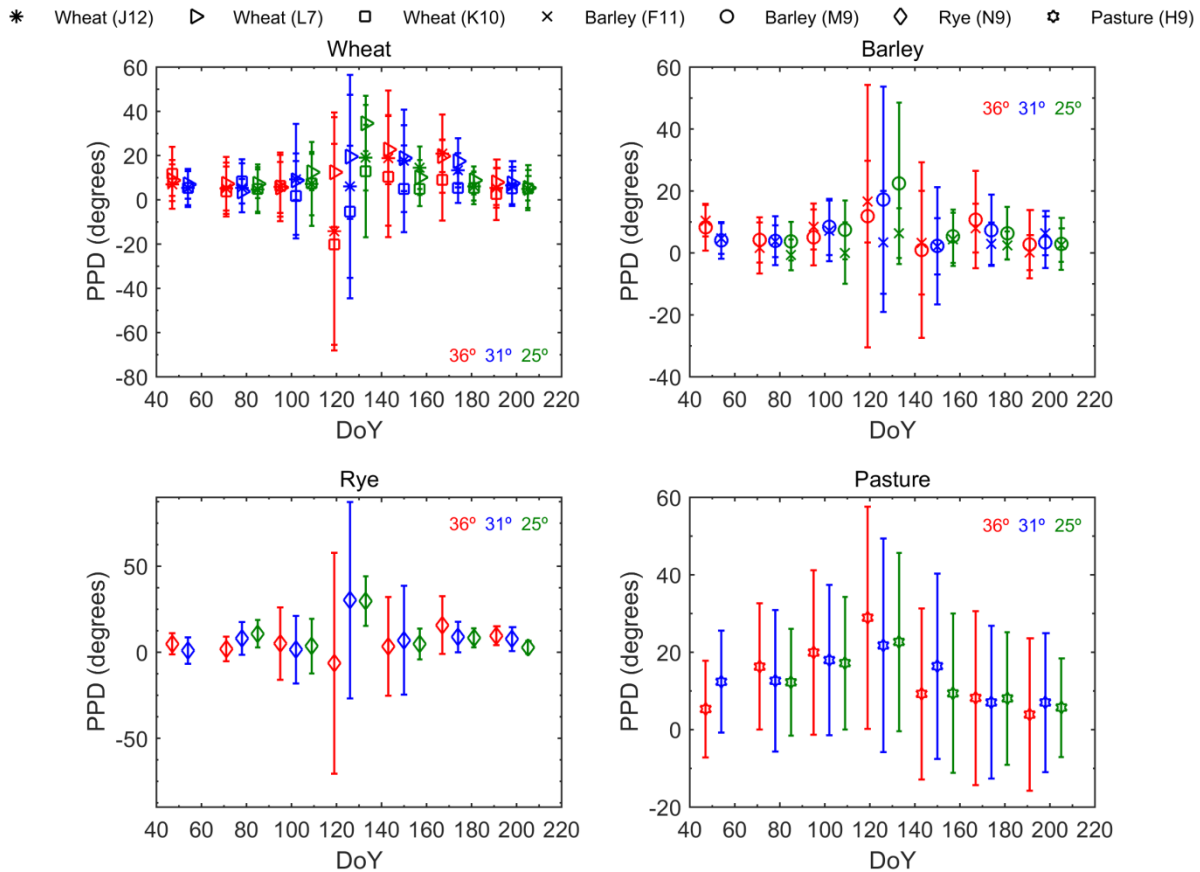
### 5.2.3. Diferencia de fase de polarización

La diferencia de fase de polarización (PPD) entre los canales co-polares muestra valores cercanos a 0° en las fechas iniciales y finales para todos los ángulos de incidencia (Figura 5.8), como resultado del dominio de la dispersión de la superficie, que también produce la alta correlación esperada entre los canales co-polares (Figura 5.7).

La presencia de vegetación en fechas intermedias se caracteriza por saltos, ya sean positivos o negativos, claramente visibles para todos los cultivos y ángulos. Varias razones podrían explicar esta fluctuación del PPD: 1) efectos de propagación diferencial o 2) doble rebote, aunque la literatura no respalda una comprensión sólida de este observable. Además, este comportamiento errático también

está relacionado con la baja correlación entre HH y VV para esas fechas, provocando que la varianza del PPD sea equivalente a la coherencia y fase en la interferometría SAR.

La decisión de estudiar el PPD es debida a que se trata de uno de los observables extraídos directamente de la matriz de covarianza polarimétrica y se ha encontrado que proporciona información útil para cultivos de arroz empleando la misma banda (Lopez-Sanchez et al., 2014).

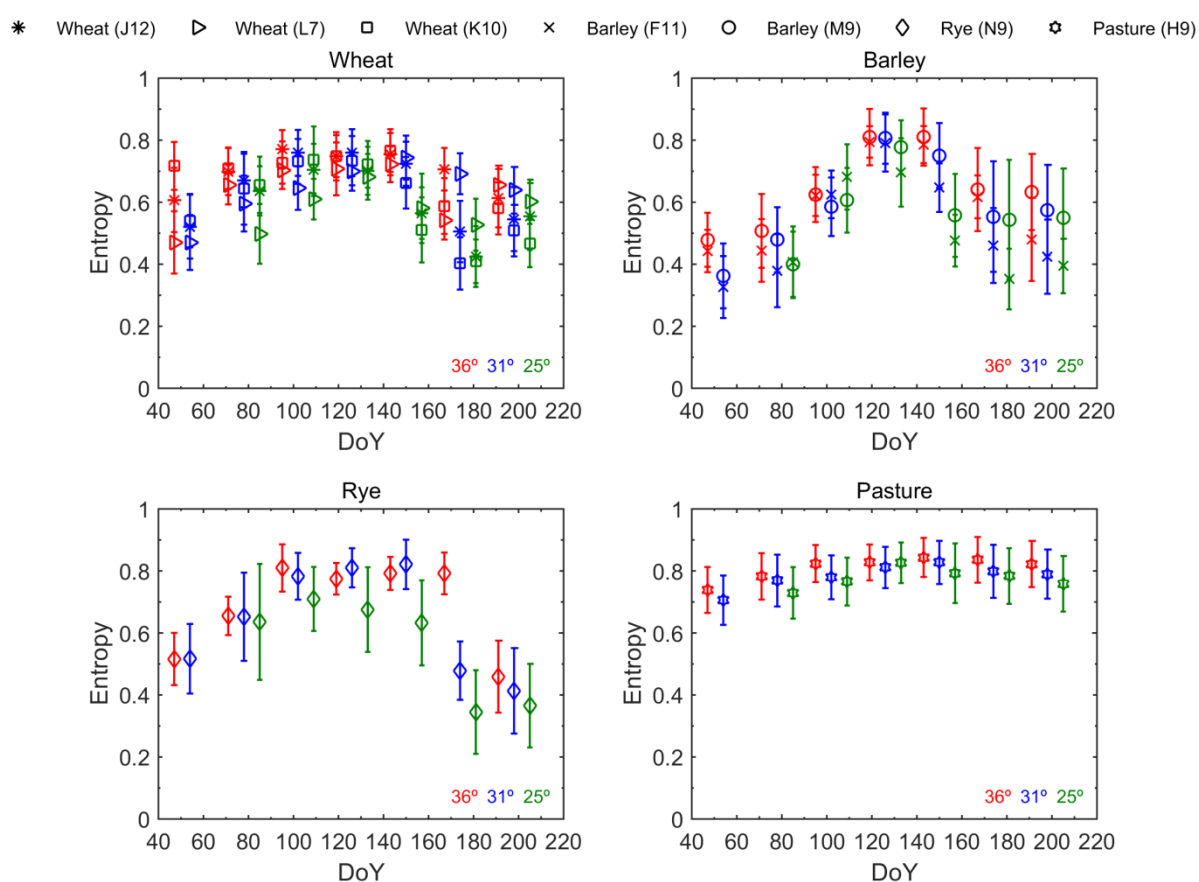


**Figura 5.8.** Evaluación temporal de la diferencia de fase de polarización (PPD) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Elaboración propia.

### 5.2.4. Entropía y ángulo alfa dominante

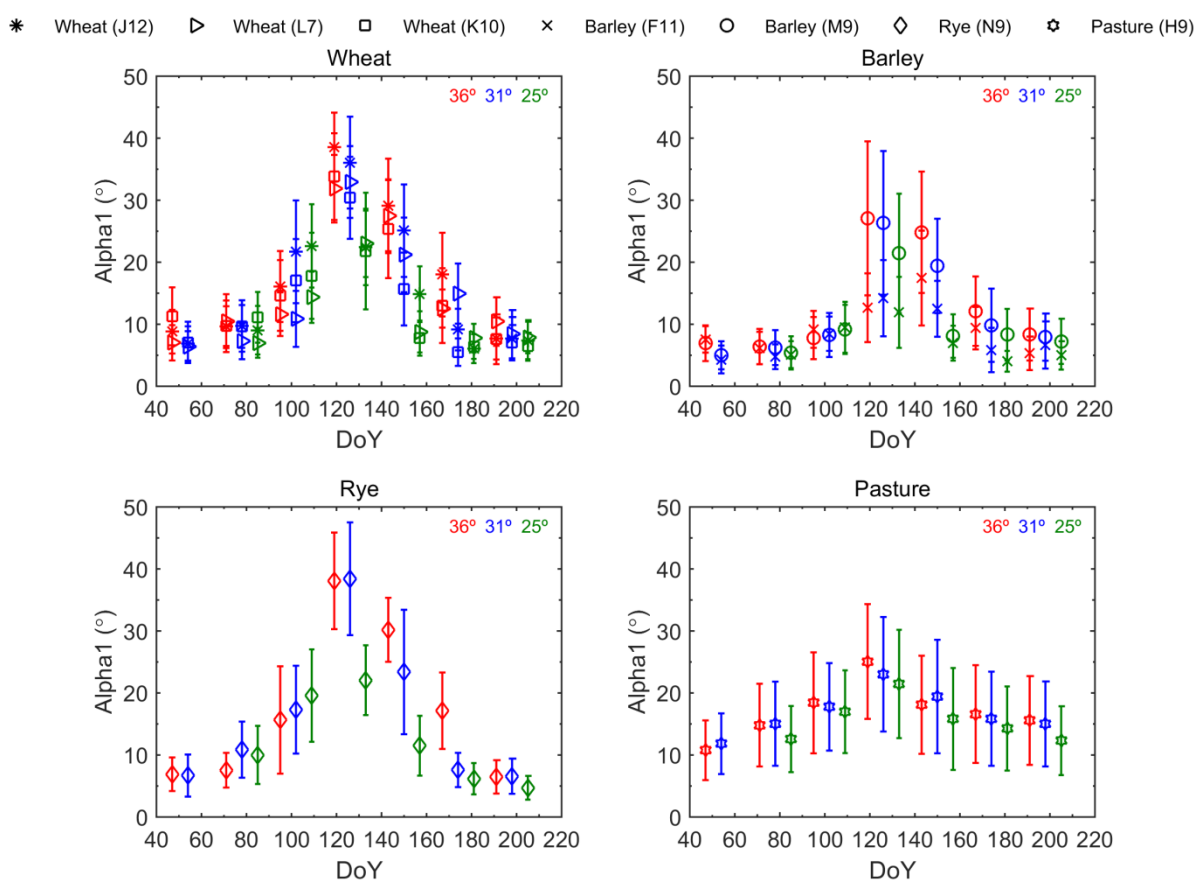
La Figura 5.9 muestra el comportamiento de uno de los observables obtenidos a partir de la descomposición de los valores propios de la matriz de covarianza polarimétrica: la entropía (H). La respuesta del radar sobre los cereales se caracteriza por un bajo valor de entropía (0,4-0,6) para las fechas iniciales, lo que indica que está dominado por un único mecanismo de dispersión, que es del tipo superficie, porque  $\alpha_1$  está por debajo de 15°. Cuando el desarrollo de las plantas alcanza las

fechas intermedias (DoY=71-135), el valor de la entropía es moderado (0,6-0,75) debido a la presencia de suelo y vegetación. Finalmente, en las fechas más tardías (más allá de DoY=140) el valor de la entropía disminuye nuevamente, volviéndose cada vez más bajo porque predomina un único mecanismo de dispersión (dispersión de superficie). Este comportamiento en función del tiempo es similar a la curva de comportamiento típica de FVC (Figura 5.1c), con mesetas o picos en mitad del ciclo. La parcela de pasto (H9) muestra una entropía constante de aproximadamente 0,7-0,8 para todos los ángulos de incidencia durante toda la campaña. Como se mencionó anteriormente, el dosel del pasto es constante y denso durante todo el año, lo que implica una buena relación entre la entropía y el FVC. Cabe destacar que, en algunos casos, para una de las parcelas de trigo, la entropía fue alta también al comienzo de la temporada y no demasiado baja al final, por lo tanto en este caso no siguió el comportamiento deseado. La causa de tal discrepancia permanece sin explicación.



**Figura 5.9.** Evaluación temporal de la entropía (H) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Elaboración propia.

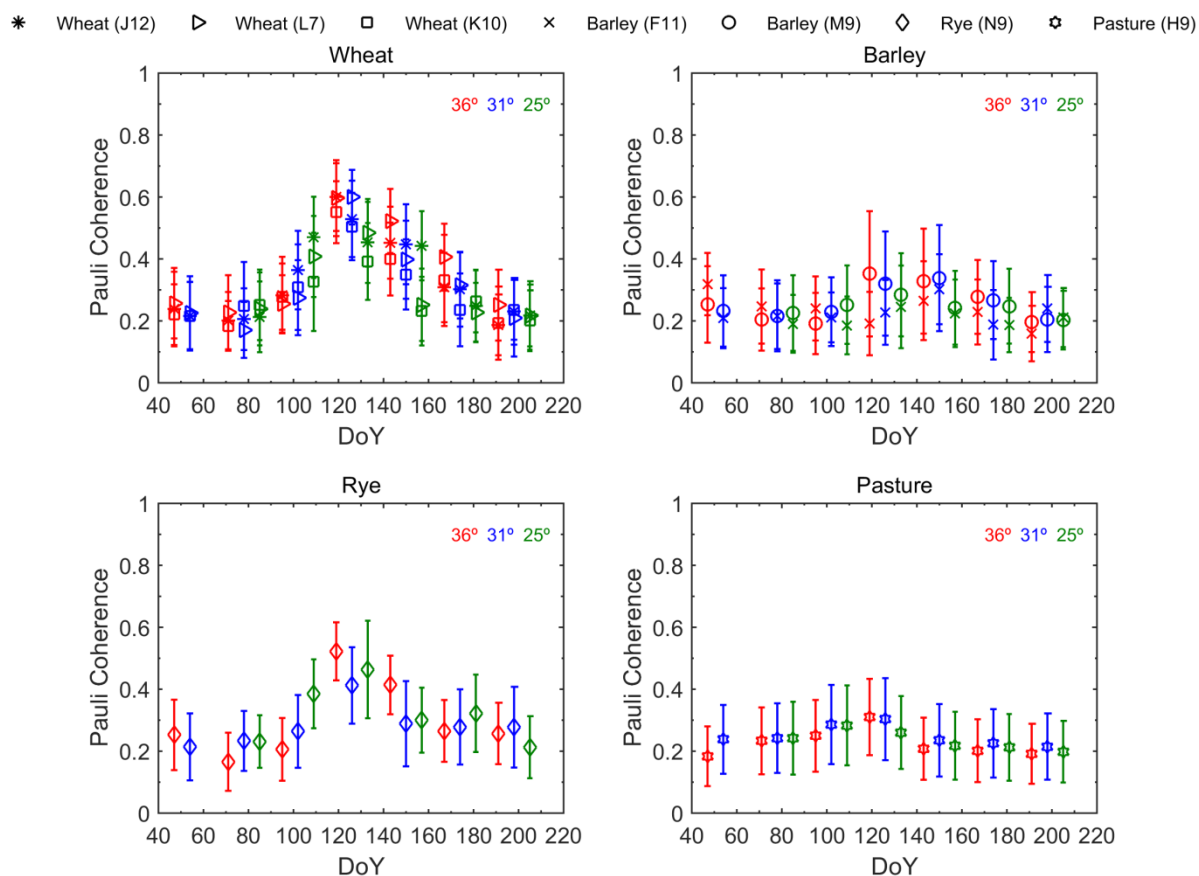
La Figura 5.10 muestra la evolución del ángulo alfa dominante ( $\alpha_1$ ), es decir, el ángulo alfa del primer vector propio. Durante la fase vegetativa temprana,  $\alpha_1$  estaba cerca de  $0^\circ$  para todos los cultivos y ángulos, lo cual es típico de suelos desnudos y dispersión de la superficie. A medida que las plantas se desarrollan se produjo una tendencia creciente, y alcanzaron un pico máximo aproximadamente en DoY=110-130 con un valor de  $40^\circ$  para trigo y centeno, en ángulos de incidencia de  $31^\circ$  y  $36^\circ$ . Este valor de alfa corresponde a un retorno de radar linealmente polarizado que proviene del dominio de HH sobre VV (HH fue 5 dB más alto que VV). En la misma etapa, pero en ángulos de incidencia más pronunciados ( $25^\circ$ ), el valor  $\alpha_1$  era solo de  $20^\circ$ , lo que significa que el mecanismo de dispersión dominante era principalmente la dispersión superficial. Al final de la campaña,  $\alpha_1$  disminuyó, volviendo a estar cerca de  $0^\circ$  para todos los ángulos de incidencia en el momento de la cosecha. Una vez más, la evolución del ángulo alfa dominante sigue un patrón de tiempo similar al del LAI y la biomasa.



**Figura 5.10.** Evaluación temporal del ángulo dominante alfa ( $\alpha_1$ ) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a  $36^\circ$ , azul a  $31^\circ$  y verde a  $25^\circ$ . Fuente: Valcarce-Diñeiro et al. (2018).

### 5.2.5. Correlación entre los dos primeros canales en la base de Pauli

La correlación entre los dos primeros canales de Pauli ( $\gamma_{P1P2}$ ) es baja (por debajo de 0,3-0,25) para todos los cultivos y ángulos de incidencia en las fases vegetativas más tempranas (Figura 5.11). A medida que las plantas se van desarrollando en fechas intermedias (DoY=71-135), la correlación se vuelve más alta (aproximadamente 0,5-0,6) para el trigo y el centeno a 36° y 31°. Sin embargo, a 25° la coherencia no está tan alta (por debajo de 0,5) para los mismos cultivos. Este comportamiento es debido, una vez más, a la importante atenuación de VV con respecto a HH, ya que cuando VV es muy bajo en comparación con HH, los dos primeros canales de Pauli son similares entre sí y con HH. El comportamiento de  $\gamma_{P1P2}$  es similar al del ratio HH/VV (Figura 5.5), como ya ha sido demostrado para el arroz por Lopez-Sanchez et al. (2014).



**Figura 5.11.** Evaluación temporal de la coherencia entre el primer y segundo canal de Pauli ( $\gamma_{P1P2}$ ) para todas las parcelas. Medias (símbolos) y las desviaciones estándar (barras de error) se calcularon dentro de cada parcela. El color rojo indica un ángulo de incidencia a 36°, azul a 31° y verde a 25°. Fuente: Elaboración propia.

Este comportamiento también es similar al patrón temporal del ángulo dominante alfa. Las parcelas en la Figura 5.1 muestran que la cebada tiene la biomasa más baja de todos los cultivos estudiados y uno de los dos campos con la altura de la planta más pequeña (incluso menos que el pasto). Por consiguiente, la cebada normalmente tiene la respuesta menos pronunciada. Por ejemplo, los valores máximos del ángulo alfa dominante y la correlación entre los dos canales de Pauli no están tan marcados como para los otros tipos de cultivos. Además de todo esto, el comportamiento de la altura con el tiempo en los dos campos de cebada es diferente, uno va por detrás del otro. Estos resultados llevaron a sospechar de un comportamiento similar al LAI y la biomasa con el tiempo, lo que se confirma mediante el análisis de correlación en la siguiente sección.

### **5.3. Análisis de correlación entre los parámetros del radar y las variables biofísicas**

Primero se analizó la correlación entre los coeficientes de retrodispersión y las variables biofísicas. HH (Tabla 5.2) está moderadamente correlacionado con las propiedades de la escena, mostrando una alta correlación solo en algunos casos. La respuesta del radar de este canal se ve afectada por los parámetros de la vegetación y del suelo, y, como se discutió anteriormente, no muestra un patrón temporal consistente (Figura 5.2). Los coeficientes de correlación más altos se obtuvieron para el centeno con la altura, el PWC y el SM, a 25° y 31°, y para trigo (L7) con el PWC, LAI y FVC en ángulos de incidencia de 31° y 36°.

El coeficiente de retrodispersión VV está altamente correlacionado con la biomasa para la mayoría de los cultivos y los ángulos de incidencia, mostrando mejores valores a 31° (Tabla 5.3). El LAI también está bien correlacionado con el VV, especialmente a 31° para la mayoría de los cultivos, y a 36° con el trigo. Estos dos parámetros de la planta se correlacionan de manera significativa pero negativa con el VV porque un aumento en la biomasa o LAI se traduce en una atenuación más fuerte de las ondas polarizadas verticalmente y una consiguiente disminución en el VV (Figura 5.3). Los resultados más consistentes para VV se obtienen a 31°, con correlaciones más bajas a 25° y 36°, por lo que este ángulo parece ser una buena opción en esta banda de frecuencia para monitorear el desarrollo del cultivo.

Las correlaciones para HV (Tabla 5.4) no son tan buenas como se esperaba con respecto a los resultados anteriores encontrados en la literatura (Moran et al., 2012). Solo está moderadamente correlacionado con la altura de la vegetación y la biomasa a 31° para la mayoría de los tipos de cultivos. Ambas variables biofísicas están relacionadas con un aumento en el volumen de la vegetación, y es sabido que la dispersión del volumen genera una retrodispersión significativa en el canal de polarización cruzada. El resto de las variables biofísicas muestran muchas inconsistencias en las correlaciones, con signos opuestos para diferentes campos del mismo cultivo (por ejemplo, el FVC del trigo a 25° y 31°, o el SM a 25°), dificultando cualquier interpretación física.

Los parámetros físicos relacionados con el contenido de agua (es decir, SM y PWC) no muestran correlación con los coeficientes de retrodispersión (excepto algunos valores altos aislados), mientras que los relacionados con la geometría o morfología de la escena (es decir, altura, biomasa y LAI) exhiben mejores coeficientes de correlación.

Con respecto al ángulo de incidencia, el ángulo intermedio (31°) proporciona las mejores correlaciones, probablemente porque da como resultado una compensación entre el dominio del suelo a 25° y una atenuación excesiva dentro de la vegetación a 36°.

Como algunas fluctuaciones de los coeficientes de retrodispersión son comunes a diferentes canales de polarización (probablemente debido a eventos específicos como lluvia u otras fuentes externas), se espera que el efecto de estas variaciones se minimice si se emplean los ratios de retrodispersión (HH/VV y HV/VV). Estos ratios muestran altas correlaciones con las variables biofísicas en muchos de los casos analizados. Las Tablas 5.5 y 5.6 indican que las correlaciones más fuertes para estos ratios se observaron con la biomasa para todos los cultivos, a 31° y 36°, con valores muy altos y correlaciones positivas. De acuerdo con estos resultados, Mattia et al. (2003) encontró que el ratio copolar (HH/VV) está altamente correlacionado con la biomasa del trigo con un ángulo de incidencia de 40°, mientras para un ángulo de 23° la correlación fue menor. Además, Moran et al. (2012) también encontraron una muy buena correlación de VV/HH (es decir, la inversa de HH/VV) con el crecimiento del cultivo para la cebada de invierno con un ángulo de incidencia superior a 35°. Tanto HH/VV como HV/VV también están altamente correlacionados con la altura de la vegetación y moderadamente correlacionados con el LAI, lo que respalda los conocimientos previos encontrados en el análisis de evolución temporal.

La correlación de  $\gamma_{HHVV}$  con la biomasa es alta para todos los cultivos, y de moderada a alta con la altura para todos los cultivos en ángulos de incidencia de 31° y 36° (Tabla 5.7). Estas correlaciones son negativas debido al patrón temporal de  $\gamma_{HHVV}$  en presencia de cultivos (Figura 5.7), como se discutió anteriormente: alto cuando la dispersión de la superficie es dominante (es decir, en fechas tempranas y tardías) y bajo cuando hay vegetación (es decir, en medio de la temporada).

De la misma manera que los ratios de retrodispersión y  $\gamma_{HHVV}$ ,  $\alpha_1$  está altamente correlacionado con la biomasa para todos los cultivos en ángulos de incidencia de 31° y 36° (Tabla 5.8). De hecho, la razón física de esta correlación es la misma: el cambio gradual del mecanismo de dispersión que domina la respuesta del radar de los cultivos durante el ciclo de crecimiento (Figura 5.10). En consecuencia, sigue la curva típica para la biomasa, como se muestra en la Figura 5.1. Lopez-Sanchez et al. (2013) utilizaron este principio y emplearon  $\alpha_1$  para estimar la etapa fenológica de varios cultivos.

La evolución temporal de la entropía (Figura 5.9) también está aumentando o disminuyendo, como los observables considerados anteriormente, y tiene una alta correlación con la biomasa a 31° y 36° para la mayoría de los cultivos (Tabla 5.9). La entropía aumenta cuando la vegetación aumenta debido a la presencia de más elementos de dispersión en la escena, lo que resulta en un comportamiento de dispersión más complejo en la mitad de la temporada de crecimiento. Sin embargo, estos coeficientes de correlación no son tan buenos como los del ángulo alfa dominante o la coherencia entre los canales copolares.



Cabe mencionar que la entropía muestra coeficientes de correlación negativos de moderados a altos con SM a 31° y 36°, ya que SM fue más bajo en la mitad de la temporada de crecimiento que al principio o al final. El ángulo alfa dominante también mostró correlaciones moderadas similares en los mismos ángulos de incidencia.

La coherencia entre el primer y segundo canal de Pauli ( $\gamma_{P1P2}$ ) también presenta una evolución temporal creciente-decreciente (Figura 5.11) y en consecuencia, tiene una correlación alta con la biomasa para todos los cultivos, excepto para la cebada (F11) a 31° y 36° (Tabla 5.10). Los altos coeficientes de correlación con la altura de la vegetación también están presentes para la mayoría de los cultivos y con LAI únicamente para alguno de ellos. Finalmente, como se esperaba de su evolución temporal errática (Figura 5.8), no se obtuvo una correlación consistente con los parámetros biofísicos para PPD en ningún ángulo de incidencia.

Hay que destacar que en ocasiones se han encontrado correlaciones fluctuantes e incluso inversas entre parcelas con el mismo cultivo. Esos pocos casos tuvieron lugar principalmente en parcelas de trigo y en ángulos menos profundos, y pueden justificarse por una mayor variabilidad entre las evoluciones del trigo en comparación con la cebada (Figura 5.1).

Debido a la gran cantidad de correlaciones resultantes de las posibles combinaciones entre parámetros, observaciones de campo y ángulos de incidencia, la Tabla 5.1 resume los resultados de la correlación, indicando las mejores correlaciones ( $r \geq +/- 0.66$ ) y el ángulo de incidencia recomendado para cada variable biofísica y parámetro SAR.

**Tabla 5.1.** Descripción general de los parámetros SAR y variables biofísicas altamente correlacionadas teniendo en cuenta el ángulo de incidencia para todos los cultivos analizados en este estudio. Se utiliza una marca de verificación para mostrar las mejores combinaciones.

Parámetro	Altura		Biomasa		LAI	
	31°	36°	31°	36°	31°	36°
HH						
VV						
HV						
HH/VV	✓	✓	✓	✓		
HV/VV	✓	✓	✓	✓	✓	✓
$\gamma_{HHVV}$	✓	✓	✓	✓		
$\alpha_1$			✓	✓		
H						
$\gamma_{P1P2}$			✓	✓		
PPD						

Para proporcionar más información se ha mostrado también el seguimiento y correlación de la diferencia de fase polarizada (PPD), entropía (H) y correlación entre los dos primeros canales de Pauli ( $\gamma_{P1P2}$ ) con las variables biofísicas, aunque estos observables no fueron incluidos en la publicación relacionada con este tema (Valcarce-Diñeiro et al., 2018) debido a restricción de páginas dado por la revista.

Este estudio de correlación nos permite identificar las relaciones entre los observables del radar y las variables biofísicas, aunque debe considerarse cuidadosamente debido al número limitado de observaciones de campo. La escasez de mediciones en campo es un problema constante en aplicaciones de radar en particular, y de teledetección en general, habida cuenta de la inversión de tiempo y personal que requieren. Sin embargo, la literatura contiene muchos ejemplos de análisis de correlación con un número similar (o menor) de observaciones en campo contra estimaciones de radar. Maity et al. (2004) compararon tres mediciones de campo con imágenes del RADARSAT para la parametrización del algodón en India durante las etapas de crecimiento del cultivo. Lim et al. (2008) llevaron a cabo un estudio temporal con múltiples ángulos comparando seis parámetros de arroz con mediciones de un dispersómetro terrestre (banda C) para toda la temporada de crecimiento del cultivo. Kim et al. (2012) compararon los índices de vegetación de arroz y soja derivados del radar (~12-19 mediciones) para estimar VWC. Baghdadi et al. (2016) utilizaron 18 mediciones de campo para caracterizar los pastizales de regadío utilizando datos polarimétricos de RADARSAT-2 a diferentes ángulos de incidencia. Las mediciones de campo requieren de mucho tiempo y organización y, por lo general, es difícil reunir un conjunto completo de datos *in situ*.

**Tabla 5.2.** Correlación (r Pearson) entre las mediciones de campo y el canal copolar HH, para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas.

	Altura			Biomasa			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Trigo)	0.76	0.57	0.27	0.71	0.47	0.25	-0.50	-0.58	-0.33	0.32	0.03	0.00	0.39	0.02	-0.28	-0.44	-0.01	0.48
L7 (Trigo)	-0.48	0.53	0.24	-0.69	-0.21	-0.31	0.27	-0.83	-0.40	-0.54	-0.77	-0.75	-0.25	-0.92	-0.77	0.52	0.24	0.18
K10 (Trigo)	-0.64	0.75	-0.19	-0.4	0.67	0.02	0.46	-0.52	0.16	-0.29	0.04	-0.22	-0.04	-0.64	-0.37	0.65	-0.29	0.53
F11 (Cebada)	-0.39	0.36	-0.28	-0.53	-0.11	-0.12	-0.28	-0.56	-0.18	-0.48	-0.31	-0.06	-0.51	-0.29	-0.10	0.71	0.14	0.68
M9 (Cebada)	-0.44	0.58	0.15	-0.51	0.37	0.01	0.31	-0.48	-0.03	-0.37	-0.31	-0.30	-0.32	-0.40	-0.32	0.51	0.11	0.29
N9 (Centeno)	0.82	0.95	0.30	0.44	0.34	-0.18	-0.76	-0.83	-0.39	-0.21	-0.61	-0.69	-0.24	-0.52	-0.65	-0.78	-0.72	0.16
H9 (Pasto)	-0.44	0.26	0.35	-0.50	-0.19	-0.15	0.21	-0.41	-0.46	-0.42	-0.36	-0.32	-0.02	-0.53	-0.61	0.83	0.43	0.43

**Tabla 5.3.** Correlación (r Pearson) entre las mediciones de campo y el canal copolar VV, para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas.

	Altura			Biomasa			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Trigo)	-0.62	-0.45	-0.42	-0.67	-0.70	-0.61	0.24	-0.21	-0.14	-0.58	-0.80	-0.76	-0.65	-0.82	-0.87	0.50	0.62	0.66
L7 (Trigo)	-0.61	-0.25	-0.38	-0.84	-0.80	-0.87	0.31	-0.26	-0.09	-0.57	-0.72	-0.75	-0.18	-0.45	-0.40	0.60	0.50	0.52
K10 (Trigo)	-0.63	-0.30	-0.63	-0.59	-0.80	-0.72	0.30	-0.25	0.22	-0.49	-0.77	-0.61	-0.10	-0.46	-0.13	0.65	0.41	0.57
F11 (Cebada)	0.44	-0.59	-0.57	0.43	-0.79	-0.36	0.16	-0.16	-0.04	0.34	-0.62	-0.17	0.37	-0.63	-0.21	-0.62	0.60	0.76
M9 (Cebada)	-0.49	-0.05	-0.34	-0.55	-0.26	-0.51	0.33	-0.23	0.07	-0.38	-0.61	-0.63	-0.33	-0.64	-0.58	0.52	0.49	0.56
N9 (Centeno)	-0.56	-0.11	-0.46	-0.87	-0.83	-0.87	0.37	-0.19	0.09	-0.40	-0.53	-0.21	-0.46	-0.78	-0.53	0.34	-0.22	0.23
H9 (Pasto)	-0.54	-0.03	0.11	-0.45	-0.59	-0.51	0.36	-0.47	-0.51	-0.33	-0.71	-0.62	0.14	-0.61	-0.69	0.82	0.65	0.55

**Tabla 5.4.** Correlación (r Pearson) entre las mediciones de campo y el canal de polarización cruzada HV, para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas.

	Altura			Biomasa			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Trigo)	0.49	0.48	0.01	0.64	0.62	0.18	0.08	-0.02	0.15	0.57	0.60	0.37	0.75	0.79	0.10	-0.83	-0.70	0.33
L7 (Trigo)	0.54	0.80	0.21	0.09	0.14	0.21	-0.50	-0.93	0.12	-0.55	-0.55	-0.13	-0.77	-0.82	-0.11	-0.11	-0.20	-0.64
K10 (Trigo)	-0.77	0.22	-0.56	-0.39	0.59	-0.01	0.67	0.27	0.69	-0.12	0.62	0.10	0.17	0.32	0.18	0.58	-0.68	0.30
F11 (Cebada)	0.43	0.45	0.21	0.60	0.85	0.71	0.25	0.25	0.12	0.54	0.79	0.72	0.57	0.82	0.72	-0.69	-0.61	-0.08
M9 (Cebada)	-0.36	0.94	0.69	-0.41	0.86	0.65	0.29	-0.50	-0.10	-0.29	0.20	0.26	-0.25	0.10	0.20	0.47	-0.43	-0.35
N9 (Centeno)	0.61	0.62	0.59	0.69	0.64	0.24	-0.47	-0.28	-0.77	0.24	0.13	-0.08	0.25	0.25	-0.35	-0.58	-0.74	-0.27
H9 (Pasto)	-0.47	0.68	0.63	-0.43	-0.09	-0.16	0.31	-0.89	-0.84	-0.33	-0.36	-0.39	0.08	-0.92	-0.92	0.80	-0.10	0.02

**Tabla 5.5.** Correlación (r Pearson) entre las mediciones de campo y el ratio copolar HH/VV, para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas.

	Altura			Biomasa			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Trigo)	0.68	0.73	0.67	0.70	0.92	0.88	-0.35	-0.11	-0.06	0.49	0.76	0.89	0.56	0.79	0.82	-0.48	-0.59	-0.44
L7 (Trigo)	0.70	0.72	0.59	0.93	0.86	0.88	-0.34	-0.30	-0.11	0.55	0.33	0.50	0.09	-0.13	0.06	-0.64	-0.46	-0.53
K10 (Trigo)	-0.45	0.60	0.64	0.08	0.94	0.89	0.60	-0.06	-0.15	0.19	0.60	0.59	0.07	0.03	-0.11	0.42	-0.45	-0.32
F11 (Cebada)	-0.42	0.83	0.84	-0.46	0.60	0.63	-0.19	-0.35	-0.21	-0.39	0.27	0.28	-0.42	0.30	0.31	0.65	-0.41	-0.58
M9 (Cebada)	0.55	0.96	0.84	0.61	0.92	0.93	-0.36	-0.44	-0.17	0.40	0.33	0.66	0.34	0.23	0.56	-0.53	-0.48	-0.54
N9 (Centeno)	0.64	0.67	0.59	0.84	0.86	0.76	-0.47	-0.36	-0.27	0.30	0.04	-0.12	0.35	0.28	0.22	-0.44	-0.28	-0.15
H9 (Pasto)	0.56	0.53	0.44	0.44	0.82	0.87	-0.40	0.18	0.27	0.31	0.74	0.78	-0.18	0.24	0.37	-0.82	-0.50	-0.41

**Tabla 5.6.** Correlación (r Pearson) entre las mediciones de campo y el ratio de polarización cruzada HV/VV, para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas.

	Altura			Biomasa			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Trigo)	0.61	0.52	0.43	0.68	0.75	0.70	-0.20	0.13	0.21	0.58	0.81	0.93	0.68	0.91	0.94	-0.55	-0.73	-0.55
L7 (Trigo)	0.76	0.83	0.39	0.89	0.86	0.84	-0.44	-0.45	0.10	0.46	0.27	0.66	0.00	-0.19	0.35	-0.65	-0.62	-0.61
K10 (Trigo)	-0.70	0.27	0.18	-0.10	0.73	0.76	0.84	0.28	0.38	0.28	0.74	0.74	0.38	0.41	0.30	0.35	-0.60	-0.35
F11 (Cebada)	0.41	0.49	0.61	0.70	0.87	0.82	0.31	0.24	0.12	0.66	0.78	0.68	0.69	0.81	0.71	-0.70	-0.63	-0.65
M9 (Cebada)	0.42	0.90	0.80	0.44	0.91	0.90	-0.03	-0.36	-0.13	0.30	0.45	0.67	0.22	0.37	0.59	-0.02	-0.61	-0.69
N9 (Centeno)	0.60	0.46	0.67	0.81	0.85	0.91	-0.43	-0.08	-0.39	0.33	0.35	0.16	0.37	0.57	0.36	-0.47	-0.37	-0.32
H9 (Pasto)	0.66	0.85	0.80	0.49	0.60	0.60	-0.46	-0.50	-0.46	0.33	0.43	0.42	-0.25	-0.35	-0.30	-0.85	-0.90	-0.89

**Tabla 5.7.** Correlación (r Pearson) entre las mediciones de campo y la correlación normalizada (coherencia) entre HH y VV ( $\gamma_{HHVV}$ ), para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas.

	Altura			Biomasa			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Trigo)	-0.60	-0.64	-0.77	-0.76	-0.85	-0.92	0.07	0.00	0.20	-0.76	-0.81	-0.81	-0.84	-0.86	-0.76	0.60	0.65	0.45
L7 (Trigo)	0.54	-0.83	-0.49	0.55	-0.84	-0.87	-0.42	0.47	-0.01	0.30	-0.23	-0.59	0.04	0.22	-0.23	-0.49	0.53	0.61
K10 (Trigo)	0.32	-0.49	-0.54	-0.29	-0.86	-0.92	-0.61	-0.04	0.00	-0.42	-0.66	-0.57	-0.16	-0.10	0.03	-0.23	0.48	0.39
F11 (Cebada)	0.31	-0.39	-0.54	-0.14	-0.90	-0.88	-0.14	-0.32	-0.21	-0.28	-0.86	-0.76	-0.26	-0.88	-0.78	-0.28	0.57	0.64
M9 (Cebada)	0.43	-0.89	-0.85	0.47	-0.94	-0.93	-0.34	0.26	0.20	0.30	-0.55	-0.65	0.25	-0.47	-0.54	-0.47	0.56	0.54
N9 (Centeno)	-0.52	-0.60	-0.67	-0.85	-0.88	-0.88	0.32	0.24	0.41	-0.43	-0.16	-0.22	-0.49	-0.42	-0.34	0.38	0.37	0.36
H9 (Pasto)	0.44	-0.86	-0.78	0.33	-0.66	-0.77	-0.39	0.44	0.27	0.22	-0.53	-0.60	-0.16	0.31	0.11	-0.74	0.89	0.81

**Tabla 5.8.** Correlación (r Pearson) entre las mediciones de campo y el ángulo dominante alfa ( $\alpha_1$ ), para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas.

	Altura			Biomasa			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Trigo)	0.69	0.70	0.72	0.73	0.90	0.92	-0.30	-0.06	-0.12	0.56	0.81	0.85	0.63	0.82	0.78	-0.51	-0.58	-0.43
L7 (Trigo)	-0.58	0.76	0.63	-0.56	0.82	0.86	0.45	-0.35	-0.15	-0.29	0.25	0.42	-0.01	-0.19	-0.01	0.51	-0.47	-0.53
K10 (Trigo)	-0.65	0.54	0.61	-0.26	0.92	0.92	0.58	0.00	-0.10	-0.09	0.65	0.59	0.04	0.10	-0.08	0.60	-0.44	-0.31
F11 (Cebada)	-0.25	0.54	0.65	0.19	0.90	0.78	0.12	0.20	0.04	0.30	0.77	0.58	0.28	0.79	0.61	0.24	-0.61	-0.64
M9 (Cebada)	-0.47	0.90	0.83	-0.51	0.92	0.92	0.35	-0.22	-0.13	-0.33	0.52	0.63	-0.27	0.45	0.53	0.49	-0.53	-0.52
N9 (Centeno)	0.29	0.52	0.60	0.69	0.88	0.86	0.04	-0.16	-0.28	0.25	0.15	0.12	0.49	0.46	0.36	-0.01	-0.22	-0.21
H9 (Pasto)	-0.36	0.78	0.54	-0.21	0.81	0.87	0.42	-0.20	0.12	-0.11	0.72	0.80	0.19	-0.07	0.28	0.67	-0.90	-0.72

**Tabla 5.9.** Correlación (r Pearson) entre las mediciones de campo y la entropía (H), para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas.

	Altura			Biomasa			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Trigo)	-0.12	0.44	0.53	0.24	0.63	0.61	0.72	0.13	-0.12	0.78	0.71	0.54	0.88	0.87	0.71	-0.57	-0.76	-0.65
L7 (Trigo)	-0.07	0.90	0.28	0.00	0.74	0.71	0.18	-0.66	0.14	-0.10	0.12	0.64	-0.14	-0.32	0.45	0.12	-0.65	-0.70
K10 (Trigo)	-0.61	0.27	-0.03	0.04	0.65	0.56	0.82	0.23	0.51	0.38	0.68	0.51	0.38	0.32	0.35	0.27	-0.65	-0.46
F11 (Cebada)	0.41	0.40	0.52	0.71	0.87	0.86	0.32	0.30	0.21	0.67	0.84	0.76	0.70	0.86	0.79	-0.71	-0.58	-0.62
M9 (Cebada)	-0.23	0.88	0.84	-0.26	0.92	0.92	0.27	-0.34	-0.27	-0.15	0.52	0.62	-0.14	0.43	0.52	0.38	-0.61	-0.61
N9 (Centeno)	0.54	0.54	0.69	0.82	0.83	0.75	-0.35	-0.20	-0.57	0.40	0.32	0.27	0.45	0.48	0.22	-0.44	-0.50	-0.53
H9 (Pasto)	-0.36	0.82	0.79	-0.30	0.49	0.50	0.32	-0.59	-0.56	-0.21	0.33	0.31	0.09	-0.44	-0.39	0.71	-0.88	-0.88

**Tabla 5.10.** Correlación (r Pearson) entre las mediciones de campo y los dos primeros canales de Pauli ( $\gamma_{P1P2}$ ), para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas.

	Altura			Biomasa			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Trigo)	0.70	0.82	0.68	0.70	0.95	0.89	-0.38	-0.27	-0.07	0.46	0.70	0.87	0.53	0.68	0.78	-0.46	-0.46	-0.39
L7 (Trigo)	-0.42	0.70	0.79	-0.24	0.81	0.83	0.45	-0.30	-0.40	-0.04	0.26	0.24	0.09	-0.18	-0.27	0.33	-0.41	-0.44
K10 (Trigo)	-0.65	0.68	0.69	-0.33	0.97	0.86	0.53	-0.16	-0.26	-0.17	0.54	0.53	0.00	0.01	-0.20	0.65	-0.48	-0.22
F11 (Cebada)	-0.39	0.79	-0.03	-0.43	0.37	-0.56	-0.21	-0.32	-0.48	-0.37	0.02	-0.67	-0.40	0.06	-0.67	0.63	-0.58	0.32
M9 (Cebada)	-0.39	0.97	0.85	-0.43	0.86	0.87	0.33	-0.53	-0.24	-0.26	0.15	0.47	-0.22	0.05	0.34	0.46	-0.33	-0.25
N9 (Centeno)	-0.23	0.53	0.51	-0.28	0.89	0.73	0.29	-0.22	-0.19	-0.29	0.11	-0.03	-0.15	0.42	0.27	0.38	-0.11	-0.06
H9 (Pasto)	0.53	0.14	0.06	0.58	0.80	0.75	-0.22	0.59	0.55	0.48	0.85	0.79	0.00	0.68	0.70	-0.86	-0.42	-0.39

**Tabla 5.11.** Correlación (r Pearson) entre las mediciones de campo y la diferencia de fase de polarización (PPD), para los tres ángulos de incidencia (25°, 31° y 36°). Las correlaciones a un nivel de significación del 95% están sombreadas.

	Altura			Biomasa			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Trigo)	-0.49	0.69	0.36	-0.47	0.46	0.03	0.28	-0.82	-0.71	-0.35	-0.29	-0.75	-0.44	-0.24	-0.62	0.39	-0.08	-0.01
L7 (Trigo)	-0.61	0.93	0.89	-0.65	0.64	0.35	0.44	-0.71	-0.77	-0.35	-0.14	-0.50	-0.03	-0.62	-0.83	0.54	-0.40	-0.42
K10 (Trigo)	-0.67	-0.33	-0.02	-0.39	-0.76	-0.54	0.51	-0.11	-0.42	-0.24	-0.59	-0.88	-0.01	0.02	-0.47	0.65	0.03	-0.09
F11 (Cebada)	-0.35	-0.66	-0.24	-0.40	-0.36	0.46	-0.23	0.24	0.36	-0.36	0.01	0.69	-0.39	0.02	0.68	0.64	0.28	0.13
M9 (Cebada)	-0.48	0.40	-0.04	-0.53	0.65	0.12	0.36	0.29	-0.08	-0.33	0.95	0.39	-0.28	0.91	0.23	0.49	-0.37	0.53
N9 (Centeno)	-0.57	0.36	0.39	-0.74	0.80	-0.42	0.46	-0.08	-0.71	-0.33	0.13	-0.48	-0.32	0.48	-0.81	0.45	-0.04	-0.44
H9 (Pasto)	-0.52	0.37	-0.06	-0.29	0.82	0.66	0.51	0.39	0.60	-0.15	0.84	0.73	0.30	0.44	0.75	0.74	-0.66	-0.34

## 5.4. Clasificación de la cobertura del suelo y evaluación de la exactitud

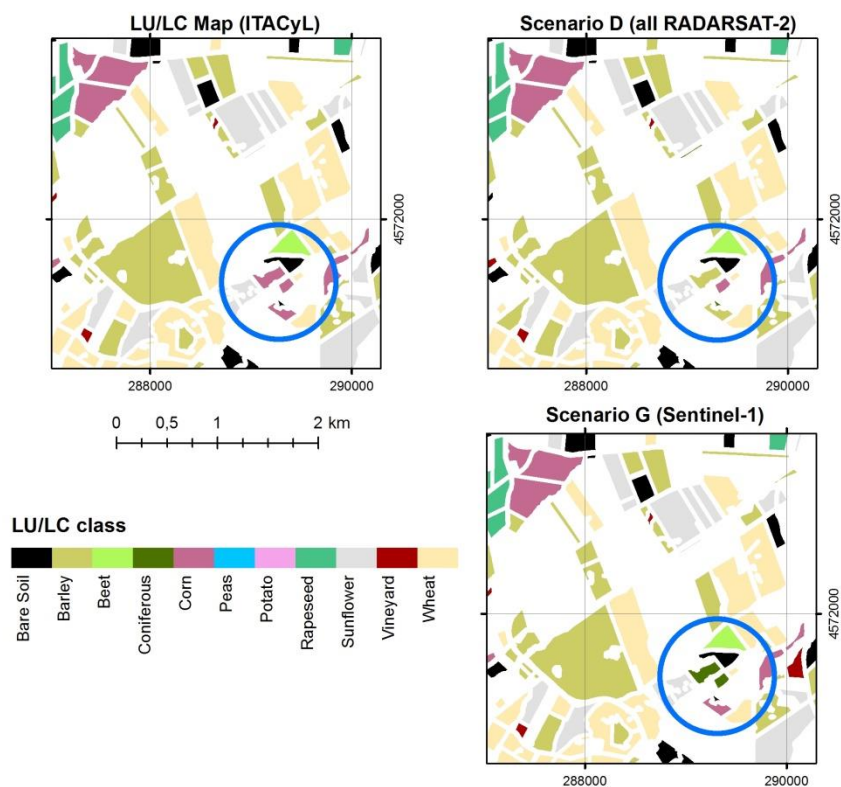
A partir de cada escenario de clasificación se puede generar un nuevo mapa de cobertura del suelo. La Figura 5.12 muestra un área detallada de dichos mapas para los escenarios A y D como un ejemplo dado. Como se puede observar, las diferencias entre ellos y con el mapa de referencia son mínimas. Luego, para cada mapa, se realizó una evaluación de la precisión de la clasificación. La precisión general de la clasificación y el coeficiente *kappa* se proporcionan en la Tabla 5.12. La precisión general para todos los escenarios varió de 83% a 89,1%, mientras que para el coeficiente *kappa* la variación fue de 0,79 a 0,88. La mayor precisión se logró utilizando todos los observables polarimétricos y todas las escenas de RADARSAT-2 (escenario D). Cuando se usaron datos SAR de Sentinel-1 *dual-pol* como entrada para la clasificación, se obtuvo la segunda mejor precisión (87,1%), mientras que el uso de datos RADARSAT-2 *dual-pol* (escenario F) proporcionó una precisión general similar (86%). La precisión de los datos de RADARSAT-2 *dual-pol* en el cómputo general de este estudio mostró una mayor precisión que los estudios previos en la literatura (Larrañaga and Álvarez-Mozos, 2016; Skakun et al., 2016). De los escenarios analizados con imágenes RADARSAT-2, las precisiones de 89,1% y 86,6% para los escenarios D y A, fueron bastante similares, sin embargo, D requirió muchas más imágenes y parámetros SAR que A para lograr esta pequeña mejora de precisión del 2.5%. Teniendo en cuenta esa observación y considerando la eficiencia y los costos de los datos SAR, se concluiría que el escenario A es más adecuado para la clasificación que el escenario D.

Desde el lanzamiento en abril de 2014 del Sentinel-1 por la ESA, los investigadores han afirmado la viabilidad de los datos Sentinel-1 *dual-pol* como entrada independiente (Balzter et al., 2015; Son et al., 2018) o combinados con datos ópticos (Kussul et al., 2016; Sonobe et al., 2017; Zhou et al., 2017) para la clasificación de LU/LC. Bargiel (2017) demostró un nuevo enfoque de clasificación de cultivos que identifica patrones de secuencia fenológica de los tipos de cultivos a partir de una pila de datos de Sentinel-1. Sugirió el uso de observables SAR multitemporales como un factor crucial para la mejora de la clasificación de cultivos.

También se ha explorado la influencia del ángulo de incidencia para la clasificación de cultivos. Cuando el clasificador utilizó los observables polarimétricos derivados de imágenes a 36°, 31° y 25°, las precisiones generales variaron de 83% a 86,6%, y de 0,79 a 0,84 para los coeficientes *kappa* (Tabla 5.12). La variación del ángulo de incidencia parece no influir significativamente en la clasificación en términos de precisión general, ya que se observó que la precisión más alta del 86,6% (escenario A) fue solo un poco mejor (~3,5%) que la precisión más baja (escenario C). En principio, se prefieren ángulos de incidencia menos pronunciados para la identificación de cultivos (Rosenthal and Blanchard, 1984) debido a la importancia de estos ángulos para minimizar las contribuciones de retrodispersión del suelo. Sin embargo, no hay evidencia concluyente en la literatura sobre qué ángulo o rango de ángulos son los más adecuados para su uso en clasificaciones. Por lo tanto, la influencia del ángulo de



incidencia parece ser muy baja, lo que abre el camino para combinar todos los ángulos de incidencia disponibles (como en el escenario D).



**Figura 5.12.** Tres subconjuntos del mapa de referencia (arriba, izquierda) y los mapas resultantes después de la clasificación de los escenarios A y D (derecha). Se detectan algunas pequeñas diferencias en el área delimitada.

Fuente: Valcarce-Diñeiro et al. (2019).

**Tabla 5.12.** Precisión general y coeficiente *kappa*.

Escenario	Precisión general (%)	<i>kappa</i>
A	86,6	0,84
B	84,5	0,81
C	83	0,79
D	89,1	0,88
E	85,1	0,82
F	86	0,83
G	87,1	0,84

Con respecto al muestreo de entrenamiento/validación, como se mencionó en el Capítulo 4, se utilizó un criterio del 60-40%, es decir, se seleccionó un muestreo aleatorio que contenía el 60% de las muestras de los datos como conjunto de datos de entrenamiento y el 40% restante como conjunto de datos de validación. Como análisis de sensibilidad, y para probar la dependencia de la precisión de la muestra de entrenamiento/validación, se realizó una nueva clasificación de todos los escenarios utilizando un muestreo aleatorio totalmente nuevo (preservando el criterio del 60-40%). La Tabla 5.13 muestra los nuevos resultados, donde está claro que la precisión general es bastante similar a los resultados que se muestran en la Tabla 5.12. Las mayores diferencias en la precisión general se muestran para los escenarios A (1,2%), B (0,9%) y C (0,8%), mientras que para el escenario D no hubo ninguna diferencia. Asimismo, las diferencias para el coeficiente *kappa* fueron insignificantes. Por lo tanto, se puede concluir que debido al alto número de muestras, la precisión no varía según la selección de muestreo.

**Tabla 5.13.** Muestreo aleatorio: precisión general y coeficiente *kappa*.

Escenario	Precisión general (%)	<i>kappa</i>
A	85,4	0,82
B	83,6	0,80
C	83,2	0,79
D	89,1	0,87
E	84,3	0,81
F	85,7	0,83
G	87,3	0,85

Un indicador importante de una clasificación exitosa es la alta precisión general; sin embargo, obtener una discriminación aceptable a nivel de cultivo individual es tan importante como una alta precisión general, especialmente para algunas aplicaciones. Con este objetivo, las precisiones del productor y del usuario para las cubiertas individuales se muestran en la Tabla 5.14.

Los resultados mostraron que la colza logró los mejores resultados de PA (> 95%) en todos los escenarios, mientras que la cebada logró el segundo PA más alto, con un rango de 92,1% a 95,3%. La precisión del usuario (UA) de ambos cultivos fue superior al 85% para todos los escenarios probados y alcanzó el 100% para la colza en los escenarios A (Tabla 5.15) y D (Tabla 5.18). Los resultados obtenidos en este estudio para la colza coinciden con los encontrados por Larrañaga and Álvarez-Mozos (2016). Los cereales (es decir, el trigo y la cebada) normalmente muestran un comportamiento similar durante la temporada de crecimiento debido a que la estructura de la planta y la fenología son muy similares, lo que causa dificultad para separarlos en función de sus características de retrodispersión. Sin embargo, los resultados mostraron que los datos SAR polarimétricos en la banda C fueron capaces de clasificar el trigo y la cebada con altos niveles de PA que van desde el 79,9% al 95,3%. Entre estos cultivos, la cebada logró mejores resultados que el trigo, con altos niveles de PA

(95,1%, 95,1% y 95,3%) para los escenarios A, E y D. De acuerdo con el resultado obtenido en el escenario D para la cebada, Larrañaga and Álvarez-Mozos (2016) también obtuvieron un PA alto para la cebada cuando se añadieron diferentes observables polarimétricos a los datos lineales *quad-pol* H-V. La mayor precisión para el trigo (88,3% y 88,1%) tuvo lugar cuando se utilizaron datos de polarización dual Sentinel-1 (escenario G) o todos los observables polarimétricos e imágenes para la clasificación (escenario D). En las matrices de confusión específicas para los escenarios D y G (Tablas 5.18 y 5.21), la mayoría de las parcelas de trigo se clasificaron correctamente (356 de 404 para el escenario D y 364 de 412 para el escenario G). Solo se produjo una pequeña clasificación errónea entre el trigo y la cebada, lo que se explica por su estructura vegetal similar. Como se muestra en la Tabla 5.14, el escenario RADARSAT-2 *dual-pol* (F) mostró buenos resultados (92,1% y 81,2%) para cebada y trigo, respectivamente. Los resultados presentados de los escenarios *dual-pol* sugieren que el modo de polarización dual VH/VV es una buena opción para discriminar los cereales de otros cultivos, y está de acuerdo con los hallazgos de McNairn et al. (2009a) y Veloso et al. (2017). Aunque se encontró que la cebada y el trigo están bien clasificados, el valor del PA y el UA del tercer cereal considerado, el maíz, no son tan buenos como se esperaba con respecto a los resultados encontrados en la literatura (Skakun et al., 2016). El mejor PA se mostró en el escenario G con los datos de polarización dual del Sentinel-1 (78,4%) y el escenario E (78,2%). El maíz en el escenario C también proporcionó la segunda PA más baja en este estudio, con solo el 54% de las parcelas de maíz clasificadas correctamente. Como se muestra en la Tabla 5.17, 23 parcelas no fueron clasificadas como maíz, siendo el viñedo el que proporcione una mayor confusión con el maíz. Mientras que el escenario B mostró de forma general la segunda peor PA (65%) para este cultivo. Nuevamente como sucedió para el escenario C, el maíz fue clasificado erróneamente con el viñedo como se muestra en la Tabla 5.16.

Las precisiones más bajas se encontraron para las patatas en 4 de los 7 escenarios, seguidos del maíz. El escenario G es el peor de todos los escenarios, con una PA del 45,8%; esto significa que la clasificación en este escenario omitió el 54,2% de las áreas de patata en el suelo, lo que indica una tendencia para que el modelo clasifique mal las patatas. Debido a sus hojas anchas, las patatas se clasifican principalmente como remolacha (Tabla 5.21), que también tienen una estructura vegetal similar. De todos los escenarios analizados para la remolacha, el escenario A (RADARSAT-2 a 36°) proporcionó la PA más alta (93,2%) seguido del escenario E (83,7%). El escenario G (datos de Sentinel-1 utilizando los coeficientes de retrodispersión y el ratio) también proporcionó una alta precisión (82,9%) para la remolacha. La precisión presentada en este estudio con los datos de Sentinel-1 es mayor que la precisión proporcionada por Sonobe et al. (2017). Lograron una PA del 74,6% utilizando KELM (*Kernel-based Extreme Learning Algorithm*) y datos de polarización VV.

La PA del suelo desnudo alcanzó la mayor precisión (92,9%) en el escenario D y precisiones superiores al 84% para el resto de los escenarios. Los buenos resultados que se obtuvieron para el suelo desnudo podrían estar relacionados con el uso de la polarización cruzada como una de las entradas para el clasificador. El uso de la polarización cruzada facilita la distinción entre el suelo desnudo y las superficies cubiertas de vegetación porque el dosel de la vegetación despolariza la radiación incidente con más fuerza que las superficies desnudas. Aunque el suelo desnudo proporcionó una PA alta en el escenario D, 120 parcelas de suelo desnudo se clasificaron erróneamente (Tabla

5.18); esto muestra, junto con el viñedo, la mayor confusión (61 parcelas, aproximadamente el 7% del total de esta categoría).

También se ha investigado el potencial de las imágenes SAR para clasificar los viñedos. Las mediciones en viñedos no son fáciles, dada la gran cantidad de postes y alambres metálicos que sostienen las espalderas y el espacio entre éstas. Como se esperaba, no se lograron altas precisiones para los viñedos. El escenario A (datos RADARSAT-2 a 36°) mostró el PA más alto (73,5%) y el escenario C el más bajo (61,3%). Para el escenario C se utilizaron datos de RADARSAT-2 a 25°, por lo que esta pobre precisión podría estar relacionada con el hecho de que en la banda C, los ángulos pronunciados son más sensibles a las condiciones del terreno y menos sensibles a las características de la planta; en contraste, los ángulos más bajos aumentan la interacción con la vegetación, por lo tanto reducen la contribución del suelo y aumentan la posibilidad de obtener una mayor precisión, como se muestra para el escenario A. A pesar de que se obtienen los resultados más pobres para el viñedo en relación con otras cubiertas de tierra, su precisión podría considerarse aceptable.

Los datos SAR de la banda L proporcionan una excelente fuente de información para el mapeo de la cubierta forestal, y disminuye la clasificación errónea entre las cubiertas debido a su capacidad de penetración significativa en relación con las copas de la vegetación. Nuestros resultados mostraron altas PA y UA, que van desde 83,1% a 91,5% y 82,5% a 94,9%. Se descubrió que el escenario F (datos *dual-pol* de RADARSAT-2) proporcionó el mejor PA que fue ligeramente más alto (0.5%) que el escenario E (91%). En las matrices de confusión para los escenarios E (Tabla 5.19) y F (Tabla 5.20) se muestra cómo las áreas forestales se clasificaron correctamente. Por lo tanto, podríamos concluir que los datos SAR de la banda C fueron capaces de proporcionar una clasificación fiable de las coníferas.

El girasol y los guisantes también fueron analizados. El girasol obtuvo una PA por encima del 81% en todos los escenarios, con la excepción del escenario C, que proporcionó una PA del 74,2%. Los escenarios *dual-pol* de datos SAR (G y F) mostraron las precisiones más altas (90% y 89,1%). Los resultados encontrados para el girasol utilizando datos de doble polarización mejoraron los resultados encontrados por Skakun et al. (2016). Sin embargo, Larrañaga and Álvarez-Mozos (2016) obtuvieron una PA del 100% para el girasol cuando aplicaron la configuración VV-VH *dual-pol* de RADARSAT-2 con solo dos coeficientes de retrodispersión en los dos canales de polarización. La diferencia en la precisión (~11%) entre sus resultados y nuestros hallazgos podría estar relacionada con el hecho de que añadimos la relación (VH/VV) como entrada en el clasificador, y porque el número de parcelas de girasol e imágenes es mayor. Skakun et al. (2016) utilizó la intensidad de retrodispersión RADARSAT-2 (VV, VH y HH) en modo de haz (FQ8W) con un ángulo de incidencia de 26,1° a 29,4° para realizar una clasificación de cultivos multitemporales en Ucrania. Encontraron PA y UA del 60% y 63,5% para el girasol. Aunque la precisión más baja (74,2%) encontrada para el girasol se produjo cuando se usaron datos RADARSAT-2 a 25° en el clasificador, este estudio demostró que el uso de diferentes observables polarimétricos (más allá de los coeficientes de retrodispersión) mejoró la clasificación del girasol cuando se utilizan los datos SAR con ángulos de baja incidencia en el clasificador.

Finalmente, para los guisantes, la PA más alta se encontró en el escenario D (95,9%), cuando el clasificador empleó todos los observables polarimétricos e imágenes. Sin embargo, existe una gran diferencia (19,2%) entre la precisión más alta y la más baja (76,7%) proporcionadas por el escenario C.

En términos de UA, después de la colza y las coníferas, los guisantes mostraron la mayor precisión (escenario A, 93,7%; escenario F, 95,9%). Los resultados encontrados para los guisantes en este estudio mejoraron los encontrados por Larrañaga and Álvarez-Mozos (2016). La Tabla 5.18 muestra que en este estudio solo se confundieron tres parcelas de guisantes con cebada y suelo desnudo.

Además de la precisión de las diferentes combinaciones de observables SAR, los análisis individuales LU/LC proporcionaron una visión interesante de la viabilidad de la serie multitemporal. Después de los resultados mencionados anteriormente, la mejor clasificación se realizó para la colza, cebada, trigo y guisantes, los cuales son cultivos de primavera, que tienen su ciclo de crecimiento entre marzo y junio, cuando la disponibilidad de imágenes es mayor (Tabla 4.4). Por el contrario, los peores resultados se encontraron para los cultivos de verano, con ciclos de crecimiento que abarcan hasta el comienzo del otoño (maíz, patatas y viñedos), que no están cubiertos por la serie SAR. Aunque con resultados razonablemente buenos, los girasoles, la remolacha y las patatas también son cultivos de verano y no pudieron lograr los resultados óptimos encontrados para los cultivos de primavera. Este resultado corrobora la hipótesis de que la estrategia mejora claramente los resultados de la clasificación polarimétrica.

**Tabla 5.14.** Precisiones del productor (PA) y del usuario (UA) de los tipos de cobertura individuales para los datos del RADARSAT-2 y Sentinel-1.

	A		B		C		D		E		F		G	
	PA	UA	PA	UA	PA	UA	PA	UA	PA	UA	PA	UA	PA	UA
Cebada	95,1	89,2	92,2	85,5	92,5	92	95,3	92,6	95,1	89,5	92,1	88,4	93,9	89,7
Colza	95,4	100	97,4	94,9	98,5	95,6	98,3	100	98,5	94,2	98,5	95,5	98,2	94,8
Conífera	90,3	87,8	89,5	91,9	83,1	82,5	89,7	94,9	91	88,8	91,5	89,9	85,7	86,8
Girasol	81,4	85,2	84,7	81,4	74,2	78,3	85,5	88,9	81,6	74,4	89,1	81,7	90	91
Guisante	82,6	92,2	87,9	90,1	76,7	82,1	95,9	92,2	86,8	88	85,7	92,3	88,7	90
Maíz	72,6	83,3	65	86,7	54	71,1	72,5	74	78,2	76,8	67,2	86,7	78,4	81,6
Viñedo	73,5	80	65,4	70,1	61,3	63,9	72,7	81,2	69,9	74,4	69	76,9	67,8	79,9
Trigo	81,9	91,1	79,9	88,1	87,2	88,3	88,1	93,7	80,6	90,9	81,2	87,3	88,3	93,1
Suelo desnudo	88,6	83,6	87	85,6	86,4	82,5	92,9	86,1	84,4	86,2	88,5	86,9	88,3	82,8
Remolacha	93,2	91,1	80	82,3	82,4	62,2	81,3	79,6	83,7	87,8	72,5	87,9	82,9	78,4
Patata	75	83,3	60	75	57,1	66,7	56	87,5	76,2	76,2	75	62,1	45,8	78,6

**Tabla 5.15.** Matriz de confusión del escenario A.

		Datos Referencia										
		Cebada	Colza	Conifera	Girasol	Guisante	Maíz	Viñedo	Trigo	Suelo desnudo	Remolacha	Patata
Datos Clasificados	Cebada	713				7	1	2	65	10		1
	Colza		62									
	Conifera			130			1	3		14		
	Girasol				276		2	14		32		
	Guisante	2	2			71				2		
	Maíz				4		45	1		1	1	2
	Viñedo			3	14	1	9	236		31		1
	Trigo	26				2			317	3		
	Suelo desnudo	9	1	11	44	5	2	64	5	721		
	Remolacha						2	1			41	1
	Patata				1						2	15

**Tabla 5.16.** Matriz de confusión del escenario B.

		Datos Referencia										
		Cebada	Colza	Conifera	Girasol	Guisante	Maíz	Viñedo	Trigo	Suelo desnudo	Remolacha	Patata
Datos Clasificados	Cebada	666				6	2	5	81	16		3
	Colza	2	74	1		1						
	Conifera	1		136	1			4		6		
	Girasol				294		4	28		34		1
	Guisante	1	2			73				5		
	Maíz				1		39	1	1	1	1	1
	Viñedo			7	21		10	197		41	2	3
	Trigo	44							339	2		
	Suelo desnudo	8		8	29	3	1	66	3	702		
	Remolacha						4				28	2
	Patata				1						4	15

**Tabla 5.17.** Matriz de confusión del escenario C.

		Datos Referencia										
		Cebada	Colza	Conifera	Girasol	Guisante	Maíz	Viñedo	Trigo	Suelo desnudo	Remolacha	Patata
Datos Clasificados	Cebada	692	1	2	2	6		7	31	9	1	1
	Colza	2	65			1						
	Conífera	1		118		1	3	7	1	12		
	Girasol	1		1	253		4	36	1	27		
	Guisante	5		1	1	69		2	3	3		
	Maíz				3		27	3		1	4	
	Viñedo			5	45	1	9	200		51	1	1
	Trigo	31			3	1		1	333	8		
	Suelo desnudo	14		14	33	10	2	65	13	719		1
	Remolacha	1			1		4	4		1	28	6
	Patata	1		1		1	1	1		1		12

**Tabla 5.18.** Matriz de confusión del escenario D.

		Datos Referencia										
		Cebada	Colza	Conifera	Girasol	Guisante	Maíz	Viñedo	Trigo	Suelo desnudo	Remolacha	Patata
Datos Clasificados	Cebada	717	1			2	3	4	41	4	1	1
	Colza		59									
	Conífera			148	1			1	1	5		
	Girasol			2	295		3	15		15	1	1
	Guisante	3			1	71			1	1		
	Maíz				4		37	2			5	2
	Viñedo	3		1	12		6	224		30		
	Trigo	21		1					356	2		
	Suelo desnudo	8		12	31	1		61	5	743		2
	Remolacha			1	1		2	1			39	5
	Patata										2	14

**Tabla 5.19.** Matriz de confusión del escenario E.

		Datos Referencia										
		Cebada	Colza	Conifera	Girasol	Guisante	Maíz	Viñedo	Trigo	Suelo desnudo	Remolacha	Patata
Datos Clasificados	Cebada	718		1		5	1	7	63	7		
	Colza	1	65			1			2			
	Conífera			142				5		13		
	Girasol				270		1	28		64		
	Guisante	6				66				2		1
	Maíz				1		43	8			3	1
	Viñedo			8	18		7	230	1	37	3	5
	Trigo	26	1			1			308	2	1	
	Suelo desnudo	4		4	40	3		51	7	687		1
	Remolacha				1		1			2	36	1
	Patata			1	1		2		1			16

**Tabla 5.20.** Matriz de confusión del escenario F.

		Datos Referencia										
		Cebada	Colza	Conifera	Girasol	Guisante	Maíz	Viñedo	Trigo	Suelo desnudo	Remolacha	Patata
Datos Clasificados	Cebada	689	1	1	1	8	1	9	64	5		
	Colza	1	64			1				1		
	Conífera			151				2	1	12	2	
	Girasol			1	295		7	21		37		
	Guisante	3				60				2		
	Maíz				2		39	3				1
	Viñedo	2		5	15		8	227	1	34	1	2
	Trigo	42						1	310	2		
	Suelo desnudo	11		7	18	1		65	6	726		1
	Remolacha							1		1	29	2
	Patata						3				8	18



**Tabla 5.21.** Matriz de confusión del escenario G.

		Datos Referencia										
		Cebada	Colza	Conifera	Girasol	Guisante	Maíz	Viñedo	Trigo	Suelo desnudo	Remolacha	Patata
Datos Clasificados	Cebada	703	1	2		2		9	38	26	1	2
	Colza	1	55	1						1		
	Conifera	2		132			2	3		13		
	Girasol				323		2	10		19		1
	Guisante	4				63			1	2		
	Maíz				1		40	2		1	2	3
	Viñedo	3		6	17	1	4	227	1	24		1
	Trigo	18		2		1			364	6		
	Suelo desnudo	18		11	18	4		84	8	694	1	
	Remolacha						2				29	6
	Patata						1				2	11

## 5.5. Evaluación de los atributos

C5.0 muestra el grado en que cada atributo (SAR observable por fecha) contribuye al clasificador y proporciona el porcentaje de casos de entrenamiento en el archivo de datos para el cual el valor de ese atributo es conocido y utilizado para la construcción del clasificador. Debido a la gran cantidad de atributos utilizados para cada escenario, la evaluación de atributos proporcionada por C5.0 es muy útil para saber cómo los atributos individuales contribuyen a la construcción del clasificador.

La Figura 5.13 muestra el uso de atributos en los primeros tres escenarios (A, B y C) que se ejecutaron con 70, 60 y 60 atributos, respectivamente. En términos de observables polarimétricos, se puede ver claramente la importancia del ángulo alfa dominante ( $\alpha_1$ ), seguido del coeficiente de retrodispersión (HV) y los ratios de retrodispersión (HH/VV y HV/VV). El uso de estos observables polarimétricos en fechas de adquisición específicas implica que la información que suministraban era útil para la separación de cultivos. Además, la contribución de la correlación entre los canales copolares ( $\gamma_{HHVV}$ ) es importante en el escenario A. Los observables polarimétricos menos importantes utilizados en estos escenarios fueron VV,  $\gamma_{P1P2}$  y la fase de diferencia polarizada (PPD).




Figura 5.13. Contribución de los atributos en los escenarios A, B y C. Fuente: Valcarce-Diñeiro et al. (2019).

El escenario D (Figura 5.14) fue el escenario más complejo probado en este estudio con 200 atributos utilizados. Al igual que los escenarios A, B y C, el ángulo alfa dominante ( $\alpha_1$ ),  $\gamma_{HHV}$  y el coeficiente de retrodispersión de polarización cruzada (HV) son los observables más importantes. Muchos observables polarimétricos en ciertas fechas muestran un porcentaje nulo, principalmente porque C5.0 no muestra los atributos con valores inferiores al 1%.

Los atributos de los últimos tres escenarios (E, F y G) se muestran en la Figura 5.15. Estos escenarios utilizaron 56 (E), 42 (F) y 42 (G) atributos. El escenario E mostró una clara influencia de  $\gamma_{HHV}$  el 29 de abril, con el 100% de los casos utilizados en el clasificador. En los escenarios F y G (con solo tres observables polarimétricos utilizados), las relaciones de la polarización cruzada (HV/VV y VH/VV) proporcionaron un alto peso al clasificador.




Figura 5.14. Contribución de los atributos en el escenario D. Fuente: Valcarce-Diñeiro et al. (2019).

En cuanto a las fechas de adquisición, las escenas RADARSAT-2 con mayor importancia, junto con los observables polarimétricos, fueron el 29 de abril, 06 de mayo y 13 de mayo. Para Sentinel-1, las imágenes fueron del 26 de abril y 08 de mayo. Skriver (2007) presentó un estudio para determinar los parámetros óptimos para la clasificación utilizando datos SAR polarimétricos aéreos de banda C y L. Descubrió que en la banda C, la adquisición temprana, es decir, en abril, tiene un alto potencial de discriminación, pero la adquisición de mayo ofrece el mayor potencial de discriminación. También informó que para mayo, el coeficiente de correlación entre HH y VV, así como la relación entre HV y VV (entre otros) mostraron un claro potencial de separación. Los resultados de este estudio concuerdan con estos hallazgos. El hecho de que abril y mayo hayan tenido mayor relevancia en la serie multitemporal no es de extrañar, ya que, como se mencionó anteriormente, durante este intervalo coinciden las etapas de crecimiento vegetativo más importantes de los cultivos en el área, es decir, el crecimiento máximo para los cultivos de primavera y etapa de desarrollo de los cultivos de verano.

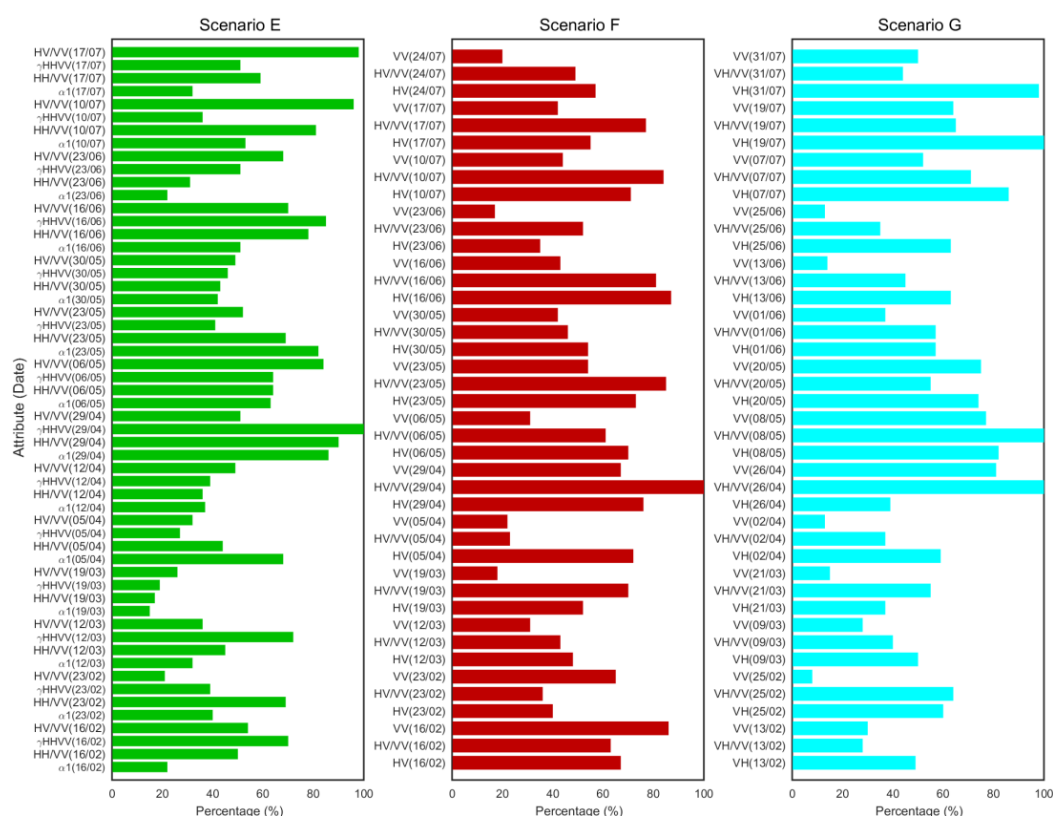



Figura 5.15. Contribución de los atributos en los escenarios E, F and G. Fuente: Valcarce-Diñeiro et al. (2019).

Como prueba final de la evaluación de la importancia del atributo se realizó un análisis de cultivos por pares para estimar qué observable contribuyó más a distinguir el trigo y la cebada, que tienen una estructura similar y, por lo tanto, se espera que también tengan una respuesta de la señal similar. Esta prueba se realizó para el escenario D como un ejemplo dado, que reúne todos los atributos posibles. El análisis por parejas resultante entre estos dos cultivos (Figura 5.16) mostró que HH/VV era el contribuyente más alto (100%) para separar ambos cultivos, seguido de  $\gamma_{HHVV}$ .

Con respecto a las fechas de adquisición, el análisis por pares con RADARSAT-2 enfatizó la mayor importancia del 13 de mayo como una fecha clave que refleja el ciclo de cultivo de cereales.



**Figura 5.16.** Atributos principales (20) utilizados para el análisis por pares. Fuente: Valcarce-Diñeiro et al. (2019).

### 5.5.1. Posibles aplicaciones del análisis de importancia de los atributos

El objetivo del análisis anterior era evaluar el peso de cada observable en la clasificación para evitar datos redundantes o inútiles sin perder precisión. Al elegir el escenario D como ejemplo, se probó la viabilidad de un conjunto de datos reducido para la clasificación. Primero, se creó un nuevo escenario (H) utilizando los observables polarimétricos con las tres contribuciones más altas en D:  $\gamma$ HHVV, HV y  $\alpha$ 1 (Figura 5.14).

Al comparar los resultados de clasificación para D y H, se encontró una ligera diferencia (0,7%) entre el escenario D (89,1%) y el escenario H (88,4%) en términos de precisión general. A nivel de cultivo individual (Tabla 5.22), el uso de atributos con la contribución más alta mejoró la precisión de PA y UA de algunos cultivos en comparación con los resultados del escenario D (Tabla 5.22). Para cultivos como el viñedo, la remolacha y la patata, la mejora de la PA entre el escenario D y H fue de aproximadamente 5%, y el maíz mostró la mayor diferencia (8,3%). Otros cultivos, como los guisantes, mostraron una ligera disminución en la PA del escenario H (88,2%) al escenario D (95,9%).

Considerando todos los datos, la precisión del escenario H es similar al escenario D, al tiempo que reduce el número de observables y, por lo tanto, haciéndolo mucho más rentable.

**Tabla 5.22.** Precisiones del productor (PA) y del usuario (UA) de los tipos de cobertura individuales utilizando solo observables seleccionados (escenario H) y todo el conjunto de datos (escenario D).

	H		D	
	PA	UA	PA	UA
Cebada	95,2	93,5	95,3	92,6
Colza	98,3	93,5	98,3	100
Conífera	91,2	90,1	89,7	94,9
Girasol	86,1	85,9	85,5	88,9
Guisante	88,2	97,4	95,9	92,2
Maíz	80,8	85,7	72,5	74
Viñedo	77,3	75,6	72,7	81,2
Trigo	90,2	90,6	88,1	93,7
Suelo desnudo	86,8	87,9	92,9	86,1
Remolacha	86,7	84,8	81,3	79,6
Patata	60,7	73,9	56	87,5

El segundo análisis consistió en una nueva clasificación solo para los cultivos por pares, trigo y cebada, utilizando únicamente los principales observables resultantes del análisis de importancia de la sección anterior, es decir, HH/VV y  $\gamma_{HHVV}$  (escenario I). La evaluación de la precisión de este nuevo escenario (Tabla 5.23) es notable en comparación con los resultados anteriores del escenario D, en el que se incluyeron todos los observables. Tanto la PA como la UA aumentaron en I, lo que significa que el análisis de importancia proporcionó una herramienta útil para separar cultivos con una respuesta similar, incluso mejorando la precisión de la clasificación y reduciendo efectivamente los datos de entrada necesarios (de 10 a 2, en este caso).

Para explorar la clasificación de cultivos por pares con entradas limitadas, se realizó un tercer análisis (denominado escenario J) a partir de datos de RADARSAT-2. Este escenario se llevó a cabo utilizando solo los dos observables principales del escenario I (HH/VV y  $\gamma_{HHVV}$ ) y las tres fechas con mayor importancia (29 de abril, 06 de mayo y 13 de mayo). Al comparar los resultados del escenario J (Tabla 5.23) con el escenario I anterior, es notable que la precisión ha disminuido, pero en una medida muy pequeña dado el conjunto de datos reducido incluido en J. De hecho, si se compara con los escenarios generales A-G (con mucho más observables y fechas polarimétricas), la precisión proporcionada por el escenario J es ligeramente mayor (~0,5%) que los escenarios B y F, mientras que para el trigo el PA es más alto que para los escenarios A, B, E y F. Una vez más, los resultados del

análisis de importancia permitieron una forma de reducir las entradas mientras se mantenía una precisión notable.

**Tabla 5.23.** Precisiones del productor (PA) y del usuario (UA) de cebada y trigo utilizando todo el conjunto de datos (escenario D), solo observables seleccionados (escenario I) y observables y fechas seleccionados (escenario J).

	D		I		J	
	PA	UA	PA	UA	PA	UA
Cebada	95,3	92,6	96,3	96,5	92,7	92,2
Trigo	88,1	93,7	93,4	92,9	85,2	86





CAPÍTULO 6:  
CONCLUSIONES



## Capítulo 6: Conclusiones

Esta tesis doctoral se ha dedicado a explorar la diversidad polarimétrica para mejorar las técnicas relacionadas con el seguimiento/monitoreo y clasificación de cultivos agrícolas a partir de datos SAR polarimétricos, aprovechando la disponibilidad de datos de la nueva generación de satélites radar. Los beneficios de la polarimetría han sido evaluados, presentados y se ha obtenido una visión de la mejora que ofrece la polarimetría.

El conocimiento de los parámetros polarimétricos para el seguimiento/monitoreo de cultivos agrícolas demostró la idoneidad de varios parámetros polarimétricos a diferentes ángulos de incidencia para monitorear los cultivos a través del análisis de su relación con diferentes variables biofísicas de plantas y doseles.

- La respuesta SAR para muchos de los parámetros polarimétricos sugirió un patrón temporal similar al del LAI y la biomasa, confirmado con el análisis de correlación. Las correlaciones más significativas se observaron para las relaciones de retrodispersión (HH/VV y HV/VV), la correlación normalizada entre HH y VV ( $\gamma_{HHVV}$ ) y el ángulo alfa dominante ( $\alpha_1$ ) con biomasa, altura y LAI a 31° y 36° ángulos de incidencia. Por lo tanto, los mejores resultados a 31° probablemente se deban a una compensación entre el efecto de las propiedades del suelo y la atenuación debida a la vegetación.
- Una cuidada selección de parámetros polarimétricos junto con la estrategia multitemporal de imágenes se revela como una alternativa remota al monitoreo de cultivos. Se demostró que ciertas variables biofísicas tales como la biomasa, el LAI y la altura de los cultivos de secano se pueden estudiar utilizando diferentes parámetros de radar proporcionados por RADARSAT-2, a pesar de que se necesitan campañas de campo adicionales para confirmar estos resultados en diferentes áreas y cultivos. Dada la resolución espacial mejorada de las misiones recientes, incluidas RADARSAT-2 y Sentinel-1, y la futura Misión de Constelación RADARSAT (RCM), y su gran disponibilidad de datos, el uso de imágenes de radar es hoy una base confirmada para aplicaciones agrícolas a escala de parcela.

En cuanto al impacto del ángulo de incidencia:

- La relación entre los parámetros SAR y las diferentes variables biofísicas mostraron que el ángulo de 31° proporciona los mejores resultados. Las ondas de radar viajan más verticalmente a 25°, por lo que la dispersión en ángulos de incidencia más pronunciados está más influenciada por las propiedades del suelo, mientras que las ondas de radar recorren un camino más largo a través de la vegetación a 36°.

- A la hora de analizar el ángulo de incidencia sobre la clasificación, los resultados mostraron que cuando el ángulo de incidencia se consideró por separado, la variación entre los casos en términos de precisión general y *kappa* es de solo 3,5% y 6%. Después de evaluar todos los casos, se llegó a la conclusión que el ángulo de incidencia parece no influir ni en la clasificación en general ni en los resultados individuales para cada cobertura, que fueron heterogéneos y no concluyentes.

Otro de los objetivos de esta tesis consistía en la evaluar la capacidad de los observables polarimétricos de series multitemporales de imágenes RADARSAT-2 y Sentinel-1 para clasificar y distinguir cultivos agrícolas.

- El empleo de todos los observables e imágenes RADARSAT-2 demostró claros beneficios en términos de precisión general a la hora de clasificar. Sin embargo, cuando se analizó el uso de menos observables e imágenes para clasificar, se encontró que los resultados son igual de altos que cuando se emplearon todos los observables e imágenes. Para ello es necesario realizar previamente un análisis de la importancia de los atributos en el proceso de la clasificación, que permite eliminar atributos redundantes y ha demostrado ser muy útil. Por lo tanto, se puede considerar que el empleo de menos datos es más rentable que usar un extenso conjunto de datos.
- El análisis individual para cada cubierta demostró la buena separación de los cereales de primavera, típicamente difícil debido a su estructura y fenología similares. La adición de datos polarimétricos SAR de banda C al clasificador permitió clasificar el trigo y la cebada con niveles de exactitud muy altos. Sin embargo, los cultivos de verano mostraron resultados no tan buenos de exactitud, debido a la escasa cobertura de imágenes durante el verano y principios del otoño. Este hecho subraya la importancia de una cobertura multitemporal completa durante todo el ciclo fenológico.
- Aunque las capacidades polarimétricas de RADARSAT-2 (full) y Sentinel-1 (dual) son bastante diferentes, el enfoque multitemporal reforzó el proceso de clasificación y proporcionó resultados satisfactorios similares para los diferentes escenarios de clasificación propuestos. Las características adicionales que también podrían ayudar a mejorar la precisión de la clasificación de los tipos de cultivos individuales son los parámetros interferométricos, como la coherencia y la información textural dentro de los valores de intensidad. Además, se deben realizar más pruebas sobre otras condiciones climáticas y ambientales diferentes para expandir y consolidar el método.
- La contribución de cada observable SAR por fecha a las diferentes alternativas de clasificación también se analizó en esta tesis. Se llegó a la conclusión que el ángulo alfa dominante ( $\alpha_1$ ) derivado de las imágenes RADARSAT-2 mostró una mayor contribución en el algoritmo de clasificación que el resto de observables, mientras que una clasificación empleando únicamente las imágenes Sentinel-1, los más importantes

fueron el canal de polarización cruzada VH y el ratio VH/VV. Este hallazgo sobre el rendimiento de cada observable ayudaría en futuras clasificaciones al reducir el uso de datos redundantes y potencialmente engañosos. En cuanto a la fecha, las adquisiciones de Mayo dieron como resultado ser las fechas clave en la clasificación, coincidiendo con el periodo de crecimiento máximo de muchos cultivos en el área.

El estudio ha demostrado que la hipótesis de partida era correcta, es decir, que el análisis polarimétrico contribuye notablemente a la estimación cualitativa de parámetros de cultivos y vegetación y la clasificación de usos y coberturas de suelo. Los resultados de esta tesis pueden contribuir a la exploración de nuevas capacidades de la polarimetría radar en agricultura y medio ambiente.

Finalmente, mencionar que el trabajo realizado en esta tesis está respaldado por varios artículos publicados en revistas internacionales y la discusión de sus resultados en varias conferencias, disponibles en los anexos A y B.



CAPÍTULO 7:  
PERSPECTIVAS FUTURAS





## Capítulo 7: Perspectivas futuras

El cumplimiento de los objetivos planteados en este trabajo ha sido completo y se concluye con una impresión satisfactoria. Sin embargo, durante el camino se han ido despertando una serie de expectativas que pueden mejorar lo ya trabajado y que abren vías de investigación paralelas.

- ✓ Para el desarrollo de esta tesis doctoral únicamente se han empleado diez observables polarimétricos, sin embargo, parámetros adicionales como el nivel de retrodispersión en la base de Pauli, las salidas de descomposiciones basadas en modelos (por ejemplo, Freeman-Durden), cambios en la base polarimétrica (por ejemplo, polarizaciones circulares) o seleccionando modos de medición específica (por ejemplo, polarimetría compacta) podrían emplearse en un futuro para seguir analizando tanto el seguimiento como la clasificación de cultivos a partir de datos de polarimetría SAR.
- ✓ La alta correlación existente entre algunas variables biofísicas y los observables, abre la posibilidad de realizar estimaciones de estas variables a partir de observables polarimétricos empleando técnicas estadísticas o algoritmos de aprendizaje automático.
- ✓ El empleo de la coherencia interferométrica extraída de las imágenes de radar mediante la técnica de interferometría polarimétrica (PolInSAR, *Polarimetric Interferometric SAR*) e información textural, en combinación con otros observables polarimétricos, podría aportar una nueva dimensión a la investigación realizada sobre clasificación. El uso en este caso de la coherencia y la técnica PolInSAR no solo proporcionaría información sobre las propiedades dieléctricas, la forma y orientación de las plantas (como hace PolSAR), sino que también añadiría información sobre la estructura vertical de la planta; mientras que la textura proporcionada por las imágenes ayudaría a caracterizar mejor los objetivos en la imagen.
- ✓ La combinación de datos satelitales a diferentes bandas de frecuencia también será explorado en un futuro, ya que generalmente la retrodispersión de los canales de polarización a diferentes frecuencias tienen patrones distintos que dependen del crecimiento del cultivo, lo que ayudaría a diferenciar mejor cultivos agrícolas, proporcionando por lo tanto una mayor exactitud en la clasificación.



## BIBLIOGRAFÍA



## Bibliografía

- Abràmoff, M.D., Magalhães, P.J., Ram, S.J., 2004. Image processing with imageJ. *Biophotonics Int.* 11, 36–42. doi:10.1201/9781420005615.ax4
- Adams, J.R., Berg, A.A., McNairn, H., Merzouki, A., 2013a. Sensitivity of C-band SAR polarimetric variables to unvegetated agricultural fields. *Can. J. Remote Sens.* 39, 1–16. doi:10.5589/m13-003
- Adams, J.R., Rowlandson, T.L., McKeown, S.J., Berg, A.A., McNairn, H., Sweeney, S.J., 2013b. Evaluating the Cloude-Pottier and Freeman-Durden scattering decompositions for distinguishing between unharvested and post-harvest agricultural fields. *Can. J. Remote Sens.* 39, 318–327. doi:10.5589/m13-040
- Ali, M., 2013. *Climate Change Impacts on Plant Biomass Growth*. Springer, Dordrecht, Netherlands. doi:10.1007/978-94-007-5370-9
- 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 Sens.* 12, 278. doi:10.3390/rs12020278
- Baghdadi, N.N., El Hajj, M., Zribi, M., Fayad, I., 2016. Coupling SAR C-Band and Optical Data for Soil Moisture and Leaf Area Index Retrieval over Irrigated Grasslands. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 9, 1229–1243. doi:10.1109/JSTARS.2015.2464698
- Balenzano, A., Mattia, F., Satalino, G., Davidson, M.W.J., 2011. Dense Temporal Series of C- and L-band SAR Data for Soil Moisture Retrieval Over Agricultural Crops. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 4, 439–450. doi:10.1109/JSTARS.2010.2052916
- Balzter, H., Cole, B., Thiel, C., Schmullius, C., 2015. Mapping CORINE Land Cover from Sentinel-1A SAR and SRTM Digital Elevation Model Data using Random Forests. *Remote Sens.* 7, 14876–14898. doi:10.3390/rs71114876
- Ban, Y., 2003. Synergy of multitemporal ERS-1 SAR and Landsat TM data for classification of agricultural crops. *Can. J. Remote Sens.* 29, 518–526. doi:10.5589/m03-014
- Baret, F., Weiss, M., Lacaze, R., Camacho, F., Makhmara, H., Pacholczyk, P., Smets, B., 2013. GEOV1: LAI and FAPAR essential climate variables and FCOVER global time series capitalizing over existing products. Part1: Principles of development and production. *Remote Sens. Environ.* 137, 299–309. doi:10.1016/j.rse.2012.12.027
- Bargiel, D., 2017. A new method for crop classification combining time series of radar images and crop phenology information. *Remote Sens. Environ.* 198, 369–383. doi:10.1016/j.rse.2017.06.022
- Becker-Reshef, I., Justice, C., Sullivan, M., Vermote, E., Tucker, C., Anyamba, A., Small, J., Pak, E., Masuoka, E., Schmaltz, J., Hansen, M., Pittman, K., Birkett, C., Williams, D., Reynolds, C., Doorn, B., 2010. Monitoring Global Croplands with Coarse Resolution Earth Observations: The Global Agriculture Monitoring (GLAM) Project. *Remote Sens.* 2, 1589–1609. doi:10.3390/rs2061589

- Bériaux, E., Waldner, F., Collienne, F., Bogaert, P., Defourny, P., 2015. Maize Leaf Area Index Retrieval from Synthetic Quad Pol SAR Time Series Using the Water Cloud Model. *Remote Sens.* 7, 16204–16225. doi:10.3390/rs71215818
- Blaes, X., Defourny, P., Wegmüller, U., Vecchia, A. Della, Guerriero, L., Ferrazzoli, P., 2006. C-band polarimetric indexes for maize monitoring based on a validated radiative transfer model. *IEEE Trans. Geosci. Remote Sens.* 44, 791–800. doi:10.1109/TGRS.2005.860969
- Blaes, X., Vanhalle, L., Defourny, P., 2005. Efficiency of crop identification based on optical and SAR image time series. *Remote Sens. Environ.* 96, 352–365. doi:http://dx.doi.org/10.1016/j.rse.2005.03.010
- Boschetti, M., Stroppiana, D., Brivio, P.A., Bocchi, S., 2009. Multi-year monitoring of rice crop phenology through time series analysis of MODIS images. *Int. J. Remote Sens.* 30, 4643–4662. doi:10.1080/01431160802632249
- Bouman, B.A.M., Uenk, D., 1992. Crop classification possibilities with radar in ERS-1 and JERS-1 configuration. *Remote Sens. Environ.* 40, 1–13. doi:http://dx.doi.org/10.1016/0034-4257(92)90122-Z
- Bouvet, A., Le Toan, T., Lam-Dao, N., 2009. Monitoring of the rice cropping system in the Mekong Delta using ENVISAT/ASAR dual polarization data. *IEEE Trans. Geosci. Remote Sens.* 47, 517–526. doi:10.1109/TGRS.2008.2007963
- Breiman, L., Friedman, J.H., Olshen, R.A., Stone, C.J., 1984. *Classification and Regression Trees*, First Edit. ed. Taylor & Francis, New York, NY, USA. doi:10.1201/9781315139470
- Brisco, B., Brown, R.J., 1995. Multidate SAR/TM synergism for crop classification in western Canada. *Photogramm. Eng. Remote Sensing* 61, 1009–1014.
- Brocca, L., Ciabatta, L., Massari, C., Camici, S., Tarpanelli, A., 2017. Soil moisture for hydrological applications: Open questions and new opportunities. *Water* 9, 140. doi:10.3390/w9020140
- Brocca, L., Hasenauer, S., Lacava, T., Melone, F., Moramarco, T., Wagner, W., Dorigo, W., Matgen, P., Martínez-Fernández, J., Llorens, P., Latron, J., Martin, C., Bittelli, M., 2011. Soil moisture estimation through ASCAT and AMSR-E sensors: An intercomparison and validation study across Europe. *Remote Sens. Environ.* 115, 3390–3408. doi:10.1016/j.rse.2011.08.003
- Brocca, L., Tarpanelli, A., Filippucci, P., Dorigo, W., Zaussinger, F., Gruber, A., Fernández-Prieto, D., 2018. How much water is used for irrigation? A new approach exploiting coarse resolution satellite soil moisture products. *Int. J. Appl. Earth Obs. Geoinf.* 73, 752–766. doi:10.1016/j.jag.2018.08.023
- Brown, R.J., Manore, M.J., Polrler, S., 1992. Correlations between X-, C-, and L-band imagery within an agricultural environment. *Int. J. Remote Sens.* 13, 1645–1661. doi:10.1080/01431169208904218
- Busquier, M., Lopez-Sanchez, J.M., Bargiel, D., 2019. Added Value of Coherent Copolar Polarimetry at X-Band for Crop-Type Mapping. *IEEE Geosci. Remote Sens. Lett.* 17, 819–823. doi:10.1109/LGRS.2019.2933738
- Busquier, M., Lopez-Sanchez, J.M., Mestre-Querada, A., Navarro, E., González-Dugo, M.P., Mateos, L., 2020. Exploring TanDEM-X Interferometric Products for Crop-Type Mapping. *Remote Sens.* 12, 1774. doi:10.3390/rs12111774

- Cable, J.W., Kovacs, J.M., Jiao, X., Shang, J., 2014. Agricultural monitoring in northeastern Ontario, Canada, using multi-temporal polarimetric RADARSAT-2 data. *Remote Sens.* 6, 2343–2371. doi:10.3390/rs6032343
- Cabo, Á., Manero, F., 1991. Castilla y León. *Planeta*.
- Calera, A., Martínez, C., Meliá, J., 2001. A procedure for obtaining green plant cover: Relation to NDVI in a case study for barley. *Int. J. Remote Sens.* 22, 3357–3362. doi:10.1080/01431160010020100
- Camacho, F., Cernicharo, J., Lacaze, R., Baret, F., Weiss, M., 2013. GEOV1: LAI, FAPAR essential climate variables and FCOVER global time series capitalizing over existing products. Part 2: Validation and intercomparison with reference products. *Remote Sens. Environ.* 137, 310–329. doi:10.1016/j.rse.2013.02.030
- Canisius, F., Shang, J., Liu, J., Huang, X., Ma, B., Jiao, X., Geng, X., Kovacs, J.M., Walters, D., 2018. Tracking crop phenological development using multi-temporal polarimetric Radarsat-2 data. *Remote Sens. Environ.* 210, 508–518. doi:10.1016/j.rse.2017.07.031
- Caruso, G., Zarco-Tejada, P.J., González-Dugo, V., Moriondo, M., Tozzini, L., Palai, G., Rallo, G., Hornero, A., Primicerio, J., Gucci, R., 2019. High-resolution imagery acquired from an unmanned platform to estimate biophysical and geometrical parameters of olive trees under different irrigation regimes. *PLoS One* 14, e0210804. doi:10.1371/journal.pone.0210804
- Caves, R., Davidson, G., Padda, J., Ma, A., 2011. *AgriSAR 2009 Final Report, Vol. 1. Executive Summary, Data Acquisition, Data Simulation*. Paris, France.
- Ceballos, A., Scipal, K., Wagner, W., Martínez-Fernández, J., 2005. Validation of ERS scatterometer-derived soil moisture data in the central part of the Duero Basin, Spain. *Hydrol. Process.* 19, 1549–1566. doi:10.1002/hyp.5585
- Chakraborty, M., Manjunath, K.R., Panigrahy, S., Kundu, N., Parihar, J.S., 2005. Rice crop parameter retrieval using multi-temporal, multi-incidence angle Radarsat SAR data. *ISPRS J. Photogramm. Remote Sens.* 59, 310–322. doi:10.1016/j.isprsjprs.2005.05.001
- Champagne, C., McNairn, H., Daneshfar, B., Shang, J., 2014. A bootstrap method for assessing classification accuracy and confidence for agricultural land use mapping in Canada. *Int. J. Appl. Earth Obs. Geoinf.* 29, 44–52. doi:10.1016/j.jag.2013.12.016
- Champagne, C., White, J., Berg, A., Belair, S., Carrera, M., 2019. Impact of soil moisture data characteristics on the sensitivity to crop yields under drought and excess moisture conditions. *Remote Sens.* 11, 372. doi:10.3390/rs11040372
- Chen, M.F., Fung, A.K., 1988. A numerical study of the regions of validity of the Kirchhoff and small-perturbation rough surface scattering models. *Radio Sci.* 23, 163–170. doi:10.1029/RS023i002p00163
- Chen, S.W., Li, Y.Z., Wang, X.S., 2015. Crop discrimination based on polarimetric correlation coefficients optimization for PolSAR data. *Int. J. Remote Sens.* 36, 4233–4249. doi:10.1080/01431161.2015.1079345

- Chen, S.W., Li, Y.Z., Wang, X.S., Xiao, S.P., Sato, M., 2014. Modeling and interpretation of scattering mechanisms in polarimetric synthetic aperture radar: Advances and perspectives. *IEEE Signal Process. Mag.* 31, 79–89. doi:10.1109/MSP.2014.2312099
- Chen, S.W., Wang, X.S., Xiao, S.P., Sato, M., 2018. Advanced Polarimetric Target Decomposition, in: *Target Scattering Mechanism in Polarimetric Synthetic Aperture Radar*. Springer, Singapore, p. 225. doi:10.1007/978-981-10-7269-7\_2
- Chirakkal, S., Haldar, D., Misra, A., 2019. A knowledge-based approach for discriminating multi-crop scenarios using multi-temporal polarimetric SAR parameters. *Int. J. Remote Sens.* 40, 4002–4018. doi:10.1080/01431161.2018.1558304
- Cloude, S.R., Pottier, E., 1997. An entropy based classification scheme for land applications of polarimetric SAR. *IEEE Trans. Geosci. Remote Sens.* 35, 68–78. doi:10.1109/36.551935
- Cloude, S.R., Pottier, E., 1996. A review of target decomposition theorems in radar polarimetry. *IEEE Trans. Geosci. Remote Sens.* 34, 498–518. doi:10.1109/36.485127
- Cohen, J., 1960. A Coefficient of Agreement for Nominal Scales. *Educ. Psychol. Meas.* 20, 37–46. doi:10.1177/001316446002000104
- Colliander, A., Jackson, T.J., Bindlish, R., Chan, S., Das, N., Kim, S.B., Cosh, M.H., Dunbar, R.S., Dang, L., Pashaian, L., Asanuma, J., Aida, K., Berg, A., Rowlandson, T., Bosch, D., Caldwell, T., Caylor, K., Goodrich, D., al Jassar, H., Lopez-Baeza, E., Martínez-Fernández, J., González-Zamora, A., Livingston, S., McNairn, H., Pacheco, A., Moghaddam, M., Montzka, C., Notarnicola, C., Niedrist, G., Pellarin, T., Prueger, J., Pulliainen, J., Rautiainen, K., Ramos, J., Seyfried, M., Starks, P., Su, Z., Zeng, Y., van der Velde, R., Thibeault, M., Dorigo, W., Vreugdenhil, M., Walker, J.P., Wu, X., Moneris, A., O'Neill, P.E., Entekhabi, D., Njoku, E.G., Yueh, S., 2017. Validation of SMAP surface soil moisture products with core validation sites. *Remote Sens. Environ.* 191, 215–231. doi:10.1016/j.rse.2017.01.021
- Congalton, R.G., 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sens. Environ.* 37, 35–46. doi:10.1016/0034-4257(91)90048-B
- Cumming, I.G., Wong, F.H., 2005. *Digital Processing of Synthetic Aperture Radar Data: Algorithms and Implementation*. Artech House, Boston, MA, USA.
- Curlander, J.C., McDonough, R.N., 1991. *Synthetic Aperture Radar: Systems and Signal Processing*. John Wiley & Sons, New York, NY, USA.
- Das, K., Paul, P.K., 2015. Present status of soil moisture estimation by microwave remote sensing. *Cogent Geosci.* 1, 1084669. doi:10.1080/23312041.2015.1084669
- Deb Burman, P.K., Sarma, D., Williams, M., Karipot, A., Chakraborty, S., 2017. Estimating gross primary productivity of a tropical forest ecosystem over north-east India using LAI and meteorological variables. *J. Earth Syst. Sci.* 126, 99. doi:10.1007/s12040-017-0874-3
- Della Vecchia, A., Ferrazzoli, P., Guerriero, L., Blaes, X., Defourny, P., Dente, L., Mattia, F., Satalino, G., Strozzi, T., Wegmuller, U., 2006. Influence of geometrical factors on crop backscattering at C-band. *IEEE Trans. Geosci. Remote Sens.* 44, 778–790. doi:10.1109/TGRS.2005.860489
- Denize, J., Hubert-Moy, L., Pottier, E., 2019. Polarimetric SAR time-series for identification of winter



- land use. *Sensors* 19, 5574. doi:10.3390/s19245574
- Dey, S., Mandal, D., Robertson, L.D., Banerjee, B., Kumar, V., McNairn, H., Bhattacharya, A., Rao, Y.S., 2020. In-season crop classification using elements of the Kennaugh matrix derived from polarimetric RADARSAT-2 SAR data. *Int. J. Appl. Earth Obs. Geoinf.* 88, 102059. doi:10.1016/j.jag.2020.102059
- Dobson, M.C., Pierce, L.E., Ulaby, F.T., 1996. Knowledge-based land-cover classification using ERS-1/JERS-1 SAR composites. *IEEE Trans. Geosci. Remote Sens.* 34, 83–99. doi:10.1109/36.481896
- Elachi, C., 1988. *Spaceborne Radar Remote Sensing: Applications and Techniques*. IEEE Press, New York, NY, USA.
- Fang, H., Baret, F., Plummer, S., Schaepman-Strub, G., 2019. An Overview of Global Leaf Area Index (LAI): Methods, Products, Validation, and Applications. *Rev. Geophys.* 57, 739–799. doi:10.1029/2018RG000608
- Freeman, A., Durden, S.L., 1998. A three-component scattering model for polarimetric SAR data. *IEEE Trans. Geosci. Remote Sens.* 36, 963–973. doi:10.1109/36.673687
- Freund, Y., Schapire, R.E., 1996. Experiments with a New Boosting Algorithm, in: *Machine Learning: Proceedings of the Thirteenth International Conference*. pp. 148–156. doi:10.1.1.133.1040
- Friedl, M.A., Brodley, C.E., Strahler, A.H., 1999. Maximizing land cover classification accuracies produced by decision trees at continental to global scales. *IEEE Trans. Geosci. Remote Sens.* 37, 969–977. doi:10.1109/36.752215
- Fung, A.K., 1994. *Microwave Scattering and Emission Models and Their Applications*. Artech House, Norwood, MA, USA.
- Gallego, F.J., Kussul, N., Skakun, S., Kravchenko, O., Shelestov, A., Kussul, O., 2014. Efficiency assessment of using satellite data for crop area estimation in Ukraine. *Int. J. Appl. Earth Obs. Geoinf.* 29, 22–30. doi:10.1016/j.jag.2013.12.013
- Gao, F., Anderson, M.C., Zhang, X., Yang, Z., Alfieri, J.G., Kustas, W.P., Mueller, R., Johnson, D.M., Prueger, J.H., 2017. Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery. *Remote Sens. Environ.* 188, 9–25. doi:10.1016/j.rse.2016.11.004
- García-Fernández, J., 1986. *El Clima en Castilla y León. Ámbito, Valladolid*.
- García-Rodríguez, M. del P., 1993. Distribución de suelos en la Cuenca del Duero: relación con otros factores ambientales. *An. Geogr. la Univ. Complut.* 13, 155–168.
- García-Rodríguez, M. del P., Forteza-Bonnín, J., Lorenzo-Martín, L.F., 1979. La cubierta edáfica de la depresión del Duero, in: *1 Reunión Sobre La Geología de La Cuenca Del Duero*. Salamanca, pp. 305–323.
- GCOS, 2011. *Systematic Observation Requirements for Satellite-Based Data Products for Climate*. Geneva, Switzerland.

- Gómez, C., White, J.C., Wulder, M.A., 2016. Optical remotely sensed time series data for land cover classification: A review. *ISPRS J. Photogramm. Remote Sens.* 116, 55–72. doi:10.1016/j.isprsjprs.2016.03.008
- González-Zamora, A., Sánchez, N., Martínez-Fernández, J., 2016. Validation of Aquarius Soil Moisture Products Over the Northwest of Spain: A Comparison With SMOS. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 9, 2763–2769. doi:10.1109/JSTARS.2016.2517401
- González-Zamora, Á., Sánchez, N., Martínez-Fernández, J., Gumuzzio, Á., Piles, M., Olmedo, E., 2015. Long-term SMOS soil moisture products: A comprehensive evaluation across scales and methods in the Duero Basin (Spain). *Phys. Chem. Earth* 83–84, 123–136. doi:10.1016/j.pce.2015.05.009
- Goodman, J.W., 1976. Some fundamental properties of speckle. *J. Opt. Soc. Am.* 66, 1145–1150. doi:10.1364/josa.66.001145
- Gul, S., Khan, M.H., Khanday, B.A., Nabi, S., 2015. Effect of Sowing Methods and NPK Levels on Growth and Yield of Rainfed Maize ( *Zea mays* L.). *Scientifica (Cairo)*. 2015, 198575. doi:10.1155/2015/198575
- Guo, J., Li, H., Ning, J., Han, W., Zhang, W., Zhou, Z.S., 2020. Feature dimension reduction using stacked sparse auto-encoders for crop classification with multi-temporal, quad-pol SAR Data. *Remote Sens.* 12, 321. doi:10.3390/rs12020321
- Guo, J., Wei, P.L., Liu, J., Jin, B., Su, B.F., Zhou, Z.S., 2018. Crop Classification Based on Differential Characteristics of H/ $\alpha$  Scattering Parameters for Multitemporal Quad- and Dual-Polarization SAR Images. *IEEE Trans. Geosci. Remote Sens.* 56, 6111–6123. doi:10.1109/TGRS.2018.2832054
- Gutman, G., Ignatov, A., 1998. The derivation of the green vegetation fraction from NOAA/AVHRR data for use in numerical weather prediction models. *Int. J. Remote Sens.* 19, 1533–1543. doi:10.1080/014311698215333
- Habyarimana, E., Piccard, I., Catellani, M., De Franceschi, P., Dall'Agata, M., 2019. Towards predictive modeling of sorghum biomass yields using fraction of absorbed photosynthetically active radiation derived from sentinel-2 satellite imagery and supervised machine learning techniques. *Agronomy* 9, 203. doi:10.3390/agronomy9040203
- Hajnsek, I., Pottier, E., Cloude, S.R., 2003. Inversion of surface parameters from polarimetric SAR. *IEEE Trans. Geosci. Remote Sens.* 41, 727–744. doi:10.1109/TGRS.2003.810702
- Han, J., Kamber, M., Pei, J., 2012. *Data Mining: Concepts and Techniques*, Third Edit. ed, Data Mining: Concepts and Techniques. Morgan Kaufmann Publishers, Waltham, MA, USA. doi:10.1016/C2009-0-61819-5
- Han, L., Yang, G., Dai, H., Xu, B., Yang, H., Feng, H., Li, Z., Yang, X., 2019. Modeling maize above-ground biomass based on machine learning approaches using UAV remote-sensing data. *Plant Methods* 15, 10. doi:10.1186/s13007-019-0394-z
- Hariharan, S., Mandal, D., Tirodkar, S., Kumar, V., Bhattacharya, A., Lopez-Sanchez, J.M., 2018. A Novel Phenology Based Feature Subset Selection Technique Using Random Forest for Multitemporal PolSAR Crop Classification. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 11, 4244–4258. doi:10.1109/JSTARS.2018.2866407

- Hensgen, F., Bühle, L., Wachendorf, M., 2016. The effect of harvest, mulching and low-dose fertilization of liquid digestate on above ground biomass yield and diversity of lower mountain semi-natural grasslands. *Agric. Ecosyst. Environ.* 216, 283–292. doi:10.1016/j.agee.2015.10.009
- Hirano, Y., Yasuoka, Y., Ichinose, T., 2004. Urban climate simulation by incorporating satellite-derived vegetation cover distribution into a mesoscale meteorological model. *Theor. Appl. Climatol.* 79, 175–184. doi:10.1007/s00704-004-0069-0
- Holzman, M.E., Carmona, F., Rivas, R., Niclòs, R., 2018. Early assessment of crop yield from remotely sensed water stress and solar radiation data. *ISPRS J. Photogramm. Remote Sens.* 145, 297–308. doi:10.1016/j.isprsjprs.2018.03.014
- Houghton, R.A., Hall, F., Goetz, S.J., 2009. Importance of biomass in the global carbon cycle. *J. Geophys. Res. Biogeosciences* 114. doi:10.1029/2009JG000935
- Huang, J., Sedano, F., Huang, Y., Ma, H., Li, X., Liang, S., Tian, L., Zhang, X., Fan, J., Wu, W., 2016. Assimilating a synthetic Kalman filter leaf area index series into the WOFOST model to improve regional winter wheat yield estimation. *Agric. For. Meteorol.* 216, 188–202. doi:10.1016/j.agrformet.2015.10.013
- Inoue, Y., Kurosu, T., Maeno, H., Uratsuka, S., Kozu, T., Dabrowska-Zielinska, K., Qi, J., 2002. Season-long daily measurements of multifrequency (Ka, Ku, X, C, and L) and full-polarization backscatter signatures over paddy rice field and their relationship with biological variables. *Remote Sens. Environ.* 81, 194–204. doi:10.1016/S0034-4257(01)00343-1
- Inoue, Y., Sakaiya, E., 2013. Relationship between X-band backscattering coefficients from high-resolution satellite SAR and biophysical variables in paddy rice. *Remote Sens. Lett.* 4, 288–295. doi:10.1080/2150704X.2012.725482
- Inoue, Y., Sakaiya, E., Wang, C., 2014. Capability of C-band backscattering coefficients from high-resolution satellite SAR sensors to assess biophysical variables in paddy rice. *Remote Sens. Environ.* 140, 257–266. doi:10.1016/j.rse.2013.09.001
- IPCC, 2013. Summary for policymakers, in: Stocker, T.F., Qin, D., Plattner, G.-K., Tignor, M.M.B., Allen, S.K., Boschung, J., Nauels, A., Xia, Y., Bex, V., Midgley, P.M. (Eds.), *Climate Change 2013 - The Physical Science Basis*. Cambridge University Press, Cambridge, UK and New York, NY, USA, p. 222.
- Jackson, T.J., Chen, D., Cosh, M., Li, F., Anderson, M., Walthall, C., Doriaswamy, P., Hunt, E.R., 2004. Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. *Remote Sens. Environ.* 92, 475–482. doi:10.1016/j.rse.2003.10.021
- Jia, K., Li, Q., Tian, Y., Wu, B., Zhang, F., Meng, J., 2012. Crop classification using multi-configuration SAR data in the North China plain. *Int. J. Remote Sens.* 33, 170–183. doi:10.1080/01431161.2011.587844
- Jiang, Z., Huete, A.R., Chen, J., Chen, Y., Li, J., Yan, G., Zhang, X., 2006. Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction. *Remote Sens. Environ.* 101, 366–378. doi:10.1016/j.rse.2006.01.003

- Jiao, X., Mc Nairn, H., Shang, J., Pattey, E., Liu, J., Champagne, C., 2011. The sensitivity of RADARSAT-2 polarimetric SAR data to corn and soybean leaf area index. *Can. J. Remote Sens.* 37, 69–81. doi:10.5589/m11-023
- Jiapaer, G., Chen, X., Bao, A., 2011. A comparison of methods for estimating fractional vegetation cover in arid regions. *Agric. For. Meteorol.* 151, 1698–1710. doi:10.1016/j.agrformet.2011.07.004
- Jonckheere, I., Fleck, S., Nackaerts, K., Muys, B., Coppin, P., Weiss, M., Baret, F., 2004. Review of methods for in situ leaf area index determination Part I. Theories, sensors and hemispherical photography. *Agric. For. Meteorol.* 121, 19–35. doi:10.1016/j.agrformet.2003.08.027
- Karam, M.A., Fung, A.K., Lang, R.H., Chauhan, N.S., 1992. A microwave scattering model for layered vegetation. *IEEE Trans. Geosci. Remote Sens.* 30, 767–784. doi:10.1109/36.158872
- Karthikeyan, L., Pan, M., Wanders, N., Kumar, D.N., Wood, E.F., 2017. Four decades of microwave satellite soil moisture observations: Part 1. A review of retrieval algorithms. *Adv. Water Resour.* 109, 106–120. doi:10.1016/j.advwatres.2017.09.006
- Kim, Y., Jackson, T., Bindlish, R., Hong, S., Jung, G., Lee, K., 2014. Retrieval of wheat growth parameters with radar vegetation indices. *IEEE Geosci. Remote Sens. Lett.* 11, 808–812. doi:10.1109/LGRS.2013.2279255
- Kim, Y., Jackson, T., Bindlish, R., Lee, H., Hong, S., 2012. Radar vegetation index for estimating the vegetation water content of rice and soybean. *IEEE Geosci. Remote Sens. Lett.* 9, 564–568. doi:10.1109/LGRS.2011.2174772
- Kogan, F., Kussul, N., Adamenko, T., Skakun, S., Kravchenko, O., Kryvobok, O., Shelestov, A., Kolotii, A., Kussul, O., Lavrenyuk, A., 2013. Winter wheat yield forecasting in Ukraine based on Earth observation, meteorological data and biophysical models. *Int. J. Appl. Earth Obs. Geoinf.* 23, 192–203. doi:10.1016/j.jag.2013.01.002
- Kothapalli Venkata, R., Poloju, S., Mullapudi Venkata Rama, S.S., Gogineni, A., Prabir Kumar, D., Allakki Venkata, R., Nagaraju, A., Diwakar, P.G., Dadhwal, V.K., Singh, K.R.P., 2017. Multi-incidence angle RISAT-1 Hybrid Polarimetric SAR data for large area mapping of maize crop – a case study in Khagaria district, Bihar, India. *Int. J. Remote Sens.* 38, 5487–5501. doi:10.1080/01431161.2017.1338783
- Kozlov, A., Ligthart, L., Logvin, A., 2001. *Mathematical and Physical Modelling of Microwave Scattering and Polarimetric Remote Sensing - Monitoring the Earth ' s Environment Using Polarimetric Radar: Formulation and Potential Applications, Remote Sensing and Digital Image Processing.* Kluwer Academic Publishers, Dordrecht. doi:10.1007/0-306-48091-3
- Kussul, N., Lemoine, G., Gallego, F.J., Skakun, S. V., Lavreniuk, M., Shelestov, A.Y., 2016. Parcel-Based Crop Classification in Ukraine Using Landsat-8 Data and Sentinel-1A Data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 9, 2500–2508. doi:10.1109/JSTARS.2016.2560141
- Kussul, N., Lemoine, G., Gallego, J., Skakun, S., Lavreniuk, M., 2015. Parcel based classification for agricultural mapping and monitoring using multi-temporal satellite image sequences, in: *International Geoscience and Remote Sensing Symposium (IGARSS)*. Milan, Italy, 26–31 July, pp. 165–168. doi:10.1109/IGARSS.2015.7325725

- Larrañaga, A., Álvarez-Mozos, J., 2016. On the added value of quad-pol data in a multi-temporal crop classification framework based on RADARSAT-2 imagery. *Remote Sens.* 8. doi:10.3390/rs8040335
- Larrañaga, A., Álvarez-Mozos, J., Albizua, L., Peters, J., 2013. Backscattering Behavior of Rain-Fed Crops Along the Growing Season. *IEEE Geosci. Remote Sens. Lett.* 10, 386–390. doi:10.1109/LGRS.2012.2205660
- Lee, J.-S., Grunes, M.R., Ainsworth, T.L., Du, L.-J., Schuler, D.L., Cloude, S.R., 1999. Unsupervised classification using polarimetric decomposition and the complex Wishart classifier. *IEEE Trans. Geosci. Remote Sens.* 37, 2249–2258. doi:10.1109/36.789621
- Lee, J.-S., Grunes, M.R., Pottier, E., 2001. Quantitative comparison of classification capability: fully polarimetric versus dual and single-polarization SAR. *IEEE Trans. Geosci. Remote Sens.* 39, 2343–2351. doi:10.1109/36.964970
- Lee, J.-S., Pottier, E., 2009. *Polarimetric Radar Imaging: From Basics to Applications*. CRC Press, Taylor & Francis Group, Boca Raton, FL. doi:10.1201/9781420054989.fmatt
- Lee, J.S., Ainsworth, T.L., Kelly, J.P., Lopez-Martinez, C., 2008. Evaluation and bias removal of multilook effect on entropy/alpha/anisotropy in polarimetric SAR decomposition. *IEEE Trans. Geosci. Remote Sens.* 46, 3039–3052. doi:10.1109/TGRS.2008.922033
- Lee, J. Sen, Grunes, M.R., Kwok, R., 1994a. Classification of multi-look polarimetric SAR imagery based on complex Wishart distribution. *Int. J. Remote Sens.* 15, 2299–2311.
- Lee, J. Sen, Hoppel, K.W., Miller, A.R., Mango, S.A., 1994b. Intensity and phase statistics of multilook polarimetric and interferometric SAR imagery. *IEEE Trans. Geosci. Remote Sens.* 32, 1017–1028. doi:10.1109/36.312890
- Leroux, L., Baron, C., Zoungrana, B., Traore, S.B., Lo Seen, D., Begue, A., 2016. Crop Monitoring Using Vegetation and Thermal Indices for Yield Estimates: Case Study of a Rainfed Cereal in Semi-Arid West Africa. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 9, 347–362. doi:10.1109/JSTARS.2015.2501343
- Li, H., Zhang, C., Zhang, S., Atkinson, P.M., 2020. Crop classification from full-year fully-polarimetric L-band UAVSAR time-series using the Random Forest algorithm. *Int. J. Appl. Earth Obs. Geoinf.* 87, 102032. doi:10.1016/j.jag.2019.102032
- Li, X., Chen, Y., Tong, L., Luo, S., 2016. A study on vegetation cover extraction using a Wishart H- $\alpha$  classifier based on fully polarimetric Radarsat-2 data. *Int. J. Remote Sens.* 37, 2844–2859. doi:10.1080/01431161.2016.1192307
- Liao, C., Wang, J., Shang, J., Huang, X., Liu, J., Huffman, T., 2018. Sensitivity study of Radarsat-2 polarimetric SAR to crop height and fractional vegetation cover of corn and wheat. *Int. J. Remote Sens.* 39, 1475–1490. doi:10.1080/01431161.2017.1407046
- Liao, C., Wang, J., Xie, Q., Baz, A. Al, Huang, X., Shang, J., He, Y., 2020. Synergistic use of multi-temporal RADARSAT-2 and VEN $\mu$ S data for crop classification based on 1D convolutional neural network. *Remote Sens.* 12, 832. doi:10.3390/rs12050832

- Lim, K.-S., Koo, V.C., Ewe, H.-T., 2008. Multi-Angular Scatterometer Measurements for Various Stages of Rice Growth. *Prog. Electromagn. Res.* 83, 385–396. doi:10.2528/PIER08070205
- Liu, C. an, Chen, Z. xin, Shao, Y., Chen, J. song, Hasi, T., Pan, H. zhu, 2019. Research advances of SAR remote sensing for agriculture applications: A review. *J. Integr. Agric.* 18, 506–525. doi:10.1016/S2095-3119(18)62016-7
- Liu, L., Zhang, X., Yu, Y., Gao, F., Yang, Z., 2018. Real-time monitoring of crop phenology in the Midwestern United States using VIIRS observations. *Remote Sens.* 10, 1540. doi:10.3390/rs10101540
- Lopez-Sanchez, J.M., 1999. Analysis and Estimation of Biophysical Parameters of Vegetation by Radar Polarimetry. Universidad Politécnica de Valencia.
- Lopez-Sanchez, J.M., Cloude, S.R., Ballester-Berman, J.D., 2012. Rice Phenology Monitoring by Means of SAR Polarimetry at X-Band. *IEEE Trans. Geosci. Remote Sens.* 50, 2695–2709. doi:10.1109/TGRS.2011.2176740
- Lopez-Sanchez, J.M., Vicente-Guijalba, F., Ballester-Berman, J.D., Cloude, S.R., 2015. Influence of Incidence Angle on the Coherent Copolar Polarimetric Response of Rice at X-Band. *IEEE Geosci. Remote Sens. Lett.* 12, 249–253. doi:10.1109/LGRS.2014.2334371
- Lopez-Sanchez, J.M., Vicente-Guijalba, F., Ballester-Berman, J.D., Cloude, S.R., 2014. Polarimetric Response of Rice Fields at C-Band: Analysis and Phenology Retrieval. *IEEE Trans. Geosci. Remote Sens.* 52, 2977–2993. doi:10.1109/TGRS.2013.2268319
- Lopez-Sanchez, J.M., Vicente-Guijalba, F., Ballester-Berman, J.D., Cloude, S.R., 2013. Estimating phenology of agricultural crops from space, in: *Proceedings of ESA Living Planet Symposium*. Edinburgh, UK.
- Lopez-Sanchez, J.M., Vicente-Guijalba, F., Erten, E., Campos-Taberner, M., Garcia-Haro, F.J., 2017. Retrieval of vegetation height in rice fields using polarimetric SAR interferometry with TanDEM-X data. *Remote Sens. Environ.* 192, 30–44. doi:10.1016/j.rse.2017.02.004
- Lu, B., He, Y., Liu, H.H.T., 2018. Mapping vegetation biophysical and biochemical properties using unmanned aerial vehicles-acquired imagery. *Int. J. Remote Sens.* 39, 5265–5287. doi:10.1080/01431161.2017.1363441
- Macelloni, G., Paloscia, S., Pampaloni, P., Marliani, F., Gai, M., 2001. The relationship between the backscattering coefficient and the biomass of narrow and broad leaf crops. *IEEE Trans. Geosci. Remote Sens.* 39, 873–884. doi:10.1109/36.917914
- Maimon, O., Rokach, L., 2010. *Data Mining and Knowledge Discovery Handbook*, Second Edi. ed. Springer, New York, NY, USA.
- Maity, S., Patnaik, C., Chakraborty, M., Panigrahy, S., 2004. Analysis of temporal backscattering of cotton crops using a semiempirical model. *IEEE Trans. Geosci. Remote Sens.* 42, 577–587. doi:10.1109/TGRS.2003.821888

- Mandal, D., Kumar, V., Bhattacharya, A., Rao, Y.S., Siqueira, P., Bera, S., 2018. Sen4Rice: A processing chain for differentiating early and late transplanted rice using time-series sentinel-1 SAR data with google earth engine. *IEEE Geosci. Remote Sens. Lett.* 15, 1947–1951. doi:10.1109/LGRS.2018.2865816
- Mandal, D., Kumar, V., Rao, Y.S., 2020a. An assessment of temporal RADARSAT-2 SAR data for crop classification using KPCA based support vector machine. *Geocarto Int.* 1–13. doi:10.1080/10106049.2020.1783577
- Mandal, D., Kumar, V., Ratha, D., Lopez-Sanchez, J.M., Bhattacharya, A., McNairn, H., Rao, Y.S., Ramana, K. V., 2020b. Assessment of rice growth conditions in a semi-arid region of India using the Generalized Radar Vegetation Index derived from RADARSAT-2 polarimetric SAR data. *Remote Sens. Environ.* 237, 111561. doi:10.1016/j.rse.2019.111561
- Martínez-Fernández, J., González-Zamora, A., Sánchez, N., Gumuzzio, A., Herrero-Jiménez, C.M., 2016. Satellite soil moisture for agricultural drought monitoring: Assessment of the SMOS derived Soil Water Deficit Index. *Remote Sens. Environ.* 177, 277–286. doi:10.1016/j.rse.2016.02.064
- Martínez-Fernández, J., Sánchez, N., González-Zamora, Á., 2017. Agricultural drought monitoring using satellite soil moisture and other remote sensing data over the Iberian Peninsula, in: Petropoulos, G.P., Islam, T. (Eds.), *Remote Sensing of Hydrometeorological Hazards*. CRC Press, Taylor & Francis Group, Boca Raton, FL, USA, p. 549. doi:10.1201/b20993
- Mascolo, L., Lopez-Sanchez, J.M., Vicente-Guijalba, F., Nunziata, F., Migliaccio, M., Mazzarella, G., 2016. A Complete Procedure for Crop Phenology Estimation with PolSAR Data Based on the Complex Wishart Classifier. *IEEE Trans. Geosci. Remote Sens.* 54, 6505–6515. doi:10.1109/TGRS.2016.2585744
- Mattia, F., Le Toan, T., Picard, G., Posa, F.I., D'Alessio, A., Notarnicola, C., Gatti, A.M., Rinaldi, M., Satalino, G., Pasquariello, G., 2003. Multitemporal C-band radar measurements on wheat fields. *IEEE Trans. Geosci. Remote Sens.* 41, 1551–1560. doi:10.1109/TGRS.2003.813531
- McKersie, B., 2015. Planning for food security in a changing climate. *J. Exp. Bot.* 66, 3435–3450. doi:10.1093/jxb/eru547
- McNairn, H., Champagne, C., Shang, J., Holmstrom, D., Reichert, G., 2009a. Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. *ISPRS J. Photogramm. Remote Sens.* 64, 434–449. doi:http://dx.doi.org/10.1016/j.isprsjprs.2008.07.006
- McNairn, H., Ellis, J., Van Der Sanden, J.J., Hirose, T., Brown, R.J., 2002. Providing crop information using RADARSAT-1 and satellite optical imagery. *Int. J. Remote Sens.* 23, 851–870. doi:10.1080/01431160110070753
- McNairn, H., Kross, A., Lapen, D., Caves, R., Shang, J., 2014. Early season monitoring of corn and soybeans with TerraSAR-X and RADARSAT-2. *Int. J. Appl. Earth Obs. Geoinf.* 28, 252–259. doi:10.1016/j.jag.2013.12.015
- McNairn, H., Shang, J., 2016. A review of multitemporal synthetic aperture radar (SAR) for crop monitoring, in: Ban, Y. (Ed.), *Multitemporal Remote Sensing*. Springer, p. 445. doi:10.1007/978-3-319-47037-5\_15

- McNairn, H., Shang, J., Jiao, X., Champagne, C., 2009b. The contribution of ALOS PALSAR multipolarization and polarimetric data to crop classification. *IEEE Trans. Geosci. Remote Sens.* 47, 3981–3992. doi:10.1109/TGRS.2009.2026052
- Meier, U., 2001. Growth stages of mono- and dicotyledonous plants, *B BCH Monograph*. doi:10.5073/bbch0515
- Mishra, V.N., Prasad, R., Kumar, P., Srivastava, P.K., Rai, P.K., 2017. Knowledge-based decision tree approach for mapping spatial distribution of rice crop using C-band synthetic aperture radar-derived information. *J. Appl. Remote Sens.* 11, 046003. doi:10.1117/1.jrs.11.046003
- Moles, A.T., Warton, D.I., Warman, L., Swenson, N.G., Laffan, S.W., Zanne, A.E., Pitman, A., Hemmings, F.A., Leishman, M.R., 2009. Global patterns in plant height. *J. Ecol.* 97, 923–932. doi:10.1111/j.1365-2745.2009.01526.x
- Morán-Tejeda, E., 2011. Variabilidad espacio-temporal de los recursos hídricos superficiales en la cuenca del Duero y su relación con los cambios ambientales. Universidad de Salamanca.
- Moran, M.S., Alonso, L., Moreno, J.F., Cendrero Mateo, M.P., de la Cruz, D.F., Montoro, A., 2012. A RADARSAT-2 Quad-Polarized Time Series for Monitoring Crop and Soil Conditions in Barrax, Spain. *IEEE Trans. Geosci. Remote Sens.* 50, 1057–1070. doi:10.1109/TGRS.2011.2166080
- Moran, M.S., Pinter, P.J., Clothier, B.E., Allen, S.G., 1989. Effect of water stress on the canopy architecture and spectral indices of irrigated alfalfa. *Remote Sens. Environ.* 29, 251–261. doi:10.1016/0034-4257(89)90004-7
- Morena, L.C., James, K. V., Beck, J., 2004. An introduction to the RADARSAT-2 mission. *Can. J. Remote Sens.* 30, 221–234. doi:10.5589/m04-004
- Mulla, D.J., 2013. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosyst. Eng.* 114, 358–371. doi:10.1016/j.biosystemseng.2012.08.009
- Nafría, D.A., del Blanco, V., Bengoa, J.L., 2017. Castile and Leon Crops and Natural Land Map, in: *WorldCover Conference*. Frascati, Rome, Italy, 14-16 March.
- Nafría García, D.A., Garrido del Pozo, N., Álvarez Arias, M. V., Cubero Jiménez, D., Fernández Sánchez, M., Villarino Barrera, I., Gutiérrez García, A., Abia Llera, I., 2013. *Atlas Agroclimático de Castilla y León*. Madrid.
- Nasirzadehdizaji, R., Sanli, F.B., Abdikan, S., Cakir, Z., Sekertekin, A., Ustuner, M., 2019. Sensitivity analysis of multi-temporal Sentinel-1 SAR parameters to crop height and canopy coverage. *Appl. Sci.* 9, 655. doi:10.3390/app9040655
- Nasrallah, A., Baghdadi, N., El Hajj, M., Darwish, T., Belhouchette, H., Faour, G., Darwich, S., Mhawej, M., 2019. Sentinel-1 data for winter wheat phenology monitoring and mapping. *Remote Sens.* 11, 2228. doi:10.3390/rs11192228
- Ndikumana, E., Minh, D.H.T., Baghdadi, N., Courault, D., Hossard, L., 2018. Deep recurrent neural network for agricultural classification using multitemporal SAR Sentinel-1 for Camargue, France. *Remote Sens.* 10, 1217. doi:10.3390/rs10081217



- Oh, Y., Hong, J.Y., 2007. Re-examination of analytical models for microwave scattering from deciduous leaves. *IET Microwaves, Antennas Propag.* 1, 617–623. doi:10.1049/iet-map:20050081
- Orynbaikyzy, A., Gessner, U., Conrad, C., 2019. Crop type classification using a combination of optical and radar remote sensing data: a review. *Int. J. Remote Sens.* 40, 6553–6595. doi:10.1080/01431161.2019.1569791
- Ostos-Garrido, F.J., de Castro, A.I., Torres-Sánchez, J., Pistón, F., Peña, J.M., 2019. High-Throughput Phenotyping of Bioethanol Potential in Cereals Using UAV-Based Multi-Spectral Imagery. *Front. Plant Sci.* 10, 948. doi:10.3389/fpls.2019.00948
- Pasqualotto, N., Delegido, J., Van Wittenberghe, S., Rinaldi, M., Moreno, J., 2019. Multi-crop green LAI estimation with a new simple sentinel-2 LAI index (SeLI). *Sensors* 14, 904. doi:10.3390/s19040904
- Petropoulos, G.P., Ireland, G., Barrett, B., 2015. Surface soil moisture retrievals from remote sensing: Current status, products & future trends. *Phys. Chem. Earth* 83–84, 36–56. doi:10.1016/j.pce.2015.02.009
- Piantanida, R., Hajduch, G., Poullaouec, J., 2016. Sentinel-1 Level 1 Detailed Algorithm Definition. Paris, France.
- Powers, R.P., Hay, G.J., Chen, G., 2012. How wetland type and area differ through scale: A GEOBIA case study in Alberta's Boreal Plains. *Remote Sens. Environ.* 117, 135–145. doi:10.1016/j.rse.2011.07.009
- Press, W.H., Teukolsky, S.A., Vetterling, W.T., Flannery, B.P., 2007. *Numerical Recipes: The Art of Scientific Computing*, Third Edit. ed. Cambridge University Press, Cambridge, UK.
- Quinlan, J.R., 1992. C4.5: Programs for Machine Learning, Morgan Kaufmann San Mateo California. doi:10.1016/S0019-9958(62)90649-6
- Quinlan, J.R., 1986. Induction of Decision Trees. *Mach. Learn.* 1, 81–106. doi:10.1023/A:1022643204877
- Ramírez-Mejía, D., Gómez-Tagle, A., Ghilardi, A., 2018. Using aerial photography to estimate wood suitable for charcoal in managed oak forests. *Environ. Res. Lett.* 13, 025006. doi:10.1088/1748-9326/aa9c63
- Rosenqvist, A., Shimada, M., Ito, N., Watanabe, M., 2007. ALOS PALSAR: A pathfinder mission for global-scale monitoring of the environment. *IEEE Trans. Geosci. Remote Sens.* 45, 3307–3316. doi:10.1109/TGRS.2007.901027
- Rosenthal, W.D., Blanchard, B.J., 1984. Active microwave responses: An aid in improved crop classification. *Photogramm. Eng. Remote Sensing* 50, 461–468.
- Sánchez, N., González-Zamora, Á., Martínez-Fernández, J., Piles, M., Pablos, M., 2018. Integrated remote sensing approach to global agricultural drought monitoring. *Agric. For. Meteorol.* 259, 141–153. doi:10.1016/j.agrformet.2018.04.022
- Sánchez, N., González-Zamora, Á., Piles, M., Martínez-Fernández, J., 2016. A new Soil Moisture Agricultural Drought Index (SMADI) integrating MODIS and SMOS products: A case of study over the Iberian Peninsula. *Remote Sens.* 8, 287. doi:10.3390/rs8040287

- Sánchez, N., Martínez-Fernández, J., González-Piqueras, J., González-Dugo, M.P., Baroncini-Turricchia, G., Torres, E., Calera, A., Pérez-Gutiérrez, C., 2012a. Water balance at plot scale for soil moisture estimation using vegetation parameters. *Agric. For. Meteorol.* 166–167, 1–9. doi:10.1016/j.agrformet.2012.07.005
- Sánchez, N., Martínez-Fernández, J., Scaini, A., Pérez-Gutiérrez, C., 2012b. Validation of the SMOS L2 Soil Moisture Data in the REMEDHUS Network (Spain). *IEEE Trans. Geosci. Remote Sens.* 50, 1602–1611. doi:10.1109/TGRS.2012.2186971
- Satalino, G., Mattia, F., Le Toan, T., Rinaldi, M., 2009. Wheat crop mapping by using ASAR AP data. *IEEE Trans. Geosci. Remote Sens.* 47, 527–530. doi:10.1109/TGRS.2008.2008026
- Scherer, P.O.J., 2013. *Computational Physics. Simulation of Classical and Quantum*, Second Edi. ed. Springer, Cham, Switzerland. doi:10.1007/978-3-319-00401-3
- Schmugge, T.J., Kustas, W.P., Ritchie, J.C., Jackson, T.J., Rango, A., 2002. Remote sensing in hydrology. *Adv. Water Resour.* 25, 1367–1385. doi:10.1016/S0309-1708(02)00065-9
- Schotten, C.G.J., Van Rooy, W.W.L., Janssen, L.L.F., 1995. Assessment of the capabilities of multi-temporal ERS-1 SAR data to discriminate between agricultural crops. *Int. J. Remote Sens.* 16, 2619–2637.
- Schubert, A., Small, D., Miranda, N., Geudtner, D., Meier, E., 2015. Sentinel-1A Product Geolocation Accuracy: Commissioning Phase Results. *Remote Sens.* 7, 9431–9449. doi:10.3390/rs70709431
- Seneviratne, S.I., Corti, T., Davin, E.L., Hirschi, M., Jaeger, E.B., Lehner, I., Orlowsky, B., Teuling, A.J., 2010. Investigating soil moisture-climate interactions in a changing climate: A review. *Earth-Science Rev.* 99, 125–161. doi:10.1016/j.earscirev.2010.02.004
- Siachalou, S., Mallinis, G., Tsakiri-Strati, M., 2015. A Hidden Markov Models Approach for Crop Classification: Linking Crop Phenology to Time Series of Multi-Sensor Remote Sensing Data. *Remote Sens.* 7, 3633–3650. doi:10.3390/rs70403633
- Sinclair, G., 1950. The Transmission and Reception of Elliptically Polarized Waves. *Proc. IRE* 38, 148–151. doi:10.1109/JRPROC.1950.230106
- Skakun, S., Kussul, N., Shelestov, A.Y., Lavreniuk, M., Kussul, O., 2016. Efficiency Assessment of Multitemporal C-Band Radarsat-2 Intensity and Landsat-8 Surface Reflectance Satellite Imagery for Crop Classification in Ukraine. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 9, 3712–3719. doi:10.1109/JSTARS.2015.2454297
- Skolnik, M.I., 1981. *Introduction to Radar Systems*, Second Edi. ed. McGraw-Hill, Singapore.
- Skriver, H., 2012. Crop Classification by Multitemporal C- and L-Band Single- and Dual-Polarization and Fully Polarimetric SAR. *IEEE Trans. Geosci. Remote Sens.* 50, 2138–2149. doi:10.1109/TGRS.2011.2172994
- Skriver, H., 2007. Signatures of polarimetric parameters and their implications on land cover classification, in: *International Geoscience and Remote Sensing Symposium (IGARSS)*. Barcelona, Spain, 23-27 July, pp. 4195–4198. doi:10.1109/IGARSS.2007.4423775

- Skriver, H., Mattia, F., Satalino, G., Balenzano, A., Pauwels, V.R.N., Verhoest, N.E.C., Davidson, M., 2011. Crop Classification Using Short-Revisit Multitemporal SAR Data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 4, 423–431. doi:10.1109/JSTARS.2011.2106198
- Skriver, H., Svendsen, M.T., Thomsen, A.G., 1999. Multitemporal C- and L-band polarimetric signatures of crops. *IEEE Trans. Geosci. Remote Sens.* 37, 2413–2429. doi:10.1109/36.789639
- Smith, A.M., Buckley, J.R., 2011. Investigating RADARSAT-2 as a tool for monitoring grassland in western Canada. *Can. J. Remote Sens.* 37, 93–102. doi:10.5589/m11-027
- Son, N.T., Chen, C.F., Chen, C.R., Minh, V.Q., 2018. Assessment of Sentinel-1A data for rice crop classification using random forests and support vector machines. *Geocarto Int.* 33, 587–601. doi:10.1080/10106049.2017.1289555
- Song, W., Mu, X., Ruan, G., Gao, Z., Li, L., Yan, G., 2017. Estimating fractional vegetation cover and the vegetation index of bare soil and highly dense vegetation with a physically based method. *Int. J. Appl. Earth Obs. Geoinf.* 58, 168–176. doi:10.1016/j.jag.2017.01.015
- Sonobe, R., 2019. Parcel-based crop classification using multi-temporal TerraSAR-X dual polarimetric data. *Remote Sens.* 11, 1148. doi:10.3390/rs11101148
- Sonobe, R., Tani, H., Wang, X., Kobayashi, N., Shimamura, H., 2015. Discrimination of crop types with TerraSAR-X-derived information. *Phys. Chem. Earth* 83–84, 2–13. doi:10.1016/j.pce.2014.11.001
- Sonobe, R., Yamaya, Y., Tani, H., Wang, X., Kobayashi, N., Mochizuki, K. ichiro, 2017. Assessing the suitability of data from Sentinel-1A and 2A for crop classification. *GIScience Remote Sens.* 54, 918–938. doi:10.1080/15481603.2017.1351149
- Srikanth, P., Ramana, K. V., Deepika, U., Kalyan Chakravarthi, P., Sessa Sai, M.V.R., 2016. Comparison of Various Polarimetric Decomposition Techniques for Crop Classification. *J. Indian Soc. Remote Sens.* 44, 635–642. doi:10.1007/s12524-015-0525-6
- Steele-Dunne, S.C., McNairn, H., Monsivais-Huertero, A., Judge, J., Liu, P.W., Papathanassiou, K., 2017. Radar Remote Sensing of Agricultural Canopies: A Review. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* doi:10.1109/JSTARS.2016.2639043
- Stoer, J., Bulirsch, R., 2002. *Introduction to Numerical Analysis*, Third Edit. ed. Springer, New York, NY, USA.
- Story, M., Congalton, R.G., 1986. Accuracy assessment: a user's perspective. *Photogramm. Eng. Remote Sens.* 52, 397–399. doi:10.1111/j.1530-9290.2010.00257.x
- Sun, C., Bian, Y., Zhou, T., Pan, J., 2019. Using of multi-source and multi-temporal remote sensing data improves crop-type mapping in the subtropical agriculture region. *Sensors* 19, 2401. doi:10.3390/s19102401
- Sun, S., Liu, R., Wen, W., 2015. Unsupervised Classification Method for Polarimetric Synthetic Aperture Radar Imagery Based on Yamaguchi Four-Component Decomposition Model. *J. Electr. Comput. Eng.* 2015, 6. doi:10.1155/2015/680715
- Thompson, A.A., 2015. Overview of the RADARSAT Constellation Mission. *Can. J. Remote Sens.* 41, 401–407. doi:10.1080/07038992.2015.1104633

- Tilly, N., Aasen, H., Bareth, G., 2015. Fusion of plant height and vegetation indices for the estimation of barley biomass. *Remote Sens.* 7, 11449–11480. doi:10.3390/rs70911449
- Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., Potin, P., Rommen, B., Floury, N., Brown, M., Traver, I.N., Deghaye, P., Duesmann, B., Rosich, B., Miranda, N., Bruno, C., L'Abbate, M., Croci, R., Pietropaolo, A., Huchler, M., Rostan, F., 2012. GMES Sentinel-1 mission. *Remote Sens. Environ.* 120, 9–24. doi:10.1016/j.rse.2011.05.028
- Turkar, V., Deo, R., Rao, Y.S., Mohan, S., Das, A., 2012. Classification accuracy of multi-frequency and multi-polarization SAR images for various land covers. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 5, 936–941. doi:10.1109/JSTARS.2012.2192915
- Ulaby, F.T., 1975. Radar response to vegetation. *IEEE Trans. Antennas Propag.* 23, 36–45. doi:10.1109/TAP.1975.1140999
- Ulaby, F.T., Allen, C.T., Eger, G., Kanemasu, E., 1984. Relating the microwave backscattering coefficient to leaf area index. *Remote Sens. Environ.* 14, 113–133. doi:10.1016/0034-4257(84)90010-5
- Ulaby, F.T., Bush, T.F., Batlivala, P.P., 1975. Radar response to vegetation II: 8–18 GHz band. *IEEE Trans. Antennas Propag.* 23, 608–618. doi:10.1109/TAP.1975.1141133
- Ulaby, F.T., Held, D., Dobson, M.C., McDonald, K.C., Senior, T.B.A., 1987. Relating Polarization Phase Difference of SAR Signals to Scene Properties. *IEEE Trans. Geosci. Remote Sens.* GE-25, 83–92. doi:10.1109/TGRS.1987.289784
- UNFCCC, 2010. Annex to Report of the Conference of the Parties on Its Fifteenth Session, Held in Copenhagen from 7 to 19 December 2009, Addendum. Part Two: Action Taken by the Conference of the Parties at Its Fifteenth Session, FCCC/CP/2009/11/Add.1. see Decision 9/CP. Copenhagen, Denmark.
- Upreti, D., Huang, W., Kong, W., Pascucci, S., Pignatti, S., Zhou, X., Ye, H., Casa, R., 2019. A comparison of hybrid machine learning algorithms for the retrieval of wheat biophysical variables from Sentinel-2. *Remote Sens.* 11, 481. doi:10.3390/rs11050481
- Ustuner, M., Sanli, F.B., 2019. Polarimetric target decompositions and light gradient boosting machine for crop classification: A comparative evaluation. *ISPRS Int. J. Geo-Information* 8, 97. doi:10.3390/ijgi8020097
- Valcarce-Diñeiro, R., Arias-Pérez, B., Lopez-Sanchez, J.M., Sánchez, N., 2019. Multi-temporal dual- and quad-polarimetric synthetic aperture radar data for crop-type mapping. *Remote Sens.* 11, 1518. doi:10.3390/rs11131518
- Valcarce-Diñeiro, R., Lopez-Sanchez, J.M., Sánchez, N., Arias-Pérez, B., Martínez-Fernández, J., 2018. Influence of Incidence Angle in the Correlation of C-band Polarimetric Parameters with Biophysical Variables of Rain-fed Crops. *Can. J. Remote Sens.* 44, 643–659. doi:10.1080/07038992.2019.1579051
- Van Emmerik, T., Steele-Dunne, S.C., Judge, J., Van De Giesen, N., 2015. Impact of Diurnal Variation in Vegetation Water Content on Radar Backscatter from Maize During Water Stress. *IEEE Trans. Geosci. Remote Sens.* 53, 3855–3869. doi:10.1109/TGRS.2014.2386142

- Veloso, A., Mermoz, S., Bouvet, A., Le Toan, T., Planells, M., Dejoux, J.F., Ceschia, E., 2017. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sens. Environ.* 199, 415–426. doi:10.1016/j.rse.2017.07.015
- Verma, A.K., Nandan, R., Verma, A., 2019. Knowledge based classifier based on backscattering coefficient for monitoring the crop growth analysis using multi-temporal images of space-borne synthetic aperture radar (SAR) sensors, in: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. New Delhi, India, pp. 643–647. doi:10.5194/isprs-archives-XLII-3-W6-643-2019
- Wang, H., 2018. Soil Moisture Retrieval from Microwave Remote Sensing Observations, in: Civeira, G. (Ed.), *Soil Moisture*. IntechOpen, p. 118. doi:10.5772/intechopen.81476
- Wang, Z., Li, Y., Su, X., Tao, S., Feng, X., Wang, Q., Xu, X., Liu, Y., Michaletz, S.T., Shrestha, N., Larjavaara, M., Enquist, B.J., 2019. Patterns and ecological determinants of woody plant height in eastern Eurasia and its relation to primary productivity. *J. Plant Ecol.* 12, 791–803. doi:10.1093/jpe/rtz025
- Weiss, M., Baret, F., Smith, G.J., Jonckheere, I., Coppin, P., 2004. Review of methods for in situ leaf area index (LAI) determination Part II. Estimation of LAI, errors and sampling. *Agric. For. Meteorol.* 121, 37–53. doi:10.1016/j.agrformet.2003.08.001
- Werninghaus, R., 2004. TerraSAR-X mission, in: *SAR Image Analysis, Modeling, and Techniques VI*. doi:10.1117/12.511500
- Werninghaus, R., Buckreuss, S., 2009. The TerraSAR-X mission and system design. *IEEE Trans. Geosci. Remote Sens.* 48, 606–614. doi:10.1109/TGRS.2009.2031062
- White, J., Berg, A.A., Champagne, C., Zhang, Y., Chipanshi, A., Daneshfar, B., 2020. Improving crop yield forecasts with satellite-based soil moisture estimates: An example for township level canola yield forecasts over the Canadian Prairies. *Int. J. Appl. Earth Obs. Geoinf.* 89, 102092. doi:10.1016/j.jag.2020.102092
- Wiseman, G., McNairn, H., Homayouni, S., Shang, J., 2014. RADARSAT-2 Polarimetric SAR Response to Crop Biomass for Agricultural Production Monitoring. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 7, 4461–4471. doi:10.1109/JSTARS.2014.2322311
- Woodhouse, I.H., 2006. *Introduction to Microwave Remote Sensing*. CRC Press, Taylor & Francis Group, Boca Raton, FL, USA.
- Xie, Q., Dash, J., Huete, A., Jiang, A., Yin, G., Ding, Y., Peng, D., Hall, C.C., Brown, L., Shi, Y., Ye, H., Dong, Y., Huang, W., 2019. Retrieval of crop biophysical parameters from Sentinel-2 remote sensing imagery. *Int. J. Appl. Earth Obs. Geoinf.* 80, 187–195. doi:10.1016/j.jag.2019.04.019
- Xu, L., Zhang, H., Wang, C., Zhang, B., Liu, M., 2019. Crop classification based on temporal information using Sentinel-1 SAR time-series data. *Remote Sens.* 11, 53. doi:10.3390/rs11010053
- Yang, G., Liu, J., Zhao, C., Li, Zhenhong, Huang, Y., Yu, H., Xu, B., Yang, X., Zhu, D., Zhang, X., Zhang, R., Feng, H., Zhao, X., Li, Zhenhai, Li, H., Yang, H., 2017. Unmanned aerial vehicle remote sensing for field-based crop phenotyping: Current status and perspectives. *Front. Plant Sci.* 8, 1111. doi:10.3389/fpls.2017.01111

- Yin, J., Liu, X., Yang, J., Chu, C.Y., Chang, Y.L., 2020. PolSAR image classification based on statistical distribution and MRF. *Remote Sens.* 12, 1027. doi:10.3390/rs12061027
- Yu, R., Evans, A.J., Malleson, N., 2018. Quantifying grazing patterns using a new growth function based on MODIS Leaf Area Index. *Remote Sens. Environ.* 209, 181–194. doi:10.1016/j.rse.2018.02.034
- Yue, J., Yang, G., Li, C., Li, Z., Wang, Y., Feng, H., Xu, B., 2017. Estimation of winter wheat above-ground biomass using unmanned aerial vehicle-based snapshot hyperspectral sensor and crop height improved models. *Remote Sens.* 9, 708. doi:10.3390/rs9070708
- Yueh, S.H., Kong, J.A., Jao, J.K., Shin, R.T., Toan, T. Le, 1992. Branching model for vegetation. *IEEE Trans. Geosci. Remote Sens.* 30, 390–402. doi:10.1109/36.134088
- Zadoks, J.C., Chang, T.T., Konzak, C.F., 1974. A decimal code for the growth stages of cereals. *Weed Res.* 14, 415–421. doi:10.1111/j.1365-3180.1974.tb01084.x
- Zeyada, H.H., Ezz, M.M., Nasr, A.H., Shokr, M., Harb, H.M., 2016. Evaluation of the discrimination capability of full polarimetric SAR data for crop classification. *Int. J. Remote Sens.* 37, 2585–2603. doi:10.1080/01431161.2016.1182663
- Zhang, C., Pattey, E., Liu, J., Cai, H., Shang, J., Dong, T., 2018. Retrieving leaf and canopy water content of winter wheat using vegetation water indices. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 11, 112–126. doi:10.1109/JSTARS.2017.2773625
- Zhang, J., Xu, Y., Yao, F., Wang, P., Guo, W., Li, L., Yang, L., 2010. Advances in estimation methods of vegetation water content based on optical remote sensing techniques. *Sci. China Technol. Sci.* 53, 1159–1167. doi:10.1007/s11431-010-0131-3
- Zhang, Xiaoyang, Wang, J., Gao, F., Liu, Y., Schaaf, C., Friedl, M., Yu, Y., Jayavelu, S., Gray, J., Liu, L., Yan, D., Henebry, G.M., 2017. Exploration of scaling effects on coarse resolution land surface phenology. *Remote Sens. Environ.* 190, 318–330. doi:10.1016/j.rse.2017.01.001
- Zhang, Xiaoqiang, Yamaguchi, Y., Li, F., He, B., Chen, Y., 2017. Assessing the Impacts of the 2009/2010 Drought on Vegetation Indices, Normalized Difference Water Index, and Land Surface Temperature in Southwestern China. *Adv. Meteorol.* 2017, 9. doi:10.1155/2017/6837493
- Zhang, Y., Zhang, J., Zhang, X., Wu, H., Guo, M., 2015. Land Cover Classification from Polarimetric SAR Data Based on Image Segmentation and Decision Trees. *Can. J. Remote Sens.* 41, 40–50. doi:10.1080/07038992.2015.1032901
- Zhao, H., Chen, Z., Jiang, H., Jing, W., Sun, L., Feng, M., 2019. Evaluation of three deep learning models for early crop classification using Sentinel-1A imagery time series—a case study in Zhanjiang, China. *Remote Sens.* 11, 2673. doi:10.3390/rs11222673
- Zhou, T., Pan, J., Zhang, P., Wei, S., Han, T., 2017. Mapping winter wheat with multi-temporal SAR and optical images in an urban agricultural region. *Sensors.* doi:10.3390/s17061210
- Zhu, Q., Luo, Y., Xu, Y.P., Tian, Y., Yang, T., 2019. Satellite soil moisture for agricultural drought monitoring: Assessment of SMAP-derived soil water deficit index in Xiang River Basin, China. *Remote Sens.* 11, 362. doi:10.3390/rs11030362

# PUBLICACIONES





## Publicaciones

### *Artículos en revistas*

Valcarce-Diñeiro, R., Lopez-Sanchez, J.M., Sánchez, N., Arias-Pérez, B., and Martínez-Fernández, J. 2018. "Influence of incidence angle in the correlation of C-band polarimetric parameters with biophysical variables of rain-fed crops." *Canadian Journal of Remote Sensing*, Vol. 44: pp. 643-659. doi: 10.1080/07038992.2019.1579051

Valcarce-Diñeiro, R., Arias-Pérez, B., Lopez-Sanchez, J.M., and Sánchez, N. 2019. "Multi-temporal dual- and quad- polarimetric SAR data for crop-type mapping." *Remote Sensing*, Vol. 11(No. 13): pp. 1518. doi: 10.3390/rs11131518

Simon de Blas, C., Valcarce-Diñeiro, R., Sipols, A.E., Sánchez, N., Arias-Pérez, B., and Santos Martin, M.T. 2020. "Prediction of crop biophysical variables with panel data techniques and radar remote sensing imagery." *Biosystems Engineering (En Revisión)*.

### *Artículos en conferencias*

Sanchez, N., Lopez-Sanchez, J.M., Arias-Pérez, B., Valcarce-Diñeiro, R., Martínez-Fernández, J., Calvo-Heras, J.M., Camps, A., Gonzalez-Zamora, A., and Vicente-Guijalda, F. New microwave-based mission applications for rainfed crops characterization, *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLI-B1, 101-107, doi:10/5194/isprs-archives-XLI-B1-101-2016, 2016.

Valcarce-Diñeiro, R., Arias-Pérez, B., Lopez-Sanchez, J.M., and Sánchez, N. "Crop classification using multi-temporal polarimetric radar imagery" (poster), in *2<sup>nd</sup> Annual Congress on Plant Science and Biosecurity (ACPB-2019)*, pp. 69, London, UK, Jul. 2019.

Valcarce-Diñeiro, R., Lopez-Sanchez, J.M., Sánchez, N., Arias-Pérez, B., Martínez-Fernández, J. "Polarimetric and multiangular RADARSAT-2 satellite data for crop monitoring" (poster), in *2<sup>nd</sup> Annual Congress on Plant Science and Biosecurity (ACPB-2019)*, pp. 70, London, UK, Jul. 2019.



# ANEXOS



## Anexo A: Influence of Incidence Angle in the Correlation of C-band Polarimetric Parameters with Biophysical Variables of Rain-fed Crops

CANADIAN JOURNAL OF REMOTE SENSING  
<https://doi.org/10.1080/07038992.2019.1579051>



### Influence of Incidence Angle in the Correlation of C-band Polarimetric Parameters with Biophysical Variables of Rain-fed Crops

Rubén Valcarce-Diñeiro<sup>a</sup>, Juan M. Lopez-Sanchez<sup>b</sup>, Nilda Sánchez<sup>a,c</sup>, Benjamín Arias-Pérez<sup>a</sup>, and José Martínez-Fernández<sup>c</sup>

<sup>a</sup>Department of Cartographic and Land Engineering, University of Salamanca, Hornos Caleros 50, Ávila, 05003, Spain; <sup>b</sup>IUII, University of Alicante, P.O. Box 99, Alicante, E-03080, Spain; <sup>c</sup>CIALE, University of Salamanca, Duero 12, 37185 Villamayor, Salamanca, Spain

#### ABSTRACT

A multi-temporal field experiment was conducted within the Soil Measurement Stations Network of the University of Salamanca (REMEDIHUS) in Spain in order to retrieve useful crop information. The objective of this research was to evaluate the potential of polarimetric observations for crop monitoring by exploiting a time series of 20 quad-pol RADARSAT-2 images at different incidence angles (i.e. 25°, 31°, and 36°) during an entire growing season of rain-fed crops, from February to July 2015. The time evolution of 6 crop biophysical variables was gathered from the field measurements, whereas 10 polarimetric parameters were derived from the images. Thus, a subsequent correlation analysis between both datasets was performed. The study demonstrates that the backscattering ratios (HH/VV and HV/VV), the normalized correlation between HH and VV ( $\gamma_{HHVV}$ ), and the dominant alpha angle ( $\alpha_1$ ), showed significant and relevant correlations with several biophysical variables such as biomass, height, or leaf area index (LAI) at incidence angles of 31° or 36°. The joint use of data acquired with different beams could be exploited effectively to increase the refresh rate of information about crop condition with respect to a single incidence acquisition scheme.

#### RÉSUMÉ

Sur le site du Réseau des Stations de Mesure des Sols de l'Université de Salamanca (REMEDIHUS) en Espagne, un suivi multitemporelle de diverses cultures a été réalisée de radar à ouverture. L'objectif de cette recherche est d'analyser le potentiel des observations polarimétriques pour la surveillance de cultures exploitant une série temporelle d'images quad-pol RADARSAT-2 sous différents angles d'incidence (c'est-à-dire 25°, 31°, et 36°) durant toute la période de croissance. Vingt images de RADARSAT-2 ont été obtenues dans la zone d'étude entre les mois de février et juillet 2015. 6 variables biophysiques ont été mesurées sur le terrain et 10 paramètres polarimétriques ont été dérivés des images. Une analyse de corrélation a été réalisée entre les ensembles de données. L'étude montre que les relations de rétrodispersion (HH/VV et HV/VV), la corrélation normalisée entre HH et VV ( $\gamma_{HHVV}$ ) et l'angle alpha dominant ( $\alpha_1$ ) présentent des corrélations significatives et importantes avec divers variables biophysiques comme la biomasse, la hauteur ou l'indice de surface foliaire (LAI) pour des angles d'incidence de 31° à 36°. On pourrait profiter de l'utilisation conjointe de ces deux angles pour augmenter le taux d'information sur l'état des cultures par rapport à un seul schéma d'acquisition d'incidence.

#### ARTICLE HISTORY

Received 17 May 2018  
Accepted 2 February 2019

#### Introduction

Synthetic aperture radar (SAR) satellite data are useful for mapping and monitoring agriculture because microwave frequencies operate night and day in all weather conditions, and agricultural targets such as soils and crops are very dynamic. Contrarily, optical sensors can miss crucial periods during the growing season due to the presence of clouds. The potential of SAR data is based on the sensitivity of the radar

backscattering to the dielectric properties and structure of the targets (i.e. the size, shape, and orientation of the distribution of the elements in the scene) (McNairn and Brisco 2004; Skriver et al. 1999; Ulaby et al. 1984).

Crop monitoring approaches that employed early SAR instruments exploited only the backscattering coefficient, usually on a single polarization channel, which was the only observation provided from the

CONTACT Rubén Valcarce-Diñeiro  [ruben.v.d@usal.es](mailto:ruben.v.d@usal.es)  
Copyright © CASI

operational sensors at that time. Unfortunately, different site properties (e.g. soil roughness and moisture, and vegetation properties) lead to similar values and equivalent changes in the backscattering coefficient, so crop monitoring with SAR was not very successful (Steele-Dunne et al. 2017). This situation started to change in 2007 with the launch of ALOS-PALSAR by the Japan Aerospace Exploration Agency (JAXA), RADARSAT-2 by the Canadian Space Agency (CSA) and TerraSAR-X by the German Aerospace Centre (DLR), for which polarimetric information (i.e. correlations and phase difference between channels) is also available. The new coherent polarimetric acquisitions opened new perspectives for the features to be studied when trying to build a crop monitoring application. In the future, the RADARSAT Constellation Mission (RCM) (Thompson 2015) will continue providing the necessary polarimetric information for agricultural monitoring.

In order to design a crop monitoring application that uses SAR images, it is necessary to analyze the sensitivity of the radar parameters (i.e. the backscattering coefficient or any other variable derived from the radar measurements) with respect to the biophysical variables that describe the crop conditions on each acquisition date. Some examples in the literature show a correlation of crop parameters with polarimetric radar parameters, both for specific crops such as rice (Inoue et al. 2002, 2014; Inoue and Sakaiya 2013), maize (Bériaux et al. 2015), or several crop types simultaneously (Cable et al. 2014; Ulaby et al. 1984; Wiseman et al. 2014).

From pioneering studies (Ulaby et al. 1984) to more recent studies (Inoue et al. 2002), ground-based scatterometers at different frequencies, polarizations, and incidence angles have shown sensitivity and good correlations to crop parameters. The use of RADARSAT-2 as a satellite sensor with polarimetric capabilities for crop monitoring was initiated with field campaigns in Canada in 2008, and also explored by the European Space Agency (ESA)-funded AgriSAR2009 campaign. One of the first full papers exploiting these data was published by Moran et al. (2012), in which the backscattering coefficients for all polarization channels were obtained from a time series of 57 RADARSAT-2 quad-polarization images acquired at C-band at different incidence angles from April to September 2009 for fields of wheat, barley, oat, corn, onion, and alfalfa. The cross-polarized channel was useful for monitoring both crop and soil conditions, and was shown to be least sensitive to differences in the incidence angle. The time series offered reliable information about crop phenology. A positive correlation was found between the backscattering coefficients and the

normalized difference vegetation index (NDVI) for onion and corn but not for all crops, and the impact of the view direction and the incidence angle on the time series was minimal compared with the signal response for crop and soil conditions. Inoue and Sakaiya (2013) and Inoue et al. (2014) studied the correlation of the backscattering coefficients obtained at X-band (COSMO SkyMed) and C-band (RADARSAT-2) for rice canopies, suggesting the potential of satellite SAR images for the direct assessment of rice yield and other parameters (leaf area index (LAI), leaf biomass, and fraction of absorbed photosynthetically active radiation (fAPAR)) at a regional scale. More recently, Bériaux et al. (2015) studied C-band quad polarimetric satellite data for retrieving LAI and soil moisture in maize fields. The cross-polarization sensitivity was highlighted, especially for a high LAI, and the vertical transmit and receive (VV) polarization was found to be sensitive for LAI values less than 2.

All of the abovementioned studies used only backscattering coefficients in 1 or more polarimetric channels, so no other polarimetric observations were analyzed. Other studies have enlarged the set of parameters beyond the backscattering coefficients. Cable et al. (2014), using RADARSAT-2 images at 2 incidence angles, analyzed how changes in the acquisition time and the incidence angle affected C-band polarimetric parameters for various crops such as barley, canola, oat, soybean, and wheat. The backscattering coefficients for all targets were higher when acquired at a steeper incidence angle (26°). All cash crop targets showed a rise and fall in the backscattering response during the course of the growing season, coinciding with the changing growth stages. Jiao et al. (2011) evaluated 18 polarimetric parameters derived from quad-pol RADARSAT-2 images at steep (25°) and shallow (40°) incidence angles with LAI of corn and soybean. They found that corn and soybean LAI were better correlated with polarimetric parameters sensitive to volume scattering (backscattering coefficient at the cross-polar channel in the linear basis, i.e. HV, and at the co-polar channels in circular basis, i.e. LL and RR, pedestal height, and volume scattering from Freeman-Durden decomposition) with the steeper incidence angle.

The polarimetric response plots and decompositions offered insight into the scattering mechanism for each crop type, and generally showed an increase in volume scattering as the crops reach maturity. Specifically, the primary scattering type shifted from surface scattering to volume scattering as the crops matured, both in regards to the Cloude and Pottier (1997) and Freeman and Durden (1998) decompositions. Wiseman et al.

(2014) compared 21 polarimetric parameters derived with RADARSAT-2 images with dry biomass of canola, corn, soybean, and spring wheat. During the period of biomass accumulation, significant correlations with dry biomass were observed for most SAR parameters in corn, canola, and soybeans, which could prove to be useful as indicators of harvest timing. Adams et al. (2013b) investigated the Cloude–Pottier and Freeman–Durden scattering decompositions of RADARSAT-2 C-band data to identify harvested fields. The research reported that polarimetric scattering decomposition applied to shallower incidence angle acquisitions may be of utility for agricultural monitoring due to the characterization of unique scattering mechanisms from soils and biomass. Other studies that use a varied set of polarimetric parameters can be found in Lopez-Sanchez et al. (2012, 2014). These parameters, computed at the X-band with dual-pol data from TerraSAR-X and at the C-band with quad-pol data from RADARSAT-2, were used to track phenological changes in rice fields. Adams et al. (2013a) employed a set of polarimetric parameters from RADARSAT-2 data at different incidence angles to assess the sensitivity of these parameters to unvegetated agricultural surface features. Smith and Buckley (2011) derived the 3 Freeman–Durden decomposition parameters from RADARSAT-2 images to monitor grasslands and generate land cover maps.

The overall goal of this research is to extend the knowledge about the potential of polarimetric parameters (i.e. beyond the backscattering coefficients) for crop monitoring. This objective is more ambitious than in previous studies because 3 overlapped time series of quad-pol RADARSAT-2 images were acquired at 3 different incidence angles. The field campaign took place in 7 plots of rain-fed crops during their growing season in central Spain in 2015. The resulting dataset of plant and canopy parameters was compared with the polarimetric parameters derived from the RADARSAT-2 images by applying a correlation analysis.

The novel contribution of this study is the investigation of the effect of incidence angle on the correlation between polarimetric parameters and biophysical variables. This effect was studied in the past mostly with ground-based systems (Della Vecchia et al. 2006), but only a few examples with satellite data exist in the literature (Cable et al. 2014; Lopez-Sanchez et al. 2015). Hence, this study could help enlighten the choice of the best incidence angle for crop monitoring, as well as determining which parameters are less affected by changes in the incidence angle (hence

enabling the combination of different beams for decreasing the time interval between images, which is key for monitoring applications).

## Materials and methods

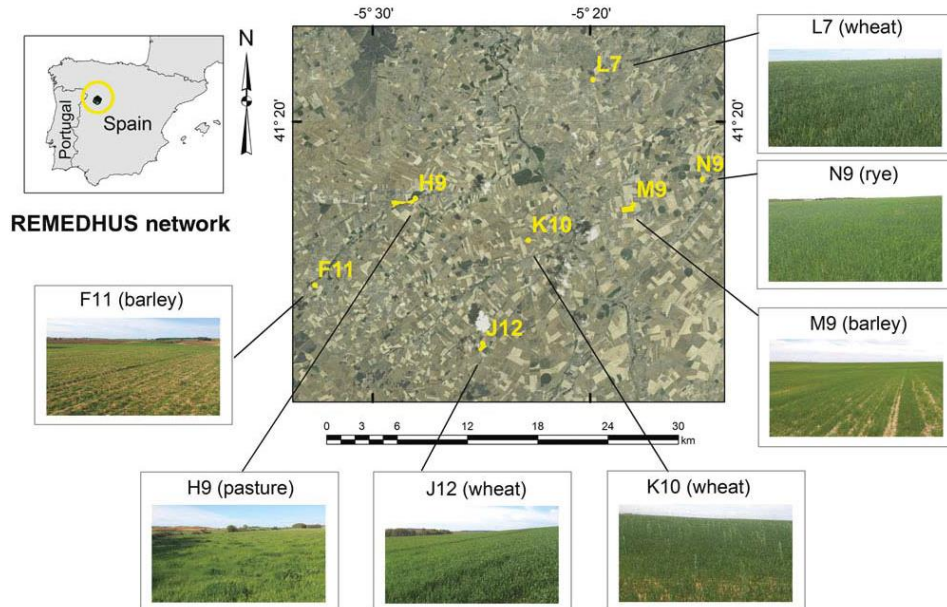
### Study area and field campaign

The field campaign took place in 2015 during the rain-fed crop-growing season in an agricultural area in the central part of the Duero Basin in Spain (Figure 1). In this area, the Soil Moisture Stations Network of the University of Salamanca (REMEDIHUS) (Sánchez et al. 2012b) routinely provides soil moisture and other agro-climatic data that have been used in remote sensing and modeling applications. For this reason, REMEDIHUS is a validation core site for several microwave passive sensors (Colliander et al. 2017; González-Zamora et al. 2016). Additionally, data from active sensors were also tested in REMEDIHUS, from the scatterometers onboard the European Remote Sensing Satellites (ERS) and its successor, the Advanced Scatterometer (ASCAT) (Brocca et al. 2011; Ceballos et al. 2005). REMEDIHUS comprises a set of soil moisture and weather stations that provide a continuous time series from 1999 to the present day. The area is mainly agricultural and has a continental semi-arid Mediterranean climate. The rain-fed crops are the most common land cover in the area, comprising approximately 80% of the entire site (Sánchez et al. 2010), and are mainly winter cereals, seeded in October and harvested at the end of June or the beginning of July. The field measurements for this experiment were made in the plots corresponding to 7 REMEDIHUS stations, namely J12, K10, and L7 (wheat), F11 and M9 (barley), N9 (rye) and H9 (natural pasture). The pasture plot (H9) is a natural area without any agricultural nor livestock use, but a random mix of different grasses. The measurements were acquired throughout the growing season, i.e. from February to July 2015, every fortnight ( $n=9$ ), 1 sample per plot over a frame of 1 m<sup>2</sup>.

In each plot, canopy height was directly measured and zenithal photographs were taken before the sampling. The phenological stages of the cereals were registered using a scale with 5 main intervals: (i) early vegetative phase (day of year (DoY)=0–70); (ii) plant emergence (DoY=71–100); (iii) advanced vegetative phase (DoY=101–115); (iv) reproductive phase (DoY=116–135); and (v) maturation phase (DoY=136–end).

LAI, the fraction of vegetation cover (FVC), the fresh and dry weights, the vegetation water content

4 R. VALCARCE-DIÑEIRO ET AL.



**Figure 1.** Study area, location of field plots, and a general view of the different vegetation types. ©Field pictures by the authors. Orthophotographs ownership and rightsholders in CC BY 4.0 <http://www.scne.es/productos.html#OrtoPNOA>. Reproduced by permission of Instituto Geográfico Nacional and Junta de Castilla y León. Permission to reuse must be obtained from the rightsholders.

(VWC) and the percentage of water content (PWC) were then estimated in the laboratory. These parameters have been used frequently in the related literature (Jackson et al. 2004; Jiang et al. 2006). The measurement protocols followed those described in Sánchez et al. (2012a). The green LAI was estimated via a destructive method in which photosynthetically active leaves were extracted from the sample, and then scanned and scaled to retrieve the areal value. The sample was then dried until reaching a constant weight in an oven at 70 °C for at least 24 hours. The VWC was estimated as the difference between the wet and dry weights, considering the total amount of water in the stems and leaves. PWC is the ratio (as a percentage) between the VWC and the fresh weight. Finally, the FVC was estimated from the digital photographs using a supervised classification. Soil moisture (SM) measurements from the REMEDHUS stations were also collected, coinciding with the date and time of the measurements. Hydra Probes Soil Sensors (Stevens® Water Monitoring System Inc., Portland, OR, USA) were installed at a depth of 5 cm in each plot for this purpose.

#### SAR data and pre-processing

Polarimetric C-band (5.405 GHz) RADARSAT-2 imagery was used in this study. RADARSAT-2 has a repeat orbit of 24 days, but its different beam modes enable more frequent revisiting. The 3 sets of fine quad-Pol RADARSAT-2 single look complex (SLC) images were acquired with average incidence angles of 25°, 31°, and 36° (Table 1). Twenty images were acquired over the study area between February and July 2015. These images can be grouped in 3 series, comprising 7 images at 36°, 7 at 31°, and 6 at 25° (Table 1).

Image processing was performed with the freely accessible Sentinel-1 Toolbox Sentinel Application Platform (SNAP, <http://step.esa.int/main/toolboxes/snap>) provided by the ESA. The RADARSAT-2 images are provided with a polarimetric calibration already applied, so the corresponding look-up table alone was employed to convert them radiometrically to represent the backscattering coefficients. The polarimetric coherency matrix (Cloude and Pottier 1996) was then generated for each pixel in an image. A 9 × 9 boxcar filter was applied to reduce the speckle noise. With reference to the specification of these



**Table 1.** List of available RADARSAT-2 images and their correspondence with field measurements.

Acquisition Date	Day of Year (DoY)	Beam Mode	Average Incidence Angle (°)	Field Measurements
16 February 2015	47	FQ16W	36	17 February 2015
23 February 2015	54	FQ11W	31	3 March 2015
12 March 2015	71	FQ16W	36	
19 March 2015	78	FQ11W	31	19 March 2015
26 March 2015	85	FQ6W	25	
5 April 2015	95	FQ16W	36	8 April 2015
12 April 2015	102	FQ11W	31	
19 April 2015	109	FQ6W	25	21 April 2015
29 April 2015	119	FQ16W	36	
6 May 2015	126	FQ11W	31	6 May 2015
13 May 2015	133	FQ6W	25	19 May 2015
23 May 2015	143	FQ16W	36	
30 May 2015	150	FQ11W	31	2 June 2015
6 June 2015	157	FQ6W	25	
16 June 2015	167	FQ16W	36	16 June 2015
23 June 2015	174	FQ11W	31	
30 June 2015	181	FQ6W	25	
10 July 2015	191	FQ16W	36	
17 July 2015	198	FQ11W	31	
24 July 2015	205	FQ6W	25	

**Table 2.** List of polarimetric parameters analyzed in this study.

Polarimetric parameter	Symbol
Backscattering coefficient at HH, HV, and VV channels	$\sigma_{HH}^0, \sigma_{HV}^0, \sigma_{VV}^0$ , or simply HH, HV, and VV
Ratio of backscattering coefficients at HH, HV, and VV channels	HH/VV, HV/VV
Normalized correlation (coherence) between the co-polar channels (HH and VV)	$\gamma_{HHVV}$
Dominant alpha angle (from the eigen decomposition of the coherency matrix)	$\alpha_1$

RADARSAT-2 images, the equivalent number of looks provided by such  $9 \times 9$  filtering is above 48, which is large enough to obtain a reliable estimate of all polarimetric parameters in the subsequent analysis. For the parameters derived from the eigen-decomposition of the coherency matrix, it is known that the necessary number of looks may be larger than 48 (Lee et al. 2008), but no significant differences were detected when the window size was increased above  $9 \times 9$ . Therefore, the same window size was used for all parameters. The range doppler orthorectification method available in SNAP was applied for terrain correction and geocoding, using the digital elevation model from the Shuttle Radar Topography Mission (SRTM). The final spacing of the geocoded images was 5 m. Geocoding was applied to all of the entries of the filtered coherency matrices, i.e. a polarimetric coherency matrix was obtained at each geocoded pixel. Before the SAR parameters were estimated at field level, a 5-pixel erosion was carried out for all fields to prevent adjacent plot pixels from affecting the results.

**Polarimetric SAR parameters**

The 7 polarimetric parameters (Table 2) were computed from the coherency matrices available for each pixel after geocoding. All parameters were obtained using the free-access PolSARpro software provided by ESA

(<https://earth.esa.int/web/polsarpro>). The symbols used below to denote the parameters are shown in Table 2.

The first group of selected parameters correspond to those that can be obtained directly from the polarimetric covariance matrix C, which is derived from the data gathered in the linear basis (horizontal and vertical polarizations) and arranged using the lexicographic basis (Cloude and Pottier 1996). These parameters are the backscattering coefficients and ratios, obtained from the diagonal of the covariance matrix C, and the correlations between channels (i.e. the amplitudes and phases) obtained from the rest of the entries of the matrix C. The mathematical expression of these parameters is as follows (see Table 2 for notation)

$$\sigma_{HH}^0 = 10\log_{10}(C(1, 1)) \quad [1]$$

$$\sigma_{HV}^0 = 10\log_{10}(C(2, 2)) \quad [2]$$

$$\sigma_{VV}^0 = 10\log_{10}(C(3, 3)) \quad [3]$$

$$HH/VV = 10\log_{10}(C(1, 1)/C(3, 3)) \quad [4]$$

$$HV/VV = 10\log_{10}(C(2, 2)/C(3, 3)) \quad [5]$$

$$\gamma_{HHVV} = C(1, 3)/\sqrt{C(1, 1) \times C(3, 3)} \quad [6]$$

The dominant alpha angle ( $\alpha_1$ ) was also tested because it is widely used in the literature on SAR polarimetry, and provides a clear physical interpretation of the data. It is important to note that the

correlations between the cross-polar channel and the co-polar channels, i.e.  $\gamma_{HHHV}$  and  $\gamma_{HVVV}$ , are not considered in the study because for natural surfaces they are very small due to reflection symmetry (Cloude and Pottier 1996). Additional parameters, such as the backscattering level on a Pauli basis or the outputs of model-based decompositions (Freeman and Durden 1998), are not included in the present study to limit its length and the final number of results. In the same vein, additional analyses could be done by exploiting other variations on a polarimetric basis (e.g. circular polarizations) or by selecting specific measurement modes (e.g. compact polarimetry). All of these options are meant to be the objectives of further research.

**Correlation between SAR parameters and biophysical variables**

A correlation analysis was carried out between all SAR parameters acquired at different incidence angles (25°, 31°, and 36°), and the monitored biophysical variables. MATLAB (<https://www.mathworks.com/products/matlab.html>) was employed to apply a spline interpolation of the ground measurements in order to match the dates of RADARSAT-2 images (Table 1). Regarding the spatial matching, a cubic interpolation

of the values at each neighboring grid point was applied. The correlation coefficient (Pearson's  $r$ ) between each parameter and the 6 biophysical variables is computed separately for the 7 crop fields and the 3 different incidence angles. The number of samples used to calculate  $r$  was 9, corresponding to the number of field measurements along the growing cycle. The statistical significance was evaluated at a 95% confidence level ( $p$ -value=0.05). For a better understanding of the correlations results, different thresholds were established to classify  $r$ : moderate ( $\pm 0.66$  to 0.75), high ( $\pm 0.75$  to 0.85), and very high ( $\pm 0.85$  to 1).

**Results and discussion**

**Behavior of biophysical variables**

The temporal evolution of each parameter for each crop type was derived from the in situ measurements (Figure 2). Crop height (Figure 2) showed a similar growth pattern for wheat, pasture, and barley (except for F11, with some delay), with maxima at the beginning of the maturity phase (DoY=126), which remained until senescence. The data clearly show that rye (N9) is much taller than the other land cover types evaluated.

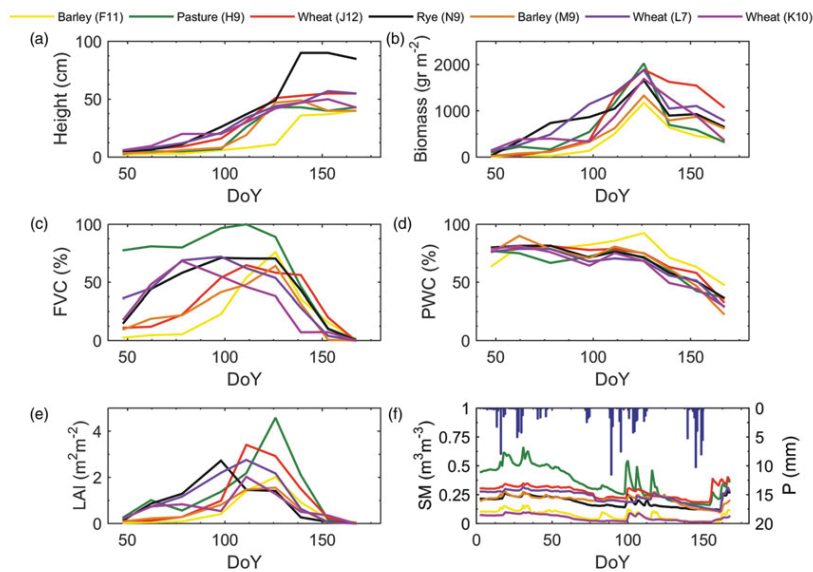


Figure 2. Evolution of: (a) height; (b) biomass; (c) FVC; (d) PWC; (e) LAI; and (f) daily precipitation and soil moisture for the 7 agricultural plots. Note that several parameters drop to 0 because the plants had already been harvested when the last measurement was made.

The highest density for FVC (Figure 2) was found for pasture (H9), which had higher values during winter, since natural pasture has an annual cycle. In contrast, cereals showed an increasing trend at the beginning of the campaign, reaching a maximum FVC approximately at the maturation phase (DoY = 126), then a plateau-shaped behavior for rye and wheat, and a peak for barley. It is important to clarify that the FVC parameter considers only green cover. At the last dates (DoY = 160), the crops are still standing but the plants are totally dry (in senescence stage), thus FVC = 0 despite that vegetation heights are large. The LAI evolution (Figure 2) showed the highest values for pasture, in accordance with the FVC, owing to its dense coverage. Barley showed the smallest LAI and a slight delay in comparison to wheat and rye, which started earlier (especially rye). All the biomass curves (Figure 2) have a similar pattern. The highest biomass ranged from  $1 \text{ kg m}^{-2}$  to  $2 \text{ kg m}^{-2}$  and corresponded to the pasture area, followed by wheat, rye, and barley. This biomass behavior represents the typical crop growth curve and is similar to the LAI behavior. The PWC (Figure 2) is very different from the rest of the vegetation parameters: a descending general trend is observed, although with some fluctuation. The consumption of water decreases towards the end as the plants dry out. This trend is confirmed by the soil moisture behavior (Figure 2), since the soil water content decreased throughout the growing cycle, even if small rainfall events occurred. These results were generally similar to those obtained in a previous field study at REMEDHUS for barley and pasture crops, described in Sánchez et al. (2012a).

#### **Behavior of the SAR parameters and effect of the incidence angle**

##### **Backscattering coefficients**

The temporal evolution of the backscattering coefficients in a linear basis (i.e. HH, HV, and VV) and the HH/VV and HV/VV ratios are plotted in Figures 3–7, respectively, for the 4 crop types and the 3 incidence angles. At an early time (DoY = 45–70), the 3 backscattering coefficients showed a decreasing trend from very large values. Because the vegetation was very short at that moment, the only explanation for this radar response could be the rain events that occurred during this time period, followed by dry weather (Figure 2). HH (Figure 3) and VV (Figure 4) have very similar values (i.e. HH/VV is approximately 0 dB), and HV is between 5 dB and 12 dB below the co-polar channels, as expected from the dominant

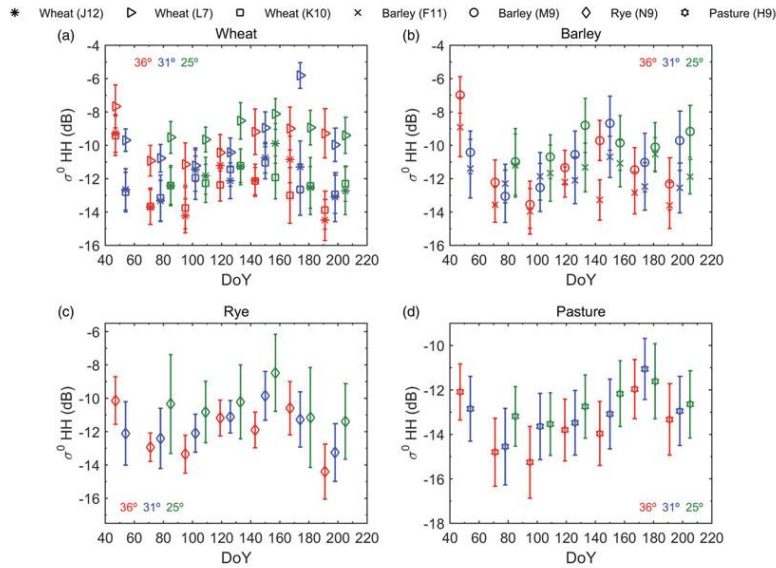
surface scattering. In fact, the small perturbation model and the Bragg scattering model for rough surfaces predict that VV will be slightly higher than HH, in a range 0 dB–3 dB, depending on roughness, moisture, and incidence angle (Chen and Fung 1988; Fung 1994; Hajnsek et al. 2003). In this study, however, it measured a very similar backscattering level for both linear channels, as it was also previously observed at the beginning of the cropping season by other authors (Bouvet et al. 2009; Satalino et al. 2009).

Plants emerged during the intermediate dates (DoY = 71–135), and the response for HH increased significantly due to the presence of vertical stems and tillers. The response for VV decreased for all crops, however, especially for  $36^\circ$  and  $31^\circ$ , because the vertical polarization was more attenuated than the horizontal one. This pattern is well described by the HH/VV ratio. At the end of the cycle, from DoY = 140 to the end, plants lose their verticality and become randomly oriented, so the difference between the 2 polarization channels is much smaller, i.e. within  $\pm 1.5$  dB at  $36^\circ$  for most crops. A similar effect occurred for  $25^\circ$ , although high values of both co-polar channels could be observed for wheat (L7) during the late dates at this incidence angle, possibly because a larger amount of biomass was present during these stages, as shown in Figure 2.

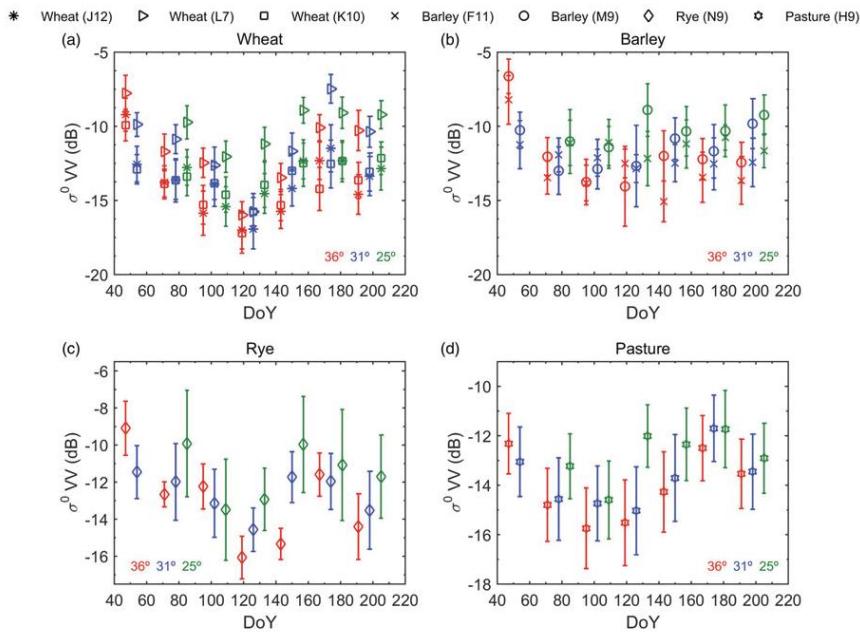
Figure 5 displays that the cross-polar channel (HV) was mostly driven by the presence of the vegetation volume as it is composed of randomly oriented elements. As previously mentioned, the cross-polar return was very low at all incidence angles during the early dates, but volume scattering increased at intermediate dates (DoY = 71–135) because of plant development, so HV increased for all crops and for all 3 incidence angles. The maximum values (between  $-13$  dB and  $-14$  dB) at this stage are found for barley (M9) at all incidence angles. It decreased for some crops at the later dates, but in other cases it increased slightly due to the random volume morphology of the crops.

The co-polar ratio (HH/VV) is strongly sensitive to the crop growth cycle for wheat, barley, and rye, whereas it showed quite a uniform response for pasture (Figure 6). The maximum values for this ratio are reached at the middle of the growing season, and clearly depend on the crop type and the incidence angle. The extreme values for wheat and rye are approximately 5 dB both at  $31^\circ$  and  $36^\circ$ , and 2 dB–3 dB at  $25^\circ$ , but the ratio for barley reaches only 2 dB for  $31^\circ$  and  $36^\circ$  and does not show any peak at  $25^\circ$ .

8 R. VALCARCE-DÍNEIRO ET AL.



**Figure 3.** Temporal evolution of the backscattering coefficient (HH) on the linear polarization basis for all fields. (a) Wheat; (b) barley; (c) rye; (d) pasture. Averages (symbols) and standard deviations (error bars) are computed within each field. Red color denotes an incidence angle at 36°, blue at 31°, and green at 25°.



**Figure 4.** Temporal evolution of the backscattering coefficient (VV) on the linear polarization basis for all fields. (a) Wheat; (b) barley; (c) rye; (d) pasture. Averages (symbols) and standard deviations (error bars) are computed within each field. Red color denotes an incidence angle at 36°, blue at 31°, and green at 25°.

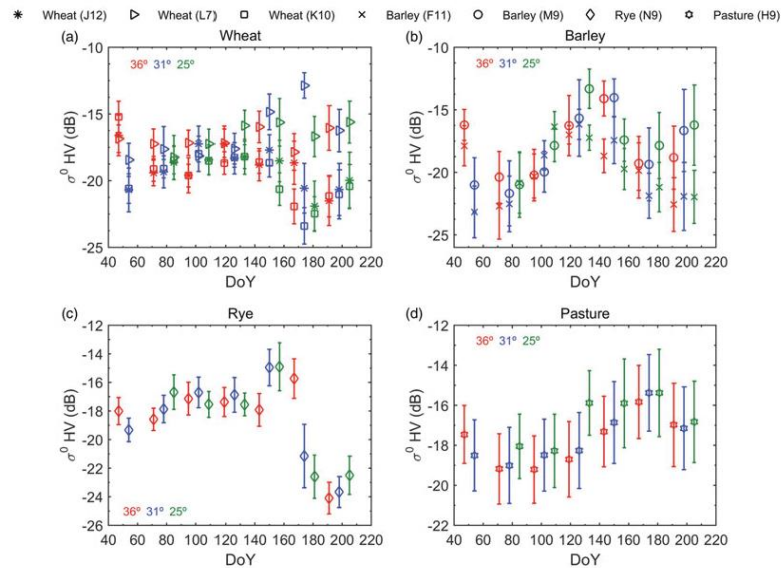


Figure 5. Temporal evolution of the backscattering coefficient (HV) on the linear polarization basis for all fields. (a) Wheat; (b) barley; (c) rye; (d) pasture. Averages (symbols) and standard deviations (error bars) are computed within each field. Red color denotes an incidence angle at 36°, blue at 31°, and green at 25°.

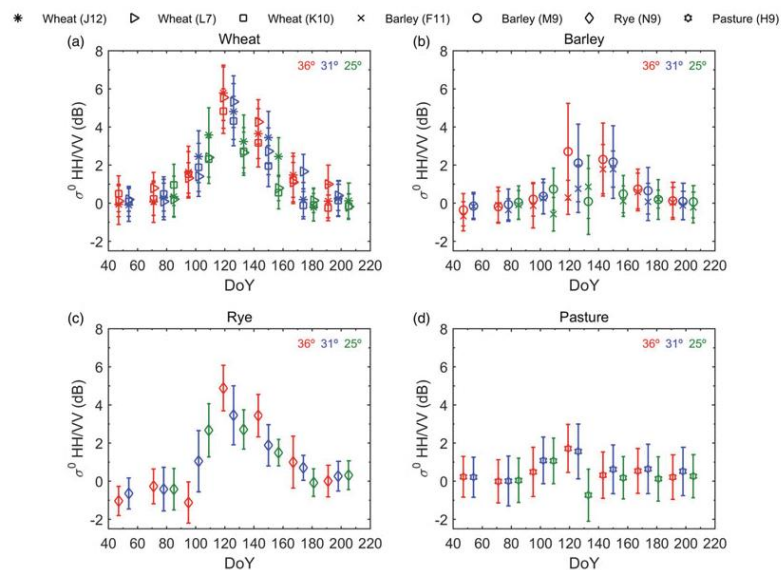
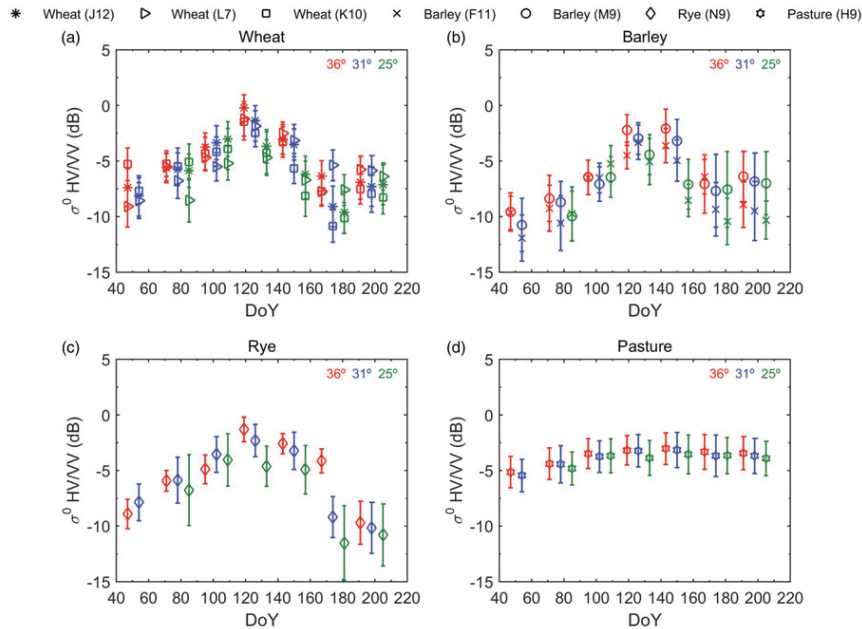


Figure 6. Temporal evolution of the backscattering ratio (HH/VV) on the linear polarization basis for all fields. (a) Wheat; (b) barley; (c) rye; (d) pasture. Averages (symbols) and standard deviations (error bars) are computed within each field. Red color denotes an incidence angle at 36°, blue at 31°, and green at 25°.

10 R. VALCARCE-DIÑEIRO ET AL.



**Figure 7.** Temporal evolution of the backscattering ratio (HV/VV) on the linear polarization basis for all fields. (a) Wheat; (b) barley; (c) rye; (d) pasture. Averages (symbols) and standard deviations (error bars) are computed within each field. Red color denotes an incidence angle at 36°, blue at 31°, and green at 25°.

Finally, the HV/VV ratio (Figure 7) also showed an increasing–decreasing behavior with time like the HH/VV ratio, but the values at each date are different for different crops and incidence angles. The shallowest angle (36°) produced the highest values at each date and the steepest (25°) the smallest, with a difference between 2 dB and 4 dB. Barley is the crop type with the lowest HV/VV values, and both rye and wheat behave similarly. In addition, both ratios have a temporal pattern similar to those of LAI and biomass (Figure 2), suggesting their feasibility for monitoring crop vigor.

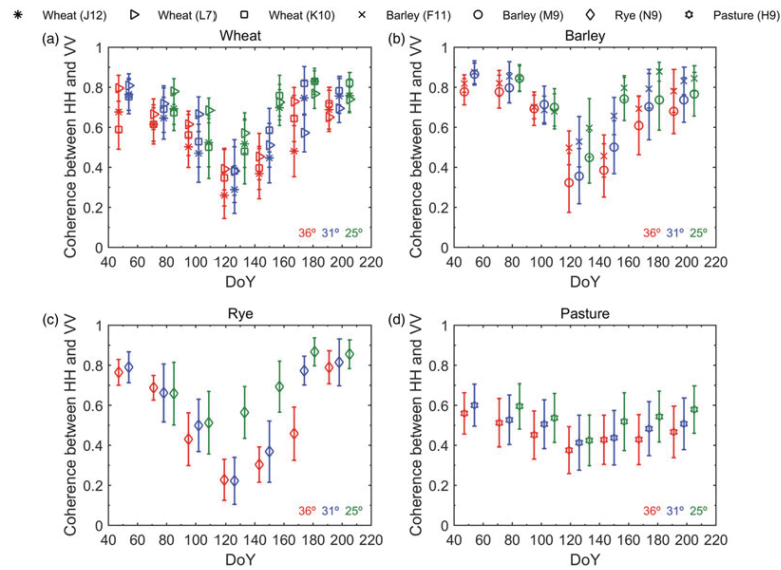
#### Correlation between HH and VV

Figure 8 depicts the normalized correlation, or coherence, between HH and VV,  $\gamma_{HHVV}$ , for all plots at different incidence angles. During the early stages, when surface scattering is the most important contribution, a high correlation is found, with values between 0.6 and 0.9. Then, as plant foliage develops,  $\gamma_{HHVV}$  decreases between 0.2 and 0.6, depending on the crop type and the incidence angle. In general, the drop is less pronounced at 25° than at 31° and 36°, in agreement with the more pronounced contribution from

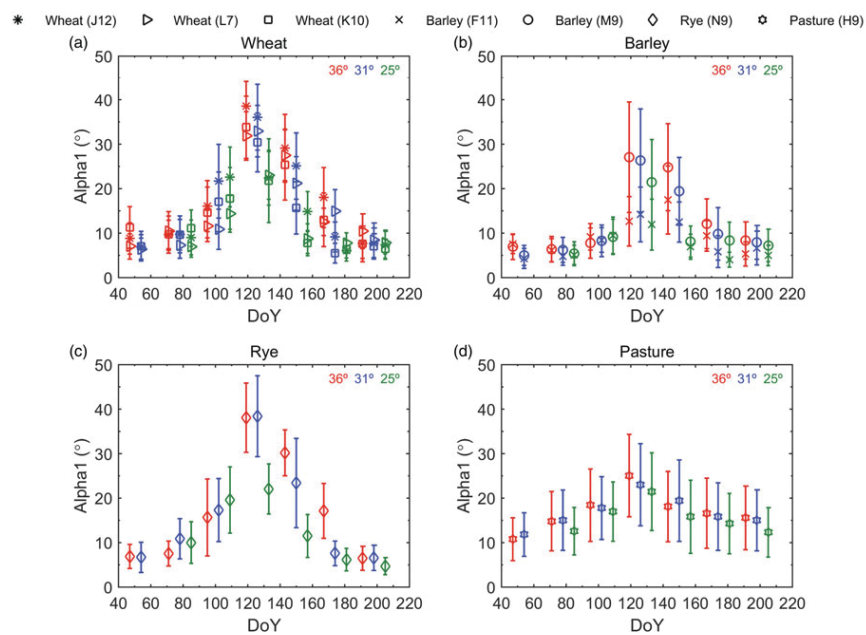
the soil at steep angles than at shallow angles. At the end of the experiment, coinciding with the driest stage of plants and the harvest time,  $\gamma_{HHVV}$  becomes high again, similar to the beginning of the campaign. The cause of the high  $\gamma_{HHVV}$  at these late stages is again the dominance of surface scattering, since backscattering from vegetation is reduced due to the dry condition of the plants. The temporal pattern for  $\gamma_{HHVV}$  is opposite to that of the HH/VV and HV/VV ratios, so it suggests an inverse relationship with LAI and biomass (Figure 2).

#### The dominant alpha angle

Figure 9 shows the evolution of the dominant alpha angle ( $\alpha_1$ ), i.e. the alpha angle of the first eigenvector. During the early vegetative phase,  $\alpha_1$  was close to 0° for all crops and angles, which is typical for bare soils and surface scattering. An increasing trend ensued as the plants developed, and peaked at approximately DoY = 110–130 with a value of 40° for wheat and rye, at incidence angles of 31° and 36°. This alpha value corresponds to a linearly polarized radar return resulting from the dominance of HH over VV (HH was 5 dB higher than VV). At the same stage, but at



**Figure 8.** Temporal evolution of the correlation between HH and VV ( $\gamma_{HH-VV}$ ) for all monitored fields. (a) Wheat; (b) barley; (c) rye; (d) pasture. Averages (symbols) and standard deviations (error bars) are computed within each field. Red color denotes an incidence angle at 36°, blue at 31°, and green at 25°.



**Figure 9.** Temporal evolution of the dominant alpha angle ( $\alpha_1$ ) for all monitored fields. (a) Wheat; (b) barley; (c) rye; (d) pasture. Averages (symbols) and standard deviations (error bars) are computed within each field. Red color denotes an incidence angle at 36°, blue at 31°, and green at 25°.

**Table 3.** Correlation (Pearson's  $r$ ) between the field measurements and the co-polar channel HH, for the 3 incidence angles (i.e., 25°, 31°, and 36°). Significant correlations at 95% coincidence level are shaded.

	Height			Biomass			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Wheat)	0.76	0.57	0.27	0.71	0.47	0.25	-0.50	-0.58	-0.33	0.32	0.03	0.00	0.39	0.02	-0.28	-0.44	-0.01	0.48
L7 (Wheat)	-0.48	0.53	0.24	-0.69	-0.21	-0.31	0.27	-0.83	-0.40	-0.54	-0.77	-0.75	-0.25	-0.92	-0.77	0.52	0.24	0.18
K10 (Wheat)	-0.64	0.75	-0.19	-0.4	0.67	0.02	0.46	-0.52	0.16	-0.29	0.04	-0.22	-0.04	-0.64	-0.37	0.65	-0.29	0.53
F11 (Barley)	-0.39	0.36	-0.28	-0.53	-0.11	-0.12	-0.28	-0.56	-0.18	-0.48	-0.31	-0.06	-0.51	-0.29	-0.10	0.71	0.14	0.68
M9 (Barley)	-0.44	0.58	0.15	-0.51	0.37	0.01	0.31	-0.48	-0.03	-0.37	-0.31	-0.30	-0.32	-0.40	-0.32	0.51	0.11	0.29
N9 (Rye)	0.82	0.95	0.30	0.44	0.34	-0.18	-0.76	-0.83	-0.39	-0.21	-0.61	-0.69	-0.24	-0.52	-0.65	-0.78	-0.72	0.16
H9 (Pasture)	-0.44	0.26	0.35	-0.50	-0.19	-0.15	0.21	-0.41	-0.46	-0.42	-0.36	-0.32	-0.02	-0.53	-0.61	0.83	0.43	0.43

**Table 4.** Correlation (Pearson's  $r$ ) between field measurements and the co-polar channel VV, for the 3 incidence angles (i.e., 25°, 31°, and 36°). Significant correlations at 95% coincidence level are shaded.

	Height			Biomass			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Wheat)	-0.62	-0.45	-0.42	-0.67	-0.70	-0.61	0.24	-0.21	-0.14	-0.58	-0.80	-0.76	-0.65	-0.82	-0.87	0.50	0.62	0.66
L7 (Wheat)	-0.61	-0.25	-0.38	-0.84	-0.80	-0.87	0.31	-0.26	-0.09	-0.57	-0.72	-0.75	-0.18	-0.45	-0.40	0.60	0.50	0.52
K10 (Wheat)	-0.63	-0.30	-0.63	-0.59	-0.80	-0.72	0.30	-0.25	0.22	-0.49	-0.77	-0.61	-0.10	-0.46	-0.13	0.65	0.41	0.57
F11 (Barley)	0.44	-0.59	-0.57	0.43	-0.79	-0.36	0.16	-0.16	-0.04	0.34	-0.62	-0.17	0.37	-0.63	-0.21	-0.62	0.60	0.76
M9 (Barley)	-0.49	-0.05	-0.34	-0.55	-0.26	-0.51	0.33	-0.23	0.07	-0.38	-0.61	-0.63	-0.33	-0.64	-0.58	0.52	0.49	0.56
N9 (Rye)	-0.56	-0.11	-0.46	-0.87	-0.83	-0.87	0.37	-0.19	0.09	-0.40	-0.53	-0.21	-0.46	-0.78	-0.53	0.34	-0.22	0.23
H9 (Pasture)	-0.54	-0.03	0.11	-0.45	-0.59	-0.51	0.36	-0.47	-0.51	-0.33	-0.71	-0.62	0.14	-0.61	-0.69	0.82	0.65	0.55

**Table 5.** Correlation (Pearson's  $r$ ) between the field measurements and the cross-polar channel HV, for the 3 incidence angles (i.e., 25°, 31°, and 36°). Significant correlations at 95% coincidence level are shaded.

	Height			Biomass			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Wheat)	0.49	0.48	0.01	0.64	0.62	0.18	0.08	-0.02	0.15	0.57	0.60	0.37	0.75	0.79	0.10	-0.83	-0.70	0.33
L7 (Wheat)	0.54	0.80	0.21	0.09	0.14	0.21	-0.50	-0.93	0.12	-0.55	-0.55	-0.13	-0.77	-0.82	-0.11	-0.11	-0.20	-0.64
K10 (Wheat)	-0.77	0.22	-0.56	-0.39	0.59	-0.01	0.67	0.27	0.69	-0.12	0.62	0.10	0.17	0.32	0.18	0.58	-0.68	0.30
F11 (Barley)	0.43	0.45	0.21	0.60	0.85	0.71	0.25	0.25	0.12	0.54	0.79	0.72	0.57	0.82	0.72	-0.69	-0.61	-0.08
M9 (Barley)	-0.36	0.94	0.69	-0.41	0.86	0.65	0.29	-0.50	-0.10	-0.29	0.20	0.26	-0.25	0.10	0.20	0.47	-0.43	-0.35
N9 (Rye)	0.61	0.62	0.59	0.69	0.64	0.24	-0.47	-0.28	-0.77	0.24	0.13	-0.08	0.25	0.25	-0.35	-0.58	-0.74	-0.27
H9 (Pasture)	-0.47	0.68	0.63	-0.43	-0.09	-0.16	0.31	-0.89	-0.84	-0.33	-0.36	-0.39	0.08	-0.92	-0.92	0.80	-0.10	0.02

steeper incidence angles (25°),  $\alpha_1$  was only approximately 20°, which means that the dominant scattering mechanism was mostly surface scattering. At the end of the campaign,  $\alpha_1$  decreased, again becoming close to 0° for all incidence angles at harvest time. Once again, the dominant  $\alpha_1$  evolution follows a time pattern similar to that of LAI and biomass.

**Correlation between radar parameters and biophysical variables**

The correlation between the backscattering coefficients at the linear basis and the biophysical variables was analyzed first. HH (Table 3) is moderately correlated with the scene properties, showing a high correlation in only a few cases. The radar response of this channel is affected by both vegetation and soil parameters and, as previously discussed, it does not show a consistent temporal pattern (Figure 3). The highest correlation coefficients were obtained for rye for height,

PWC, and SM, at 25° and 31°, and for wheat (L7) for PWC, the LAI, and FVC at incidence angles of 31° and 36°.

VV is highly correlated with biomass for most crops and incidence angles, with the best values at 31° (Table 4). The LAI is also well correlated with VV, especially at 31° for most crops and at 36° for wheat. These 2 plant parameters are significantly but negatively correlated with VV because an increase in biomass or LAI translates into a stronger attenuation of the vertically polarized waves and a consequent decrease in VV (Figure 4). The most consistent results for VV are obtained at 31°, with lower correlations at 25° and 36°, so this angle seems to be a good choice at this frequency band to monitor crop development.

The correlations for HV (Table 5) are not as good as expected in regard to previous results found in the literature (Moran et al. 2012). It is only moderately correlated to vegetation height and biomass at 31° for



**Table 6.** Correlation (Pearson's  $r$ ) between field measurements and the co-polar ratio HH/VV, for the 3 incidence angles (i.e., 25°, 31°, and 36°). Significant correlations at 95% coincidence level are shaded.

	Height			Biomass			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Wheat)	0.68	0.73	0.67	0.70	0.92	0.88	-0.35	-0.11	-0.06	0.49	0.76	0.89	0.56	0.79	0.82	-0.48	-0.59	-0.44
L7 (Wheat)	0.70	0.72	0.59	0.93	0.86	0.88	-0.34	-0.30	-0.11	0.55	0.33	0.50	0.09	-0.13	0.06	-0.64	-0.46	-0.53
K10 (Wheat)	-0.45	0.60	0.64	0.08	0.94	0.89	0.60	-0.06	-0.15	0.19	0.60	0.59	0.07	0.03	-0.11	0.42	-0.45	-0.32
F11 (Barley)	-0.42	0.83	0.84	-0.46	0.60	0.63	-0.19	-0.35	-0.21	-0.39	0.27	0.28	-0.42	0.30	0.31	0.65	-0.41	-0.58
M9 (Barley)	0.55	0.96	0.84	0.61	0.92	0.93	-0.36	-0.44	-0.17	0.40	0.33	0.66	0.34	0.23	0.56	-0.53	-0.48	-0.54
N9 (Rye)	0.64	0.67	0.59	0.84	0.86	0.76	-0.47	-0.36	-0.27	0.30	0.04	-0.12	0.35	0.28	0.22	-0.44	-0.28	-0.15
H9 (Pasture)	0.56	0.53	0.44	0.44	0.82	0.87	-0.40	0.18	0.27	0.31	0.74	0.78	-0.18	0.24	0.37	-0.82	-0.50	-0.41

**Table 7.** Correlation (Pearson's  $r$ ) between field measurements and the cross-polar ratio HV/VV for the 3 incidence angles (i.e., 25°, 31°, and 36°). Significant correlations at 95% coincidence level are shaded.

	Height			Biomass			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Wheat)	0.61	0.52	0.43	0.68	0.75	0.70	-0.20	0.13	0.21	0.58	0.81	0.93	0.68	0.91	0.94	-0.55	-0.73	-0.55
L7 (Wheat)	0.76	0.83	0.39	0.89	0.86	0.84	-0.44	-0.45	0.10	0.46	0.27	0.66	0.00	-0.19	0.35	-0.65	-0.62	-0.61
K10 (Wheat)	-0.70	0.27	0.18	-0.10	0.73	0.76	0.84	0.28	0.38	0.28	0.74	0.74	0.38	0.41	0.30	0.35	-0.60	-0.35
F11 (Barley)	0.41	0.49	0.61	0.70	0.87	0.82	0.31	0.24	0.12	0.66	0.78	0.68	0.69	0.81	0.71	-0.70	-0.63	-0.65
M9 (Barley)	0.42	0.90	0.80	0.44	0.91	0.90	-0.03	-0.36	-0.13	0.30	0.45	0.67	0.22	0.37	0.59	-0.02	-0.61	-0.69
N9 (Rye)	0.60	0.46	0.67	0.81	0.85	0.91	-0.43	-0.08	-0.39	0.33	0.35	0.16	0.37	0.57	0.36	-0.47	-0.37	-0.32
H9 (Pasture)	0.66	0.85	0.80	0.49	0.60	0.60	-0.46	-0.50	-0.46	0.33	0.43	0.42	-0.25	-0.35	-0.30	-0.85	-0.90	-0.89

**Table 8.** Correlation (Pearson's  $r$ ) between field measurements and the normalized correlation (coherence) between HH and VV ( $\gamma_{HHVV}$ ) for the 3 incidence angles (i.e., 25°, 31°, and 36°). Significant correlations at 95% coincidence level are shaded.

	Height			Biomass			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Wheat)	-0.60	-0.64	-0.77	-0.76	-0.85	-0.92	0.07	0.00	0.20	-0.76	-0.81	-0.81	-0.84	-0.86	-0.76	0.60	0.65	0.45
L7 (Wheat)	0.54	-0.83	-0.49	0.55	-0.84	-0.87	-0.42	0.47	-0.01	0.30	-0.23	-0.59	0.04	0.22	-0.23	-0.49	0.53	0.61
K10 (Wheat)	0.32	-0.49	-0.54	-0.29	-0.86	-0.92	-0.61	-0.04	0.00	-0.42	-0.66	-0.57	-0.16	-0.10	0.03	-0.23	0.48	0.39
F11 (Barley)	0.31	-0.39	-0.54	-0.14	-0.90	-0.88	-0.14	-0.32	-0.21	-0.28	-0.86	-0.76	-0.26	-0.88	-0.78	-0.28	0.57	0.64
M9 (Barley)	0.43	-0.89	-0.85	0.47	-0.94	-0.93	-0.34	0.26	0.20	0.30	-0.55	-0.65	0.25	-0.47	-0.54	-0.47	0.56	0.54
N9 (Rye)	-0.52	-0.60	-0.67	-0.85	-0.88	-0.88	0.32	0.24	0.41	-0.43	-0.16	-0.22	-0.49	-0.42	-0.34	0.38	0.37	0.36
H9 (Pasture)	0.44	-0.86	-0.78	0.33	-0.66	-0.77	-0.39	0.44	0.27	0.22	-0.53	-0.60	-0.16	0.31	0.11	-0.74	0.89	0.81

most crop types. Both biophysical variables are related to an increase in the vegetation volume, and volume scattering is known to generate significant backscattering in the cross-polarized channel. The rest of the biophysical variables evidence many inconsistencies in the correlations, with opposite signs for different fields of the same crop (e.g. for FVC for wheat at 25° and 31°, or for SM at 25°), making difficult any physical interpretation.

The physical parameters related to water content (i.e. SM and PWC) show no correlation with the backscattering coefficients (excepting some isolated high values), whereas those related to scene geometry or morphology (i.e. height, biomass, and LAI) exhibit better correlation coefficients.

Regarding the incidence angle, the intermediate angle (31°) provides the best correlations, probably because it results in a trade-off between the soil

dominance at 25° and an excessive attenuation within the vegetation at 36°.

As some fluctuations of the backscattering coefficients are common to different polarization channels (probably due to specific events such as rain or other external sources), it is expected that the effect of such variations will be minimized if backscattering ratios are employed, such as HH/VV and HV/VV. These ratios exhibit high correlations with biophysical variables in many cases. Tables 6 and 7 indicate that the strongest correlations for these ratios were observed with biomass for all crops, and most notably at 31° and 36°, with very high values and positive correlations. In agreement with these results, the C-band co-polar ratio HH/VV was found to be highly correlated with biomass for winter wheat at a 40° incidence angle by Mattia et al. (2003), whereas the correlation was poor at 23°. Moreover, Moran et al. (2012) also

**Table 9.** Correlation (Pearson's  $r$ ) between field measurements and the dominant alpha angle,  $\alpha_1$ , for the 3 incidence angles (i.e., 25°, 31°, and 36°). Significant correlations at 95% coincidence level are shaded.

	Height			Biomass			PWC			LAI			FVC			SM		
	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°	25°	31°	36°
J12 (Wheat)	0.69	0.70	0.72	0.73	0.90	0.92	-0.30	-0.06	-0.12	0.56	0.81	0.85	0.63	0.82	0.78	-0.51	-0.58	-0.43
L7 (Wheat)	-0.58	0.76	0.63	-0.56	0.82	0.86	0.45	-0.35	-0.15	-0.29	0.25	0.42	-0.01	-0.19	-0.01	0.51	-0.47	-0.53
K10 (Wheat)	-0.65	0.54	0.61	-0.26	0.92	0.92	0.58	0.00	-0.10	-0.09	0.65	0.59	0.04	0.10	-0.08	0.60	-0.44	-0.31
F11 (Barley)	-0.25	0.54	0.65	0.19	0.90	0.78	0.12	0.20	0.04	0.30	0.77	0.58	0.28	0.79	0.61	0.24	-0.61	-0.64
M9 (Barley)	-0.47	0.90	0.83	-0.51	0.92	0.92	0.35	-0.22	-0.13	-0.33	0.52	0.63	-0.27	0.45	0.53	0.49	-0.53	-0.52
N9 (Rye)	0.29	0.52	0.60	0.69	0.88	0.86	0.04	-0.16	-0.28	0.25	0.15	0.12	0.49	0.46	0.36	-0.01	-0.22	-0.21
H9 (Pasture)	-0.36	0.78	0.54	-0.21	0.81	0.87	0.42	-0.20	0.12	-0.11	0.72	0.80	0.19	-0.07	0.28	0.67	-0.90	-0.72

reported a very good correlation of VV/HH (i.e. the inverse of HH/VV) with crop growth for winter barley at an incidence angle greater than 35°. Both HH/VV and HV/VV are also highly correlated with vegetation height and moderately correlated with LAI, supporting the previous insights found in the temporal evolution analysis.

The correlation of  $\gamma_{HHVV}$  with biomass is high for all crops, and moderate to high with height for all crops at incidence angles of 31° and 36° (Table 8). These correlations are negative because of the temporal pattern of  $\gamma_{HHVV}$  in the presence of crops (Figure 8), as discussed above: high when surface scattering is dominant (i.e. at early and late dates), and low when vegetation is present (i.e. in the middle of the season).

In the same fashion as for the backscattering ratios and  $\gamma_{HHVV}$ ,  $\alpha_1$  is highly correlated with biomass for all crops at incidence angles of 31° and 36° (Table 9). Indeed, the physical reason for this correlation is the same: the gradual change of the scattering mechanism that dominates the radar response of the crops during the growth cycle (see Figure 9). Consequently, it follows the typical curve for biomass, as shown in Figure 2. Lopez-Sanchez et al. (2013) used this principle and employed  $\alpha_1$  to estimate the phenological stages of several crops.

It is remarkable that, occasionally, fluctuating and even inverse correlations have been found between plots with the same crop. Those few cases took place mainly over wheat plots and for the shallower angles, and can be justified by a higher variability between wheat evolutions than for barley (Figure 2).

Because of the great number of correlations resulting from the possible combinations between parameters, field observations, and incidence angles, Table 10 summarizes the correlation results, indicating the best correlations ( $r \geq \pm 0.66$ ) and the recommended incidence angle for each biophysical variable and SAR parameter.

This correlation study allows us to identify the relationships between radar parameters and field

**Table 10.** Overview of SAR parameters and highly-correlated biophysical variables taking into account the incidence angle for all crops analyzed in this study. A check mark is used to show the best combinations.

Parameter	Height		Biomass		LAI	
	31°	36°	31°	36°	31°	36°
HH						
HV						
VV						
HH/VV	✓	✓	✓	✓		
HV/VV	✓	✓	✓	✓	✓	✓
$\gamma_{HHVV}$	✓	✓	✓	✓		
$\alpha_1$			✓	✓		

parameters, although it should be carefully considered due to the limited number of field observations. The scarcity of ground measurements is a recurrent and steady issue in radar applications. The literature contains many examples of correlation analyses with a similar (or smaller) number of ground observations against radar estimates. Maity et al. (2004) compared 3 field measurements with RADARSAT for cotton parametrization in India during low to peak crop growth stages. Lim et al. (2008) carried out a temporal study with multiple angles comparing 6 rice parameters with ground-based C-band scatterometer measurements for an entire growing season, with an objective similar to the present study. Kim et al. (2012) compared radar-derived vegetation indices of rice and soybean (~12–19 measurements) to estimate VWC. Baghdadi et al. (2016) used 18 field measurements to characterize irrigated grasslands, and used polarimetric RADARSAT-2 data at different incidence angles. Field measurements are highly time-consuming, and it is typically difficult to gather a comprehensive dataset of in situ data.

**Potential applications**

The results presented in the previous section suggest a number of potential applications of the radar parameters. First, all the rain-fed crops analyzed here respond quite similarly, but in a different manner from the natural pasture. Thus, it may be inferred that cereals

can be distinguished from natural pasture or grassland areas by exploiting the single radar parameters considered here at any incidence angle. Second, the HH/VV and HV/VV ratios,  $\alpha_1$ , and  $\gamma_{HHVV}$  capture the dynamics of the growth cycle of these crops well at both 31° and 36°. Therefore, a time series of these observations could be used as input for monitoring products and applications such as the detection of cultivation problems, and forecasting dates for key treatments (e.g. fertilization) or harvest. These applications could be set up by interleaving both 31° and 36° incidence series, which would increase the information refresh rate, thus improving its applicability—an important aspect for end users. In this context, it should be emphasized that the HV/VV ratio, which is very sensitive to plant development, is freely available on a routine basis over Europe since 2016, with a revisit time of 6 days, thanks to the constellation of Sentinel-1A and 1B. The use of dual-pol modes such as for Sentinel-1A and 1B provides better spatial coverage (i.e. a double swath) with respect to quad-pol images, at the expense of a reduced polarimetric observation space. In addition, the revisit time (i.e. the refresh rate) is a key aspect that may favor systems with fewer polarimetric channels when timeliness is relevant. In the same vein, a deep analysis of the best combination of channels in a dual-pol system should be carried out considering the application objectives.

This study obtained very significant correlations of some parameters with height and biomass, which opens the door for the development of Earth observation products based on the estimation of these parameters. Biomass is known to be related to crop yield, so a yield forecast based on a time series of C-band radar data (e.g. from Sentinel-1) is possible. In addition, data fusion with optical data (especially those provided by Sentinel-2) could be explored to take advantage of their complementarity. Radar data are sensitive to the structure and morphology of the canopy, whereas optical data are more sensitive to the biochemistry related to the plants' physiological activity. This synergy has been recently exploited for crop monitoring in a data fusion framework (De Bernardis et al. 2016).

Additionally, further research may account for a full regression model based on the best relationships found here in order to retrieve and validate a complete dataset of vegetation parameters.

### Conclusions

This study aimed to assess the feasibility of several polarimetric parameters at different incidence angles

to monitor crops through the analysis of their relationships with different plant and canopy biophysical variables. The SAR response for many of the polarimetric parameters suggested a temporal pattern similar to that of LAI and biomass, confirmed with the correlation analysis. The most significant correlations were observed for the backscattering ratios (HH/VV and HV/VV), the normalized correlation between HH and VV ( $\gamma_{HHVV}$ ), and the dominant alpha angle ( $\alpha_1$ ) with biomass, height, and the LAI at 31° and 36° incidence angles.

Regarding the impact of the incidence angle, an angle of 31° provides the best results. The radar waves travel more vertically at 25°, so the scattering at steeper incidence angles is more influenced by the soil properties, whereas the radar waves travel a longer path through the vegetation at 36°.

The results of this research may provide some insight into the selection of polarimetric parameters as a remotely sensed alternative to crop monitoring. It was shown that biomass, LAI, and height of rain-fed crops may be surveyed using different radar parameters provided by RADARSAT-2, even though additional field campaigns are needed to confirm these results over different areas and crops. Given the improved spatial resolution of recent missions, including RADARSAT-2 and Sentinel-1, and the future RADARSAT Constellation Mission (RCM), and the large availability of their data, the use of radar imagery is currently a confirmed foundation for agricultural applications at plot scale.

### Acknowledgments

We thank MacDonald, Dettwiler and Associates Ltd. (MDA, 2015) for RADARSAT-2 Data and Products—All Rights Reserved. RADARSAT is an official trademark of the Canadian Space Agency (CSA). All RADARSAT-2 images have been provided by MDA and CSA in the framework of the SOAR-EU2 Project ref. I6375.

### Funding

This study was supported by the Spanish Ministry of Economy and Competitiveness and the Spanish Ministry of Science, Innovation and Universities, [Projects ESP2015-67549-C3-3, ESP2017-89463-C3-3-R, and TEC2017-85244-C2-1-P] and the European Regional Development Fund (FEDER).

### References

- Adams, J.R., Berg, A.A., McNairn, H., and Merzouki, A. 2013a. "Sensitivity of C-band SAR polarimetric variables to unvegetated agricultural fields." *Canadian Journal of*

- Remote Sensing*, Vol. 39(No. 1): pp. 1–16. doi:10.5589/m13-003.
- Adams, J.R., Rowlandson, T.L., McKeown, S.J., Berg, A.A., McNairn, H., and Sweeney, S.J. 2013b. "Evaluating the Cloude-Pottier and Freeman-Durden scattering decompositions for distinguishing between unharvested and post-harvest agricultural fields." *Canadian Journal of Remote Sensing*, Vol. 39(No. 4): pp. 318–327. doi:10.5589/m13-040.
- Baghdadi, N.N., El Hajj, M., Zribi, M., and Fayad, I. 2016. "Coupling SAR C-band and optical data for soil moisture and leaf area index retrieval over irrigated grasslands." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 9(No. 3): pp. 1229–1243. doi:10.1109/JSTARS.2015.2464698.
- Bériaux, E., Waldner, F., Collienne, F., Bogaert, P., and Defourny, P. 2015. "Maize leaf area index retrieval from synthetic quad pol SAR time series using the water cloud model." *Remote Sensing*, Vol. 7(No. 12): pp. 16204–16225. doi:10.3390/rs71215818.
- Bouvet, A., Le Toan, T., and Lam-Dao, N. 2009. "Monitoring of the rice cropping system in the Mekong Delta using ENVISAT/ASAR dual polarization data." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 47(No. 2): pp. 517–526. doi:10.1109/TGRS.2008.2007963.
- Brocca, L., Hasenauer, S., Lacava, T., Melone, F., Moramarco, T., Wagner, W., Dorigo, W., et al. 2011. "Soil moisture estimation through ASCAT and AMSR-E sensors: An intercomparison and validation study across Europe." *Remote Sensing of Environment*, Vol. 115(No. 12): pp. 3390–3408. doi:10.1016/j.rse.2011.08.003.
- Cable, J.W., Kovacs, J.M., Jiao, X., and Shang, J. 2014. "Agricultural monitoring in Northeastern Ontario, Canada, using multi-temporal polarimetric RADARSAT-2 data." *Remote Sensing*, Vol. 6 (No. 3): pp. 2343–2371. doi:10.3390/rs6032343.
- Ceballos, A., Scipal, K., Wagner, W., and Martínez-Fernández, J. 2005. "Validation of ERS scatterometer-derived soil moisture data in the central part of the Duero Basin, Spain." *Hydrological Processes*, Vol. 19(No. 8): pp. 1549–1566. doi:10.1002/hyp.5585.
- Chen, M.F., and Fung, A.K. 1988. "A numerical study of the regions of validity of the Kirchhoff and small-perturbation rough surface scattering models." *Radio Science*, Vol. 23(No. 2): pp. 163–170. doi:10.1029/RS023i002p00163.
- Cloude, S.R., and Pottier, E. 1996. "A review of target decomposition theorems in radar polarimetry." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 34(No. 2): pp. 498–518. doi:10.1109/36.485127.
- Cloude, S.R., and Pottier, E. 1997. "An entropy based classification scheme for land applications of polarimetric SAR." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 35(No. 1): pp. 68–78. doi:10.1109/36.551935.
- Colliander, A., Jackson, T.J., Bindlish, R., Chan, S., Das, N., Kim, S.B., Cosh, M.H., et al. 2017. "Validation of SMAP surface soil moisture products with core validation sites." *Remote Sensing of Environment*, Vol. 191: pp. 215–231. doi:10.1016/j.rse.2017.01.021.
- De Bernardis, C., Vicente-Guijalba, F., Martínez-Marín, T., and López-Sánchez, J.M. 2016. "Contribution to real-time estimation of crop phenological states in a dynamical framework based on NDVI time series: Data fusion with SAR and temperature." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 9(No. 8): pp. 3512–3523. doi:10.1109/JSTARS.2016.2539498.
- Della Vecchia, A., Ferrazzoli, P., Guerriero, L., Blaes, X., Defourny, P., Dente, L., Mattia, F., Satalino, G., Strozzi, T., and Wegmüller, U. 2006. "Influence of geometrical factors on crop backscattering at C-band." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 44(No. 4): pp. 778–790. doi:10.1109/TGRS.2005.860489.
- Freeman, A., and Durden, S.L. 1998. "A three-component scattering model for polarimetric SAR data." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 36(No. 3): pp. 963–973. doi:10.1109/36.673687.
- Fung, A. K. 1994. "Microwave Scattering and Emission Models and their Applications." Norwood: Artech House.
- González-Zamora, A., Sánchez, N., and Martínez-Fernández, J. 2016. "Validation of Aquarius soil moisture products over the Northwest of Spain: A comparison with SMOS." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 9(No. 6): pp. 2763–2769. doi:10.1109/JSTARS.2016.2517401.
- Hajnsek, I., Pottier, E., and Cloude, S.R. 2003. "Inversion of surface parameters from polarimetric SAR." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 41(No. 4): pp. 727–744. doi:10.1109/TGRS.2003.810702.
- Inoue, Y., Kurosu, T., Maeno, H., Uratsuka, S., Koza, T., Dabrowska-Zielinska, K., and Qi, J. 2002. "Season-long daily measurements of multifrequency (Ka, Ku, X, C, and L) and full-polarization backscatter signatures over paddy rice field and their relationship with biological variables." *Remote Sensing of Environment*, Vol. 81(No. 2-3): pp. 194–204. doi:10.1016/S0034-4257(01)00343-1.
- Inoue, Y., and Sakaiya, E. 2013. "Relationship between X-band backscattering coefficients from high-resolution satellite SAR and biophysical variables in paddy rice." *Remote Sensing Letters*, Vol. 4(No. 3): pp. 288–295. doi:10.1080/2150704X.2012.725482.
- Inoue, Y., Sakaiya, E., and Wang, C. 2014. "Capability of C-band backscattering coefficients from high-resolution satellite SAR sensors to assess biophysical variables in paddy rice." *Remote Sensing of Environment*, Vol. 140: pp. 257–266. doi:10.1016/j.rse.2013.09.001.
- Jackson, T.J., Chen, D., Cosh, M., Li, F., Anderson, M., Walthall, C., Doriaswamy, P., and Hunt, E.R. 2004. "Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans." *Remote Sensing of Environment*, Vol. 92(No. 4): pp. 475–482. doi:10.1016/j.rse.2003.10.021.
- Jiang, Z., Huete, A.R., Chen, J., Chen, Y., Li, J., Yan, G., and Zhang, X. 2006. "Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction." *Remote Sensing of Environment*, Vol. 101(No. 3): pp. 366–378. doi:10.1016/j.rse.2006.01.003.
- Jiao, X., McNairn, H., Shang, J., Pattey, E., Liu, J., and Champagne, C. 2011. "The sensitivity of RADARSAT-2 polarimetric SAR data to corn and soybean leaf area

- index." *Canadian Journal of Remote Sensing*, Vol. 37(No. 1): pp. 69–81. doi:10.5589/m11-023.
- Kim, Y., Jackson, T., Bindlish, R., Lee, H., and Hong, S. 2012. "Radar vegetation index for estimating the vegetation water content of rice and soybean." *IEEE Geoscience and Remote Sensing Letters*, Vol. 9(No. 4): pp. 564–568. doi:10.1109/LGRS.2011.2174772.
- Lee, J.S., Ainsworth, T.L., Kelly, J.P., and Lopez-Martinez, C. 2008. "Evaluation and bias removal of multilook effect on entropy/alpha/anisotropy in polarimetric SAR decomposition." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 46(No. 10): pp. 3039–3052. doi:10.1109/TGRS.2008.922033.
- Lim, K.-S., Koo, V.C., and Ewe, H.-T. 2008. "Multi-angular scatterometer measurements for various stages of rice growth." *Progress in Electromagnetics Research*, Vol. 83: pp. 385–396. doi:10.2528/PIER08070205.
- Lopez-Sanchez, J.M., Cloude, S.R., and Ballester-Berman, J.D. 2012. "Rice phenology monitoring by means of SAR polarimetry at X-band." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 50(No. 7): pp. 2695–2709. doi:10.1109/TGRS.2011.2176740.
- Lopez-Sanchez, J.M., Vicente-Guijalba, F., Ballester-Berman, J.D., and Cloude, S.R. 2014. "Polarimetric response of rice fields at C-band: Analysis and phenology retrieval." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 52(No. 5): pp. 2977–2993. doi:10.1109/TGRS.2013.2268319.
- Lopez-Sanchez, J.M., Vicente-Guijalba, F., Ballester-Berman, J.D., and Cloude, S.R. 2015. "Influence of incidence angle on the coherent copolar polarimetric response of rice at X-band." *IEEE Geoscience and Remote Sensing Letters*, Vol. 12(No. 2): pp. 249–253. doi:10.1109/LGRS.2014.2334371.
- Lopez-Sanchez, J.M., Vicente-Guijalba, F., Ballester-Berman, J.D., and Cloude, S.R. 2013. "Estimating phenology of agricultural crops from space." Paper presented at ESA Living Planet Symposium, September 2013, Edinburgh, UK: ESA.
- Maity, S., Patnaik, C., Chakraborty, M., and Panigrahy, S. 2004. "Analysis of temporal backscattering of cotton crops using a semiempirical model." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 42(No. 3): pp. 577–587. doi:10.1109/TGRS.2003.821888.
- Mattia, F., Le Toan, T., Picard, G., Posa, F.I., D'Alessio, A., Notarnicola, C., Gatti, A.M., Rinaldi, M., Satalino, G., and Pasquariello, G. 2003. "Multitemporal C-band radar measurements on wheat fields." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 41(No. 7): pp. 1551–1560. doi:10.1109/TGRS.2003.813531.
- McNairn, H., and Brisco, B. 2004. "The application of C-band polarimetric SAR for agriculture: A review." *Canadian Journal of Remote Sensing*, Vol. 30(No. 3): pp. 525–542. doi:10.5589/m03-069.
- Moran, M.S., Alonso, L., Moreno, J.F., Cendrero Mateo, M.P., de la Cruz, D.F., and Montoro, A. 2012. "A RADARSAT-2 quad-polarized time series for monitoring crop and soil conditions in Barrax, Spain." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 50(No. 4): pp. 1057–1070. doi:10.1109/TGRS.2011.2166080.
- Sánchez, N., Martínez-Fernández, J., Calera, A., Torres, E., and Pérez-Gutiérrez, C. 2010. "Combining remote sensing and *in situ* soil moisture data for the application and validation of a distributed water balance model (HIDROMORE)." *Agricultural Water Management*, Vol. 98(No. 1): pp. 69–78. doi:10.1016/j.agwat.2010.07.014.
- Sánchez, N., Martínez-Fernández, J., González-Piqueras, J., González-Dugo, M.P., Baroncini-Turricchia, G., Torres, E., Calera, A., and Pérez-Gutiérrez, C. 2012a. "Water balance at plot scale for soil moisture estimation using vegetation parameters." *Agricultural and Forest Meteorology*, Vol. 166–167: pp. 1–9. doi:10.1016/j.agrformet.2012.07.005.
- Sánchez, N., Martínez-Fernández, J., Scaini, A., and Pérez-Gutiérrez, C. 2012b. "Validation of the SMOS L2 soil moisture data in the REMEDHUS network (Spain)." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 50(No. 5): pp. 1602–1611. doi:10.1109/TGRS.2012.2186971.
- Satalino, G., Mattia, F., Le Toan, T., and Rinaldi, M. 2009. "Wheat crop mapping by using ASAR AP data." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 47(No. 2): pp. 527–530. doi:10.1109/TGRS.2008.2008026.
- Skriver, H., Svendsen, M.T., and Thomsen, A.G. 1999. "Multitemporal C- and L-band polarimetric signatures of crops." *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 37(No. 5): pp. 2413–2429. doi:10.1109/36.789639.
- Smith, A.M., and Buckley, J.R. 2011. "Investigating RADARSAT-2 as a tool for monitoring grassland in western Canada." *Canadian Journal of Remote Sensing*, Vol. 37(No. 1): pp. 93–102. doi:10.5589/m11-027.
- Steele-Dunne, S.C., McNairn, H., Monsivais-Huertero, A., Judge, J., Liu, P.W., and Papatthanassiou, K. 2017. "Radar remote sensing of agricultural canopies: A review." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 10(No. 5): pp. 2249–2273. doi:10.1109/JSTARS.2016.2639043.
- Thompson, A.A. 2015. "Overview of the RADARSAT constellation mission." *Canadian Journal of Remote Sensing*, Vol. 41(No. 5): pp. 401–407. doi:10.1080/07038992.2015.1104633.
- Ulaby, F.T., Allen, C.T., Eger, G., and Kanemasu, E. 1984. "Relating the microwave backscattering coefficient to leaf area index." *Remote Sensing of Environment*, Vol. 14(No. 1-3): pp. 113–133. doi:10.1016/0034-4257(84)90010-5.
- Wiseman, G., McNairn, H., Homayouni, S., and Shang, J. 2014. "RADARSAT-2 polarimetric SAR response to crop biomass for agricultural production monitoring." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 7(No. 11): pp. 4461–4471. doi:10.1109/JSTARS.2014.2322311.



# Anexo B: Multi-temporal Dual- and Quad-Polarimetric Synthetic Aperture Radar Data for Crop Type Mapping



Article

## Multi-Temporal Dual- and Quad-Polarimetric Synthetic Aperture Radar Data for Crop-Type Mapping

Rubén Valcarce-Diñeiro <sup>1,\*</sup>, Benjamín Arias-Pérez <sup>1</sup>, Juan M. Lopez-Sanchez <sup>2</sup> and Nilda Sánchez <sup>1,3</sup>

<sup>1</sup> Department of Cartographic and Land Engineering, University of Salamanca, Hornos Caleros 50, 05003 Avila, Spain

<sup>2</sup> IUII, University of Alicante, P.O. Box 99, E-03080 Alicante, Spain

<sup>3</sup> CIALE, University of Salamanca, Duero 12, 37185 Villamayor, Salamanca, Spain

\* Correspondence: ruben.v.d@usal.es

Received: 14 May 2019; Accepted: 24 June 2019; Published: 27 June 2019



**Abstract:** Land-cover monitoring is one of the core applications of remote sensing. Monitoring and mapping changes in the distribution of agricultural land covers provide a reliable source of information that helps environmental sustainability and supports agricultural policies. Synthetic Aperture Radar (SAR) can contribute considerably to this monitoring effort. The first objective of this research is to extend the use of time series of polarimetric data for land-cover classification using a decision tree classification algorithm. With this aim, RADARSAT-2 (quad-pol) and Sentinel-1 (dual-pol) data were acquired over an area of 600 km<sup>2</sup> in central Spain. Ten polarimetric observables were derived from both datasets and seven scenarios were created with different sets of observables to evaluate a multitemporal parcel-based approach for classifying eleven land-cover types, most of which were agricultural crops. The study demonstrates that good overall accuracies, greater than 83%, were achieved for all of the different proposed scenarios and the scenario with all RADARSAT-2 polarimetric observables was the best option (89.1%). Very high accuracies were also obtained when dual-pol data from RADARSAT-2 or Sentinel-1 were used to classify the data, with overall accuracies of 87.1% and 86%, respectively. In terms of individual crop accuracy, rapeseed achieved at least 95% of a producer's accuracy for all scenarios and that was followed by the spring cereals (wheat and barley), which achieved high producer's accuracies (79.9%–95.3%) and user's accuracies (85.5% and 93.7%).

**Keywords:** agriculture; classification; C5.0 algorithm; multitemporal; polarimetric SAR; RADARSAT-2; Sentinel-1

### 1. Introduction

Land-cover classification on different scales provides accurate and cost-effective information whilst representing an important asset for various applications, from environment to economy. Knowing the crop present on each agricultural field on national and regional scales is valuable information for crop yield forecasting [1] and crop area estimation [2]. On a global scale, the knowledge of cropland uses and covers is key for estimating global food production or drought risk analysis and can even have an impact on studies on climate events and water [3].

Remote sensing is an effective and reliable data source for classifying different land covers. Optical remote sensing images have demonstrated that vegetation types can be clearly distinguished by exploiting their spectral signature and the phenological stage at the time of the image acquisition.

However, due to the presence of clouds, optical remote sensing images can miss crucial periods in the growing season, thus they may not be accurate enough for crop classification in some situations [4].

However, active microwave sensors can provide data independently from daylight, cloud cover and weather conditions, making Synthetic Aperture Radar (SAR) images relevant to agricultural applications, such as crop classification and monitoring activities, that are time-critical. In addition, early studies reported that SAR images could be integrated with optical satellite images to achieve very high crop classification accuracies, for example, using C-band images with at least one optical image [5–9].

Since the launch of the ERS-1 (European Remote Sensing Satellite) by the European Space Agency (ESA) in 1991, several SAR sensors have been developed with different frequencies and polarizations. Radar sensitivity depends on the frequency band and on the polarization of the waves. Regarding the frequency, the lower the frequency, the farther the waves penetrate; therefore, lower frequencies are more sensitive to the ground conditions, whereas high frequencies have a shallower penetration capacity and are more sensitive to the vegetation canopy. C-band-based sensors (~5.4 GHz) are on board satellites such as RADARSAT-1 and -2, RISAT-1 (Radar Imaging Satellite), ENVISAT/ASAR (Environmental Satellite/Advanced Synthetic Aperture Radar) and more recently Sentinel-1 [10] as part of Copernicus, the European Commission's Earth Observation Programme [11]. Other sensors operate at L-band (~1.3 GHz), such as in JERS-1 (Japanese Earth Resource Satellite) and ALOS/PALSAR-1 and -2 (Advanced Land Observing Satellite); whereas X-band sensors (~10 GHz) are on board TerraSAR-X, TanDEM-X and COSMO-SkyMed. In addition to the frequency, radar sensitivity depends also on the polarimetric configuration. Polarimetry is sensitive to the geometry or morphology of the plants, so different polarimetric channels present different responses as a function of the geometrical properties of the scene. Thus, some of the satellites operate in dual-pol mode and a few in quad-pol configurations.

In the field of crop discrimination and land-cover classification, a multifrequency multipolarization data set would be a useful option. Compared to single frequency data, researchers reported higher classification accuracies with C-, L- and P-band data [12–14]. The advantage of multifrequency data sets for separating vegetation types has also been demonstrated using data acquired from multiple satellite platforms, especially ERS (C-band) and JERS (L-band) [15,16]. As mentioned above, lower frequencies (i.e., L-band) penetrate larger biomass crops and the scattering within the canopy, where structure is quite different, helps in separating them [17]. For smaller biomass canopies, lower frequencies can penetrate too far into the canopy and become mostly dependent on soil properties such as the soil moisture content [18]. In this case, discrimination is achieved using higher frequency microwaves where most interaction is limited to the canopy. In addition, a distinct variation is seen for the agricultural scene properties due to the development of crops through the growing season [19]. Therefore, the discrimination capabilities may vary through the year, and, consequently, land-cover mapping can be significantly improved by performing a multitemporal classification [9,20–22]. Multitemporal image classification not only improves the overall accuracy of classifier but also provides more reliable crop discrimination in comparison to single-date [23–27].

Regardless of the sensor or frequency used, a key to successful crop classification lies in understanding which growth stages are best for crop discrimination. Like optical sensors, the energy recorded by SAR sensors could be similar for different crops at a given point in their growing cycle. However, the use of multitemporal datasets allows us to distinguish more crops from each other due to their different phenological cycles [23,28,29].

With the increasing number of spaceborne SAR systems, different SAR techniques, such as polarimetry (PolSAR), interferometry (InSAR) and differential interferometry (DInSAR), have also increased their abilities to improve parameter retrieval (e.g., biophysical variables), derive surface topography (e.g., digital elevation models (DEMs)) and measure the Earth's surface displacement, respectively. SAR polarimetry has been widely used as a technique for obtaining qualitative and quantitative physical information over land. Regarding land cover classification, instead of approaching the classification problem with simply one single-polarization single-date single-frequency input image,



the enlargement of the observation space by adding diversity is highly beneficial, as it is described in many examples in the literature and briefly reviewed here.

Regarding the use of individual polarization, many studies have confirmed that the cross-polar channel (HV or VH, which are virtually identical due to reciprocity) is the most important single polarization to identify the majority of crops [8,17,30–32]. This polarization is responsive to multiple scattering from the vegetation volume and since vegetation structures vary greatly among vegetation canopies, the cross-polarized backscatter provides the best discrimination. Nevertheless, classification accuracy is increased substantially with the inclusion of additional polarimetric channels in form of backscattering coefficients or other alternative ways (e.g., other derived observables or different matrix forms of the radar data). Regarding the use of backscattering coefficients of more than one polarimetric channel, a significant improvement in accuracy is observed when adding a second channel [31], whereas a third polarization results in extra improvements in classification accuracy only for specific crops [8].

The exploitation of polarimetric SAR data for crop classification is usually carried out by employing the covariance or coherency matrices but additional different approaches exist [22]: 1) statistical methods based on the Wishart distribution of the data; 2) transformation of covariance matrix entries into backscatter-like coefficients; 3) methods based on scattering mechanisms; and 4) knowledge-based methods. It is possible to apply relatively robust methods and easily adjust to different growing conditions [21], including both the results of the scattering model and common knowledge about targets. However, these methods have the disadvantage of only being able to determine a relatively small number of classes. The contribution of polarimetry was also assessed in Reference [33] by testing the performance when input information is removed progressively. The capability of polarimetric SAR data in crop classification has also been demonstrated by applying machine learning algorithms such as Random Forest (RF) [34–36], Decision Tree (DT) [37,38], Neural Networks (NNs) [39] and Support Vector Machines (SVMs) [40,41].

The present research is aimed at extending the use of a time series of polarimetric observables for land-cover classification, mainly focussed over agricultural fields. This possibility was previously identified [42] when several crop parameters were tested against radar measurements. The difference found in the correlations for different crop types suggested that specific crops, mainly cereal types, could be classified using SAR observables. Here, the set of land-cover types is enlarged with other vegetation types, including vineyard and forest. With this aim, we exploited a total of 20 RADARSAT-2 images acquired at three different incidence angles, as well as 14 Sentinel-1A images that were acquired during the growing season of 2015 over an agricultural area of 600 km<sup>2</sup> in central Spain. Different SAR observables were derived from each dataset and a parcel-based classification was performed using a decision tree classifier. The main objectives of this study were: 1) the evaluation of different polarimetric observables for land cover classification in a multitemporal approach, 2) the assessment and comparison of dual- and quad-polarimetric SAR data from different sensors for classification and 3) the analysis of the influence of the incidence angle for classification.

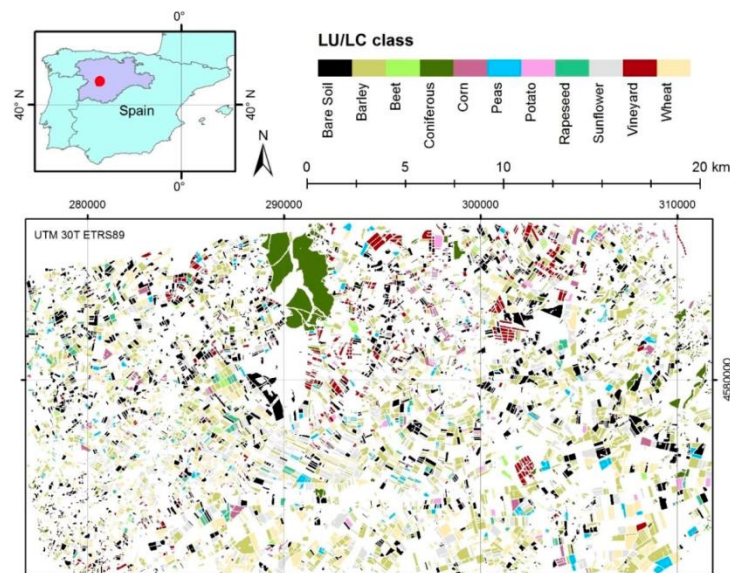
The paper has been organized as follows. Section 2 provides a description of the study area, ground truth and satellite data used, as well as the classification algorithm applied. The results and discussion are shown in Section 3. Section 4 describes the main conclusions of this work.

## 2. Materials and Methods

### 2.1. Study Area and Ground Truth

The study area is located in central Spain and covers an area of approximately 35 km x 18 km in the Castilla y Leon region (Figure 1). The topography of the study area is characterized by flat areas with slopes of up to 12%. The climate is continental semiarid Mediterranean characterized by dry and warm summers and cool to mild and wet winters. The limited amount of rainfall (336 mm average

over the last 10 years) together with the shallow soils make this area prone to rainfed crops, mainly cereals and industrial crops (sunflower and rapeseed).



**Figure 1.** Study area and selected plots, indicating their land use/land cover (LU/LC) category from the map.

Both to train the classification and to assess the accuracy of the resulting classification maps, a land-use/land-cover (LU/LC) map of the whole Castilla y Leon region from 2015 was used as the ground truth of the LU/LC for each plot. Since 2011, the Agriculture Technological Institute of Castilla y Leon (ITACyL) map service (<http://mcsncyl.itacyl.es/en/descarga>) has updated the LU/LC maps annually. These maps are based on optical image classification and represent the changes in annual arable crops as well as permanent crops and natural vegetation areas. Their spatial resolution is 20 m. The overall classification accuracy of these maps is 82% on average ( $\kappa$  coefficient around 0.78), which is generally much higher for crop categories than for natural land [43].

Based on the LU/LC map for 2015 and field surveys, the selected crops to be classified were: wheat (*Triticum aestivum* L.), sunflower (*Helianthus annuus* L.), barley (*Hordeum vulgare* L.), peas (*Pisum sativum* L.), rapeseed (*Brassica napus* L.), corn (*Zea mays* L.), beet (*Beta vulgaris* L.), potatoes (*Solanum tuberosum* L.) and vineyards (*Vitis vinifera*), as well as two other covers: bare soil and coniferous. The growing season of these crops can be clustered into two groups: long cycle, from fallow to the end of the spring (wheat, barley, peas and rapeseed) and short cycle, from spring to the beginning of fallow (sunflower, corn, beet and potatoes). Vineyard and coniferous are permanent covers.

Table 1 shows the number of plots (total 7580) and their area on average; their geographical distribution is shown in Figure 1. For classification purposes, 60% of the plots were selected randomly as the training dataset and 40% as the validation dataset. Prior to classification and to avoid selecting training pixels from the field boundaries, the plots of the training dataset were buffered inward by 20 m, following the approach of Sonobe et al. [40].

**Table 1.** Overview of ground truth data.

Crop Type	Number of Plots	Total Area (ha)	Average Area of Plots (ha)
Wheat	967	3994.86	4.13
Barley	1914	7422.48	3.88
Sunflower	897	3717.53	4.14
Rapeseed	165	614.92	3.73
Peas	206	849.48	4.12
Corn	142	632.80	4.46
Beet	90	310.65	3.45
Potatoes	57	271.24	4.76
Vineyard	788	1763.29	2.24
Coniferous	401	1843.09	4.60
Bare soil	1953	6170.19	3.16

2.2. RADARSAT-2 and Sentinel-1A Data

RADARSAT-2 and Sentinel-1 data were used for crop classification over the study area, using data acquired between February and July 2015. RADARSAT-2, launched by the Canadian Space Agency (CSA) and MacDonald, Dettwiler and Associates Ltd. (MDA) in December 2007, has a C-band (5.405 GHz) SAR sensor and multiple beam modes, with an orbit repeat cycle of 24 days. Sentinel-1A is the first of the two Sentinel-1 satellites. It was launched in April 2014 by ESA. It operates at C-band (5.405 GHz) with an orbit repeat cycle of 12 days and it has four different operational modes—Interferometric Wide Swath (IW), Wave (WV), Stripmap (SM) and Extra Wide Swath (EW). All modes are available in single (HH or VV) or dual polarization (HH and HV or VV and VH), except for WV, which is available just in single polarization [10].

For the purpose of this study, three sets of Fine Quad-Pol RADARSAT-2 Single Look Complex (SLC) images at different incidence angles were acquired. The Fine Quad-Pol mode provides a high spatial resolution and the capacity to extract polarimetric observables. From Sentinel-1A, we obtained high resolution Level-1 IW Ground Range Detected (GRD) dual-polarization (VV and VH) images. According to the product specifications, Level-1 GRD products have already been detected, multi-looked and projected to the ground range using an Earth ellipsoid model. Some basic information about RADARSAT-2 and Sentinel-1A images, as well as a list of the available acquisition data, are shown in Table 2; Table 3, respectively.

**Table 2.** Characteristics of RADARSAT-2 and Sentinel-1A.

RADARSAT-2					
Beam mode	Avg. Incidence angle (°)	Orbits	Time of acquisition (UTC)	Slant-range pixel spacing (m)	Azimuth pixel spacing (m)
FQ16W	36.2	Ascending	18:16	4.73	5.49
FQ11W	31.1		18:12		4.61
FQ6W	25.4		18:08		4.70
Sentinel-1A					
Beam mode	Incidence angle range (°)	Orbit	Resolution (m) (range × azimuth)	Pixel spacing (m) (range × azimuth)	Number of looks
IW	29.1–46	Descending	20 × 22	10 × 10	5 × 1

**Table 3.** List of RADARSAT-2 and Sentinel-1A IW ground range detected (GRD) images.

RADARSAT-2			Sentinel-1A		
Acquisition Date	Day of Year (DoY)	Beam Mode	Acquisition Date	Day of Year (DoY)	Beam Mode
16 February 2015	47	FQ16W	13 February 2015	44	IW
23 February 2015	54	FQ11W	25 February 2015	56	IW
12 March 2015	71	FQ16W	09 March 2015	68	IW
19 March 2015	78	FQ11W	21 March 2015	80	IW
26 March 2015	85	FQ6W	02 April 2015	92	IW
05 April 2015	95	FQ16W	26 April 2015	116	IW
12 April 2015	102	FQ11W	08 May 2015	128	IW
19 April 2015	109	FQ6W	20 May 2015	140	IW
29 April 2015	119	FQ16W	01 June 2015	152	IW
06 May 2015	126	FQ11W	13 June 2015	164	IW
13 May 2015	133	FQ6W	25 June 2015	176	IW
23 May 2015	143	FQ16W	07 July 2015	188	IW
30 May 2015	150	FQ11W	19 July 2015	200	IW
06 June 2015	157	FQ6W	31 July 2015	212	IW
16 June 2015	167	FQ16W			
23 June 2015	174	FQ11W			
30 June 2015	181	FQ6W			
10 July 2015	191	FQ16W			
17 July 2015	198	FQ11W			
24 July 2015	205	FQ6W			

2.3. SAR Data Processing

Some steps were applied to pre-process RADARSAT-2 and Sentinel-1A images. Both datasets were pre-processed using free-access Sentinel-1 Toolbox of the SNAP (Sentinel Application Platform) software provided by ESA.

The steps applied to RADARSAT-2 images were as follows: 1) radiometric calibration to sigma naught backscatter values; 2) polarimetric coherency matrix generation [44]; 3) application of a spatial average speckle filter to the coherency matrix (a 9x9 boxcar filter was selected); 4) terrain correction and geocoding using the Range Doppler orthorectification method available in SNAP and the digital elevation model from the Shuttle Radar Topography Mission; and 5) polarimetric observables computation using the free-access PolSARpro software provided by ESA. In total, 10 polarimetric observables (Table 4) were derived from the input polarimetric RADARSAT-2 SAR data. The symbols used hereafter to denote these observables are shown in Table 4.

**Table 4.** List of polarimetric observables derived from RADARSAT-2.

Polarimetric Observable	Symbol
Backscattering coefficient at HH, HV and VV channels	$\sigma_{HH}^0, \sigma_{HV}^0, \sigma_{VV}^0$ or simply HH, HV and VV
Ratio of backscattering coefficients at HH, HV and VV channels	HH/VV, HV/VV
Normalized correlation (coherence) between the copolar channels (HH and VV)	$\gamma_{HHVV}$
Polarization phase difference between the copolar channels (HH and VV)	PPD
Entropy and dominant alpha angle (from the Eigen decomposition of the coherency matrix)	H, $\alpha_1$
Normalized correlation (coherence) between the 1 <sup>st</sup> two channels in the Pauli basis (HH+VV and HH-VV)	$\gamma_{P1P2}$

Pre-processing Sentinel-1A images consisted of: 1) precise orbit ephemerides files were used for the geolocation accuracy [45]; 2) data calibration to obtain the sigma naught ( $\sigma^0$ ) backscatter coefficient; 3) terrain correction and geocoding using the Range Doppler orthorectification method available in SNAP and the digital elevation model from the Shuttle Radar Topography Mission; 4) a temporal stack using the first image as master; 5) application of a multitemporal speckle filter to reduce the speckle effect without degrading the spatial resolution of GRD data at 10 m; and 6) transformation of the terrain-corrected backscatter coefficients of VV and VH to dB scale and derivation of the ratio between both channels (subtraction in dB).

#### 2.4. Classification Algorithm

The See5 or C5.0 decision tree (DT) classification algorithm was used for this study. The reason for using this software and DT is that DTs have proven to be consistent and reliable with SAR data used in crop classification [8,17].

C5.0 is based on decision trees and was developed from the well-known and widely used C4.5 algorithm [46]. DTs are non-parametric methods, which can be used for both classification and regression. DTs predict class membership by dividing data sets into progressively homogeneous and mutually exclusive subsets via a branched system of data splits. A DT is composed of internal nodes (decision or rules applied), branches (connections linking two nodes) and terminal nodes (leaves), which represent the class labels. Given an input (i.e., training samples) at each internal node, they split the data set into subsets until the leaf node of the decision tree algorithm is reached. The attributes used to split the dataset are determined using a method known as the information gain ratio [46], where the attributes that exhibit the highest normalized information gain are selected.

The use of C5.0 for classification involves a few steps. First, the training dataset is prepared. Two files are essential for all C5.0 applications: a “name” file describing the attributes and the classes and a “data” file, providing information on the training case. Second, the tree classifier is constructed. Finally, the results of the classification are evaluated. To prevent overfitting, the DT was run using a 25% global pruning of the model [37,47,48]. Boosting, which was proposed by Freund and Schapire [49], is another feature in C5.0. Boosting helps to improve the classification accuracy generating several classifiers instead of a single classifier. In this case, the software was run using boosting over 5 out of 10 trials, following the procedure used in Champagne et al. [47] and McNairn et al. [37].

#### 2.5. Classification Scenarios

Firstly, seven different sets of observables used as inputs for classification, hereafter named classification scenarios (Table 5), were considered to evaluate the feasibility of polarimetric RADARSAT-2 and Sentinel-1 observables for crop classification. Regarding RADARSAT-2, six scenarios (A to F) were tested, owing to the fully polarimetric configuration and the available range of incidence angles. Since Sentinel-1 is dual-pol, only one scenario was explored (G) for this satellite. Scenario E was created after previous research [42], where it was found that the differences in the correlation between SAR observables and biophysical parameters among crop types suggested the possibility of classifying crops with these SAR observables. Scenario F was generated to compare the dual-pol data from RADARSAT-2 against Sentinel-1. With this end, only the images from RADARSAT-2 closest to the Sentinel-1 dates were selected for the analysis.

In addition, after the evaluation of the observables and crops importance in the classification results shown in Section 3.2, three new scenarios were created (H to J), which are explained in detail in that section.

**Table 5.** Description of the seven different scenarios explored with RADARSAT-2 and Sentinel-1 images.

Scenario	Description of Inputs	
	Polarimetric Observables	Images
A	HH, HV, VV, HH/VV, HV/VV, $\gamma_{HHVV}$ , PPD, H, $\alpha_1$ , $\gamma_{PIP2}$	RADARSAT-2 at 36°
B	HH, HV, VV, HH/VV, HV/VV, $\gamma_{HHVV}$ , PPD, H, $\alpha_1$ , $\gamma_{PIP2}$	RADARSAT-2 at 31°
C	HH, HV, VV, HH/VV, HV/VV, $\gamma_{HHVV}$ , PPD, H, $\alpha_1$ , $\gamma_{PIP2}$	RADARSAT-2 at 25°
D	HH, HV, VV, HH/VV, HV/VV, $\gamma_{HHVV}$ , PPD, H, $\alpha_1$ , $\gamma_{PIP2}$	All RADARSAT-2
E	HH/VV, HV/VV, $\gamma_{HHVV}$ , $\alpha_1$	RADARSAT-2 at 36° and 31°
F	HV, VV, HV/VV	RADARSAT-2 closest to Sentinel-1
G	VH, VV, VH/VV	Sentinel-1

2.6. Accuracy Assessment

The accuracy assessment was carried out at plot level using the ITACyL LU/LC map as reference. One of the most common ways to assess the accuracy of a classification of remotely sensed data is through the confusion matrix. This matrix is derived from a comparison of the reference map (columns) to the classified map (rows). Several statistical techniques such as the overall accuracy (OA), producer’s accuracy (PA), user’s accuracy (UA) and *kappa* coefficient can be derived from the confusion matrix [50]. The overall accuracy is found by relating the correctly classified fields from the main diagonal to the total number of fields in the confusion matrix. PA is calculated for a specific class by dividing the total number of correct fields in that class by the total number of fields derived by the reference data, that is, the probability that a reference class is correctly classified. However, if the correctly classified field in a class is divided by the total number of fields that were classified in that class, this measure is called user’s accuracy (UA) [51] and it is a measure of the reliability of the map. Finally, the *kappa* coefficient [52] is calculated as follows:

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} x_{+i})} \tag{1}$$

where *r* is the number of rows in the matrix,  $x_{ii}$  is the number of observations in row *i* and column *i*,  $x_{i+}$  and  $x_{+i}$  are the marginal total of row *i* and column *i* and *N* is the total number of observations.

3. Results and Discussion

3.1. Land-Cover Classification and Accuracy Assessment

A new land-cover map resulted from each scenario of classification. Figure 2 shows a detailed area of such maps from scenarios A and D as a given example. As it can be observed, the differences between them and with the reference map are minimal. Then, for each map, a classification accuracy assessment was carried out. The resulting overall classification accuracy and *kappa* coefficient are provided in Table 6. The overall accuracy for all scenarios ranged from 83% to 89.1%, with *kappa* coefficients ranging from 0.79 to 0.88. The highest accuracy was achieved using all polarimetric observables and all scenes of RADARSAT-2 (scenario D). When Sentinel-1 dual-pol SAR data were used as input for the classification, the second-best accuracy (87.1%) was obtained, whereas using dual-pol RADARSAT-2 data (scenario F) provided a similar overall accuracy (86%). The accuracy of the dual-pol RADARSAT-2 data in the general computation of this study showed higher accuracy than previous studies in the literature [35,39]. From RADARSAT-2 scenarios, the accuracies of 89.1% and 86.6% for scenarios D and A, respectively, were quite similar; however, D required many more SAR images and parameters than A to achieve this small 2.5% improvement of accuracy. Taking that observation and considering the efficiency and costs of the SAR data, scenario A would be concluded to be more suitable for classification than scenario D.

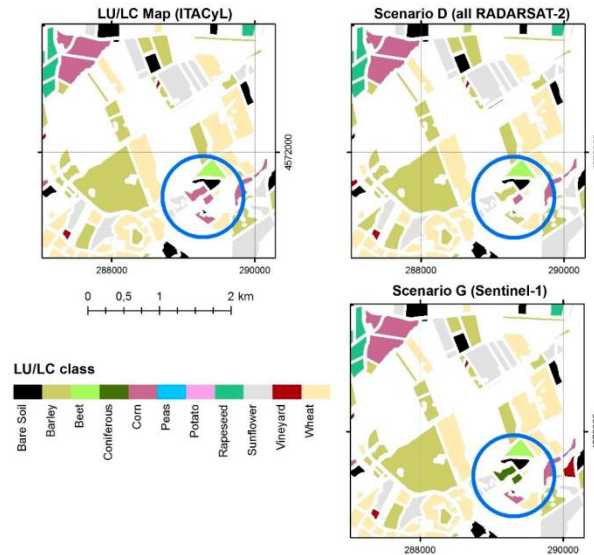


Figure 2. Three subsets of the reference map (top, left) and the resulting maps after the classification of scenarios A and D (right). Some small differences are detected in the encircled area.

Table 6. Overall accuracy and kappa coefficient.

Scenario	Overall Accuracy (%)	kappa
A	86.6	0.84
B	84.5	0.81
C	83	0.79
D	89.1	0.88
E	85.1	0.82
F	86	0.83
G	87.1	0.84

Since the launch in April 2014 of Sentinel-1 by ESA, researchers have claimed the feasibility of dual-pol Sentinel-1 data as standalone input [53,54] or blended with optical data [55–57] for LU/LC classification. Bargiel [23] demonstrated a new crop classification approach that identified phenological sequence patterns of the crop types from a stack of Sentinel-1 data. He suggested the use of multitemporal SAR observables as a crucial factor for the improvement of crop classification.

The influence of the incidence angle for crop classification has also been explored. When the polarimetric observables derived from images at 36°, 31° and 25° were used by the classifier, the overall accuracies ranged from 83% to 86.6% and 0.79 to 0.84 for kappa coefficients (Table 6). The variation of the incidence angle seems not to influence the classification significantly in terms of overall accuracy, as it was observed that the highest accuracy of 86.6% (scenario A) was only slightly better (~3.5%) than the lowest accuracy (scenario C). In principle, shallower incidence angles are preferred for identification of crops [58] due to the importance of these angles to minimize backscatter contributions from the soil. However, there is no conclusive evidence in the literature about which angle or narrow range of angles are the most adequate for classification purposes. Therefore, the influence of incidence angle seems to be very low, opening the way to combine all available incidence angles (as in scenario D).

Regarding the training/validating sampling, as it was previously mentioned, a 60-40% criterion was used, that is, a random sampling containing 60% of the samples from the data were selected as training dataset and the remaining 40% as validating dataset. To test the dependence of the accuracy on the training/validating sample, a new classification of all scenarios was run using a new random sampling (preserving the 60-40% criterion). Table 7 shows the new results, where it is clear that the overall accuracy is quite similar to the results shown in Table 6. The highest differences in overall accuracy are shown for scenarios A (1.2%), B (0.9%) and C (0.8%), whereas for scenario D there was not any difference. Likewise, the differences for the *kappa* coefficient were negligible. Therefore, it can be concluded that, owing to the high number of samples, the accuracy does not vary depending on the sampling selection.

**Table 7.** Random sampling: overall accuracy and *kappa* coefficient.

Scenario	Overall Accuracy (%)	<i>kappa</i>
A	85.4	0.82
B	83.6	0.80
C	83.2	0.79
D	89.1	0.87
E	84.3	0.81
F	85.7	0.83
G	87.3	0.85

An important indicator of a successful classification is a high overall accuracy; however, getting an acceptable discrimination at the individual crop level is as important as a high overall accuracy, especially for some final applications. With this aim, the producer’s and user’s accuracies for individual covers are listed in Table 8.

**Table 8.** Producer’s accuracies (PAs) and user’s accuracies (UAs) of individual cover types for RADARSAT-2 and Sentinel-1 data.

	A		B		C		D		E		F		G	
	PA	UA	PA	UA	PA	UA	PA	UA	PA	UA	PA	UA	PA	UA
Barley	95.1	89.2	92.2	85.5	92.5	92	95.3	92.6	95.1	89.5	92.1	88.4	93.9	89.7
Rapeseed	95.4	100	97.4	94.9	98.5	95.6	98.3	100	98.5	94.2	98.5	95.5	98.2	94.8
Coniferous	90.3	87.8	89.5	91.9	83.1	82.5	89.7	94.9	91	88.8	91.5	89.9	85.7	86.8
Sunflower	81.4	85.2	84.7	81.4	74.2	78.3	85.5	88.9	81.6	74.4	89.1	81.7	90	91
Peas	82.6	92.2	87.9	90.1	76.7	82.1	95.9	92.2	86.8	88	85.7	92.3	88.7	90
Corn	72.6	83.3	65	86.7	54	71.1	72.5	74	78.2	76.8	67.2	86.7	78.4	81.6
Vineyard	73.5	80	65.4	70.1	61.3	63.9	72.7	81.2	69.9	74.4	69	76.9	67.8	79.9
Wheat	81.9	91.1	79.9	88.1	87.2	88.3	88.1	93.7	80.6	90.9	81.2	87.3	88.3	93.1
Bare soil	88.6	83.6	87	85.6	86.4	82.5	92.9	86.1	84.4	86.2	88.5	86.9	88.3	82.8
Beet	93.2	91.1	80	82.3	82.4	62.2	81.3	79.6	83.7	87.8	72.5	87.9	82.9	78.4
Potatoes	75	83.3	60	75	57.1	66.7	56	87.5	76.2	76.2	75	62.1	45.8	78.6

Results showed that rapeseed achieved the best PA results (>95%) in all scenarios, whereas barley achieved the second highest PA’s, ranging from 92.1% to 95.3%. The user’s accuracy (UA) of both crops was above 85% for all scenarios tested and achieved 100% for rapeseed in scenarios A and D. The results reported in this study for rapeseed agree with those found by Larrañaga and Álvarez-Mozos [35]. Cereals (i.e., wheat and barley) normally show a similar behaviour during the growing season due to their very similar plant structure and phenology, which causes difficulty in separating them based on their backscatter characteristics. However, the results showed that polarimetric SAR data at C-band were capable of classifying wheat and barley with high PAs ranging from 79.9% to 95.3%. Among these crops, barley achieved better results than wheat, with high PAs (95.1%, 95.1% and 95.3%) for scenarios A, E and D, respectively. In agreement with the result obtained in scenario D for barley, Larrañaga and Álvarez-Mozos [35] also reported a high PA for barley when different polarimetric observables



were added to the H-V linear quad-pol data. The highest accuracy for wheat (88.3% and 88.1%) took place when Sentinel-1 dual-pol data (scenario G) or all polarimetric observables and images were used for classification (scenario D). In the specific confusion matrices for scenarios D (Figure 3a) and G (Figure 3b), most of the wheat plots were classified properly (356 out of 404 for scenario D and 364 out of 412 for scenario G). Only a small misclassification between wheat and barley was produced, which is explained by their similar plant structure. As shown in Table 8, RADARSAT-2 dual-pol scenario (F) showed good results (92.1% and 81.2%) for barley and wheat, respectively. The results reported from the dual-pol scenarios suggest that VH/VV dual polarization mode is a good choice for discriminating cereals from other crops and agrees with findings by McNairn et al. [8] and Veloso et al. [59]. Although barley and wheat were found to be well classified, the PA and UA of the third cereal considered, corn, are not as good as expected with regard to previous results found in the literature [39]. The best PA was shown in scenario G with Sentinel-1 dual-pol data (78.4%) and scenario E (78.2%). Corn in scenario C also provided the second poorest PA in this study, with just 54% of the corn plots classified correctly.

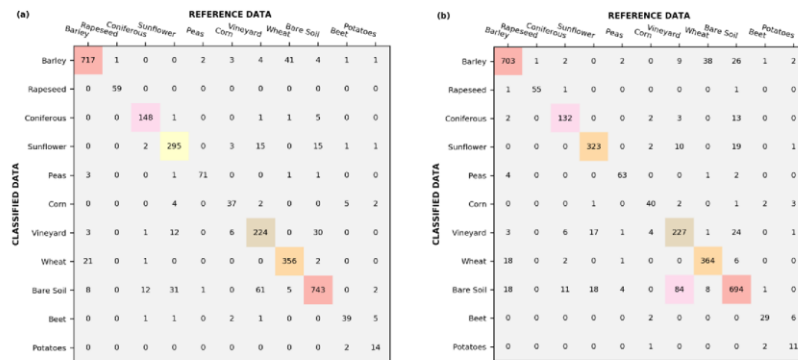


Figure 3. Confusion matrices of classification for different scenarios: (a) Scenario D. (b) Scenario G.

The lowest accuracies were found for potatoes in 4 out of 7 scenarios, which were followed by corn. The scenario G is the worst of all scenarios, with a PA of 45.8%; this means that the classification at this scenario missed 54.2% of the potato areas on the ground, indicating a tendency for the model to misclassify potatoes. Due to their broad leaves, potatoes are mostly misclassified as beets (Figure 3b), which also have a similar plant structure. From all scenarios analysed for beet, scenario A (RADARSAT-2 at 36°) provided the highest PA (93.2%) followed by scenario E (83.7%). Scenario G (Sentinel-1 data using the backscattering coefficients and the ratio) also provided a high accuracy (82.9%) for beets. The accuracy reported in this study with Sentinel-1 data is higher than the accuracy provided by Sonobe et al. [56]. They achieved a PA of 74.6% using KELM (Kernel-based Extreme Learning Algorithm) and VV polarization data.

The PA of bare soil reached the highest accuracy (92.9%) in scenario D and accuracies above 84% for the rest of the scenarios. These good results for bare soil could be related to the use of cross-polarization as one of the inputs for the classifier. The use of cross-polarization makes the distinction between bare soil and vegetation-covered surfaces easier because the vegetation canopies depolarize the incident radiation more strongly than bare surfaces. Although bare soil provided a high PA in scenario D, 120 plots of bare soil were misclassified (Figure 3a); this shows, together with the vineyard, the highest confusion (61 plots, approximately 7% of the total of this category).

The potential of SAR images for classifying vineyards has also been investigated. Measurements on vineyards are not easy, given the high number of poles and metallic wires supporting the runners and the space between runners. As expected, no high accuracies were achieved for vineyards. Scenario

A (RADARSAT-2 data at  $36^\circ$ ) showed the highest PA (73.5%) and scenario C the lowest (61.3%). Scenario C was run using RADARSAT-2 data at  $25^\circ$ , so this poor accuracy could be related to the fact that at C-band, steep angles are more sensitive to ground conditions and less sensitive to the plant features; in contrast, shallower angles increase the interaction with the vegetation, therefore reducing the contribution of the soil and increasing the possibility of getting better accuracy, as it is shown for scenario A. Even though the poorer results are obtained for vineyard relative to other land covers, its accuracy could be considered acceptable.

The misclassification among forested areas, agricultural crops and grassland is expected in land-cover applications. However, L-band SAR data are known to provide an excellent source of information for forest cover mapping and it decreases the misclassification between covers due to its significant penetration capability relative to vegetation canopies. Our results showed high PAs and UAs, ranging from 83.1% to 91.5% and 82.5% to 94.9%, respectively. Scenario F (RADARSAT-2 dual-pol data) was found to provide the best PA that was slightly higher (0.5%) than scenario E (91%). Therefore, we could conclude that C-band SAR data were able to provide reliable classification of coniferous.

Sunflower and peas were also analysed. Sunflower obtained PAs above 81% in all scenarios with the exception of scenario C, which provided a PA of 74.2%. SAR data dual-pol scenarios (G and F) showed the highest accuracies (90% and 89.1%). The results found for sunflower using dual-pol data improved the results found by Skakun et al. [39]. However, Larrañaga and Álvarez-Mozos [35] obtained a PA of 100% for sunflower when they applied VV-VH dual-pol configuration of RADARSAT-2 data with just two backscattering coefficients in the two polarization channels. The difference in accuracy (~11%) between their results and our findings could be related to the fact that we added the ratio (VH/VV) as input into the classifier and because the number of sunflower plots and images is higher. Skakun et al. [39] used RADARSAT-2 backscattering intensity (VV, VH and HH) in beam mode (FQ8W) with incidence angle ranging from  $26.1^\circ$  to  $29.4^\circ$  to run a multitemporal crop classification in Ukraine. They found PA and UA of 60% and 63.5% for sunflower. Although the poorest accuracy (74.2%) found for sunflower was when RADARSAT-2 data at  $25^\circ$  were used in the classifier, our study demonstrated that the use of different polarimetric observables (beyond backscattering coefficients) improved the classification of sunflower when SAR data with low incidence angle are used in the classifier.

Finally, for peas, the highest PA was found in scenario D (95.9%), when all polarimetric observables and images were employed by the classifier. However, there is a high difference (19.2%) between the highest and the lowest accuracy (76.7%) provided by scenario C. In terms of UA, after rapeseed and coniferous, peas showed the highest accuracies (scenario A, 93.7%; scenario E, 95.9%). The results found for peas in this study improved those found by Larrañaga and Álvarez-Mozos [35]. Figure 3a shows that only three plots of peas were confused with barley and bare soil in this study.

In addition to the accuracy of the different combinations of SAR observables, the individual LU/LC analyses provided an interesting insight into the feasibility of the multitemporal series. After the results mentioned above, the best classification took place for rapeseed, barley, wheat and peas, all of which are spring crops, having their growing cycle between March and June, when the availability of images is higher (Table 3). Conversely, the worst results were found for summer crops, with growing cycles spanning until the beginning of fall (corn, potatoes and vineyard), which is not covered by the SAR series. Although with reasonably good results, sunflowers, beets and potatoes are also summer crops and could not achieve the optimal results found for the spring crops. Thus, it can be reasoned that, as suspected, the multitemporal-based classification clearly enhances the results of the polarimetric-based classification.

### 3.2. Attribute Evaluation

C5.0 shows the degree to which each attribute (SAR observable per date) contributes to the classifier and provides the percentage of training cases in the data file for which the value of that attribute is known and used for the construction of the classifier. Due to the large number of attributes

used for each scenario, the attribute evaluation provided by C5.0 is very useful to know how individual attributes contribute to the construction of the classifier.

Figure 4 shows the attribute usage across the first three scenarios (A, B and C) that were run with 70, 60 and 60 attributes, respectively. In terms of polarimetric observables, the importance of the dominant alpha angle ( $\alpha_1$ ) can be clearly seen, followed by the cross-polar backscattering coefficient (HV) and the backscattering ratios (HH/VV and HV/VV). The large usage of these polarimetric observables at specific acquisition dates implied that the information they supplied was useful for crop separation. Additionally, the contribution of the correlation between the co-polar channels ( $\gamma_{HHVV}$ ) is important in scenario A. The least important polarimetric observables used in these scenarios were VV,  $\gamma_{PP1P2}$  and polarized difference phase (PPD).

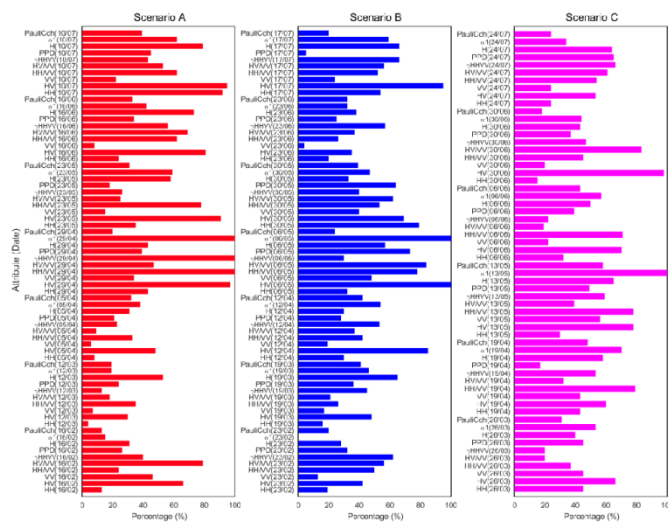


Figure 4. Attribute contribution for scenarios A, B and C.

Scenario D (Figure 5) was the more complex scenario tested in this study with 200 attributes used. Like scenarios A, B and C, the dominant alpha angle ( $\alpha_1$ ),  $\gamma_{HHVV}$  and the cross-polar backscattering coefficient (HV) are the most important observables. Many polarimetric observables at certain dates show null percentage, mainly because C5.0 does not show the attributes with values smaller than 1%.

The attributes of the last three scenarios (E, F and G) are shown in Figure 6. These scenarios used 56 (E), 42 (F) and 42 (G) attributes. Scenario E showed a clear influence of  $\gamma_{HHVV}$  on April 29, with 100% of the cases used in the classifier. In scenarios F and G (with just three polarimetric observables used), the cross-polar ratios (HV/VV and VH/VV) provided a high weight to the classifier.

In terms of the acquisition dates, the RADARSAT-2 scenes with highest importance, along with the polarimetric observables, were April 29, May 06 and May 13. For Sentinel-1, the images were from April 26 and May 08. Skriver [60] reported a study to determine the optimum parameters for classification using airborne C- and L-band polarimetric SAR data. He found that at C-band, early acquisition, that is, in April, has a high discrimination potential but May acquisition provides the largest discrimination potential. He also reported that for May, the correlation coefficient between HH and VV as well as the ratio between HV and VV (among others) showed clear potential for separation. The results of this study agree with these findings. The fact that April and May had major relevance in the multi-temporal series is not surprising, since as previously mentioned, during this interval the

most important vegetative growing stages of the crops in the area coincide, that is, maximum growth for the spring crops and development stage for the summer crops.




Figure 5. Attribute contribution for scenario D.

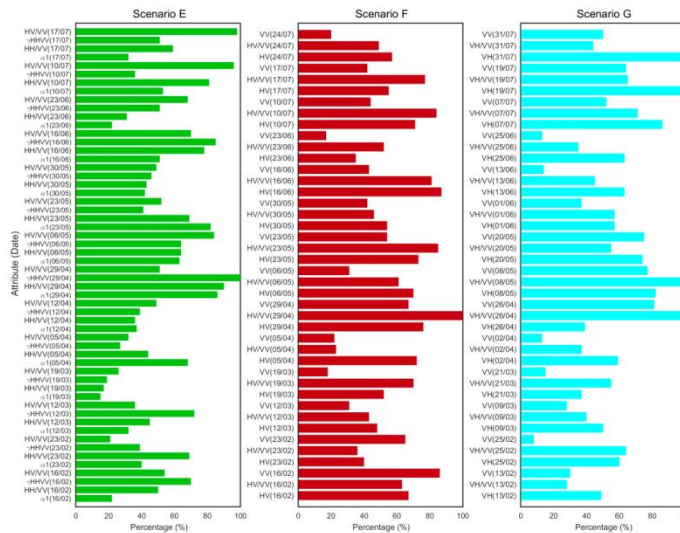


Figure 6. Attribute contribution for scenarios E, F and G.

As a final test of the evaluation of attribute importance, a focussed pairwise crop analysis was conducted to estimate which observable contributed more to distinguishing wheat and barley, which

were similar in structure and therefore expected to have a similar signal response. This test was performed for scenario D as a given example, which gathers all the possible attributes. The resulting pairwise analysis between these two crops (Figure 7) showed HH/VV as the highest contributor (100%) to separate both crops, followed by  $\gamma_{HHVV}$ .




Figure 7. Top 20 attributes used for the pairwise analysis.

Regarding the acquisition dates, the pairwise analysis with RADARSAT-2 emphasized the higher importance of May 13 as a key date reflecting the cereal growing cycle.

Feasible Applications Using the Importance of Attributes

The aim of the former analysis was to evaluate the weight of each observable in the classification to avoid redundant or useless data without losing accuracy. Choosing scenario D as an example, the feasibility of a reduced dataset for classification was tested. First, a new scenario (H) was created using the polarimetric observables with the three highest contributions in D:  $\gamma_{HHVV}$ , HV and  $\alpha_1$  (Figure 5).

Comparing the classification results for D and H, a slight difference (0.7%) between scenario D (89.1%) and scenario H (88.4%) in terms of the overall accuracy was found. At individual crop level (Table 9), the use of attributes with the highest contribution improved the PA and UA accuracy of some crops compared with the results from scenario D (Table 9). For crops such as vineyard, beet and potato, the PA improvement between scenario D and H was of approximately 5% and corn showed the highest difference (8.3%). Other crops such as peas showed a slight decrease in PA from scenario H (88.2%) to scenario D (95.9%). All data considered, the accuracy of scenario H is similar to scenario D, whilst reducing dramatically the number of observables and therefore it is much more cost-effective.

The second analysis consisted of a new classification only for the pairwise crops—wheat and barley—using solely the paramount observables resulting from the importance analysis of the previous section, that is, HH/VV and  $\gamma_{HHVV}$  (Scenario I). The accuracy assessment resulting for this new scenario (Table 10) is remarkable in comparison with the previous results of scenario D, in which all the observables were included. Both the PA and UA increased in I, meaning that the importance analysis afforded a powerful tool for separating crops with similar response, even improving the accuracy of the classification whilst reducing effectively the inputs needed (from 10 to 2, in this case).

**Table 9.** Producer’s accuracies (PAs) and user’s accuracies (UAs) of individual cover types using only selected observables (scenario H) and the whole dataset (scenario D).

	H		D	
	PA	UA	PA	UA
Barley	95.2	93.5	95.3	92.6
Rapeseed	98.3	93.5	98.3	100
Coniferous	91.2	90.1	89.7	94.9
Sunflower	86.1	85.9	85.5	88.9
Peas	88.2	97.4	95.9	92.2
Corn	80.8	85.7	72.5	74
Vineyard	77.3	75.6	72.7	81.2
Wheat	90.2	90.6	88.1	93.7
Bare soil	86.8	87.9	92.9	86.1
Beet	86.7	84.8	81.3	79.6
Potatoes	60.7	73.9	56	87.5

**Table 10.** Producer’s accuracies (PAs) and user’s accuracies (UAs) of barley and wheat using the whole dataset (scenario D), only selected observables (scenario I) and selected observables and dates (scenario J).

	D		I		J	
	PA	UA	PA	UA	PA	UA
Barley	95.3	92.6	96.3	96.5	92.7	92.2
Wheat	88.1	93.7	93.4	92.9	85.2	86

In order to explore the pairwise crop classification with limited inputs, a third analysis (named scenario J) was carried out from RADARSAT-2 data. This scenario was run using only the two main observables from Scenario I ( $HH/VV$  and  $\gamma_{HHVV}$ ) and the three dates with highest importance (April 29, May 06 and May 13). Comparing the results of scenario J (Table 10) with the previous scenario I, it is noticeable that the accuracy has decreased but to a very small extent given the reduced dataset included on J. Indeed, if compared to the general scenarios A–G (with much more polarimetric observables and dates), the accuracy provided by scenario J is slightly higher (~0.5%) than scenarios B and E, whilst for wheat the PA is higher than for scenarios A, B, E and F. Again, the results of the importance analysis enabled a way to reduce the inputs whilst maintaining a remarkable accuracy.

#### 4. Conclusions

The capability of polarimetric observables from multitemporal series of RADARSAT-2 and Sentinel-1 images for crop-type classification was assessed, together with an analysis of the influence of the incidence angle and the importance of the observables. A dataset of more than 3000 plots of 11 crop types and land covers was used as a reference map to obtain the confusion matrices and therefore to validate all the combinations of the 10 SAR observables proposed.

The use of all polarimetric RADARSAT-2 observables and scenes available produced clear benefits in terms of the overall accuracy (scenario D), which was approximately 90%. However, other alternatives tested with RADARSAT-2, such as those that use incidence angles separately (scenarios A, B and C) also afforded very high overall accuracies. Since these latter alternatives require less data, they may be considered more cost-effective than the extensive dataset required in D. Thus, it may be concluded that even with the limited revisit time of 24 days of RADARSAT-2, the strength of the multitemporal series using polarimetric data reinforced its high capability to classify land covers. Nonetheless, the joint use of only dual-pol Sentinel-1 and RADARSAT-2 also provided very good accuracies greater than 85%. The results from the *kappa* coefficient confirmed all these results.

When the incidence angle was considered separately (cases A, B and C aforementioned), the variation between cases in terms of overall accuracy and  $\kappa$  is only 3.5% and 6%, respectively. After the results, the incidence angle seems not to influence neither the classification broadly nor the individual results for each cover, which were heterogeneous and not conclusive.

Regarding the individual results for each specific land cover, the rapeseed crop obtained the best accuracy for all scenarios—higher than 95%. The good separation of spring cereals, typically difficult owing to their similar structure and phenology, was also remarkable. The addition of polarimetric SAR data at C-band allowed classifying wheat and barley with high very high PAs and UAs. In contrast, vineyard, corn and potatoes showed the worst results, followed by sunflowers, beets and peas. The middling results for those summer crops may be explained by their shorter time coverage of images during summer-early fall, highlighting the importance of a complete multitemporal coverage for the whole growing season, as in the case of wheat and barley.

The contribution of each SAR observable per date to the different alternatives of classification was also analysed by means of the attribute study available in the C5.0 algorithm. Among the polarimetric observables, the dominant alpha angle ( $\alpha_1$ ) showed a predominant contribution with RADARSAT-2 at all the different incidence angle alternatives, whereas for the dual polarization scenario of Sentinel-1 (G), the cross-polar channel VH and the VH/VV ratio were the most important. Those findings about the performance of each observable would help in future classifications by reducing the use of redundant and potentially misleading data. Following this thread, it has been proven that a classification using only the key observables improved on, or afforded similar accuracy to, the previous classifications with the whole dataset, whilst dramatically reducing the number of data and the computing time. This finding applied not only for a classification of all the categories in a whole but also for discriminating crop pairs with low separability, for example, wheat versus barley. The analysis of importance was also useful for defining which dates were crucial in the classification. The results showed that May acquisitions were the key dates in the classification, coinciding with the maximum growing period of many crops in the area. When the crops have a summer cycle, the separation worsened.

Finally, although the polarimetric capabilities of RADARSAT-2 and Sentinel-1 are rather different, the multitemporal approach reinforced the classification process and provided similar satisfactory results for the different scenarios of classification. Additional features that could also help to improve the accuracy of the classification of individual crop types are interferometric parameters, such as coherence, as well as textural information within the intensity values. In addition, further tests should be conducted over other different climatic and environmental conditions to expand and consolidate the method.

**Author Contributions:** All authors contributed significantly to this manuscript. R.V.-D. conceived the research and performed the analysis. R.V.-D. and B.A.-P. processed the satellite data. J.M.L.-S. and N.S. provided constructive suggestions. Finally, R.V.-D. prepared the manuscript draft and the rest of the authors contributed to the final manuscript and approved it.

**Funding:** RADARSAT-2 Data and Products @ MacDonald, Dettwiler and Associates Ltd. (MDA, 2015)—All Rights Reserved RADARSAT is an official trademark of the Canadian Space Agency (CSA). All RADARSAT-2 images have been provided by MDA and CSA in the framework of the SOAR-EU2 Project ref. 16375. This study was supported by the Spanish Ministry of Science, Innovation and Universities, State Research Agency (AEI) and the European Regional Development Fund under projects TEC2017-85244-C2-1-P, ESP2015-67549-C3-3 and ESP2017-89463-C3-3-R.

**Conflicts of Interest:** The authors declare no conflict of interest.

## References

1. Kogan, F.; Kussul, N.; Adamenko, T.; Skakun, S.; Kravchenko, O.; Kryvobok, O.; Shelestov, A.; Kolotii, A.; Kussul, O.; Lavrenyuk, A. Winter wheat yield forecasting in Ukraine based on Earth observation, meteorological data and biophysical models. *Int. J. Appl. Earth Obs. Geoinf.* **2013**, *23*, 192–203. [[CrossRef](#)]

2. Gallego, F.J.; Kussul, N.; Skakun, S.; Kravchenko, O.; Shelestov, A.; Kussul, O. Efficiency assessment of using satellite data for crop area estimation in Ukraine. *Int. J. Appl. Earth Obs. Geoinf.* **2014**, *29*, 22–30. [[CrossRef](#)]
3. Becker-Reshef, I.; Justice, C.; Sullivan, M.; Vermote, E.; Tucker, C.; Anyamba, A.; Small, J.; Pak, E.; Masuoka, E.; Schmalz, J.; et al. Monitoring Global Croplands with Coarse Resolution Earth Observations: The Global Agriculture Monitoring (GLAM) Project. *Remote Sens.* **2010**, *2*, 1589–1609. [[CrossRef](#)]
4. McNairn, H.; Ellis, J.; Van Der Sanden, J.J.; Hirose, T.; Brown, R.J. Providing crop information using RADARSAT-1 and satellite optical imagery. *Int. J. Remote Sens.* **2002**, *23*, 851–870. [[CrossRef](#)]
5. Ban, Y. Synergy of multitemporal ERS-1 SAR and Landsat TM data for classification of agricultural crops. *Can. J. Remote Sens.* **2003**, *29*, 518–526. [[CrossRef](#)]
6. Blaes, X.; Vanhalle, L.; Defourny, P. Efficiency of crop identification based on optical and SAR image time series. *Remote Sens. Environ.* **2005**, *96*, 352–365. [[CrossRef](#)]
7. Brisco, B.; Brown, R.J. Multidate SAR/TM synergism for crop classification in western Canada. *Photogramm. Eng. Remote Sens.* **1995**, *61*, 1009–1014.
8. McNairn, H.; Champagne, C.; Shang, J.; Holmstrom, D.; Reichert, G. Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. *ISPRS J. Photogramm. Remote Sens.* **2009**, *64*, 434–449. [[CrossRef](#)]
9. Schotten, C.G.J.; Van Rooy, W.W.L.; Janssen, L.L.F. Assessment of the capabilities of multi-temporal ERS-1 SAR data to discriminate between agricultural crops. *Int. J. Remote Sens.* **1995**, *16*, 2619–2637. [[CrossRef](#)]
10. Torres, R.; Snoeij, P.; Geudtner, D.; Bibby, D.; Davidson, M.; Attema, E.; Potin, P.; Rommen, B.; Floury, N.; Brown, M.; et al. GMES Sentinel-1 mission. *Remote Sens. Environ.* **2012**, *120*, 9–24. [[CrossRef](#)]
11. Aschbacher, J.; Milagro-Pérez, M.P. The European Earth monitoring (GMES) programme: Status and perspectives. *Remote Sens. Environ.* **2012**, *120*, 3–8. [[CrossRef](#)]
12. Chen, K.S.; Huang, W.P.; Tsay, D.H.; Amar, F. Classification of multifrequency polarimetric SAR imagery using a dynamic learning neural network. *IEEE Trans. Geosci. Remote Sens.* **1996**, *34*, 814–820. [[CrossRef](#)]
13. Ferrazzoli, P.; Guerriero, L.; Schiavon, G. Experimental and model investigation on radar classification capability. *IEEE Trans. Geosci. Remote Sens.* **1999**, *37*, 960–968. [[CrossRef](#)]
14. Ferrazzoli, P.; Paloscia, S.; Pampaloni, P.; Schiavon, G.; Sigismondi, S.; Solimini, D. The potential of multifrequency polarimetric SAR in assessing agricultural and arboreous biomass. *IEEE Trans. Geosci. Remote Sens.* **1997**, *35*, 5–17. [[CrossRef](#)]
15. Bouman, B.A.M.; Uenk, D. Crop classification possibilities with radar in ERS-1 and JERS-1 configuration. *Remote Sens. Environ.* **1992**, *40*, 1–13. [[CrossRef](#)]
16. Dobson, M.C.; Pierce, L.E.; Ulaby, F.T. Knowledge-based land-cover classification using ERS-1/JERS-1 SAR composites. *IEEE Trans. Geosci. Remote Sens.* **1996**, *34*, 83–99. [[CrossRef](#)]
17. McNairn, H.; Shang, J.; Jiao, X.; Champagne, C. The contribution of ALOS PALSAR multipolarization and polarimetric data to crop classification. *IEEE Trans. Geosci. Remote Sens.* **2009**, *47*, 3981–3992. [[CrossRef](#)]
18. Schmutge, T.J.; Kustas, W.P.; Ritchie, J.C.; Jackson, T.J.; Rango, A. Remote sensing in hydrology. *Adv. Water Resour.* **2002**, *25*, 1367–1385. [[CrossRef](#)]
19. Skriver, H.; Svendsen, M.T.; Thomsen, A.G. Multitemporal C- and L-band polarimetric signatures of crops. *IEEE Trans. Geosci. Remote Sens.* **1999**, *37*, 2413–2429. [[CrossRef](#)]
20. Larrañaga, A.; Álvarez-Mozos, J.; Albizua, L.; Peters, J. Backscattering Behavior of Rain-Fed Crops Along the Growing Season. *IEEE Geosci. Remote Sens. Lett.* **2013**, *10*, 386–390. [[CrossRef](#)]
21. Skriver, H. Crop Classification by Multitemporal C- and L-Band Single- and Dual-Polarization and Fully Polarimetric SAR. *IEEE Trans. Geosci. Remote Sens.* **2012**, *50*, 2138–2149. [[CrossRef](#)]
22. Skriver, H.; Mattia, F.; Satalino, G.; Balenzano, A.; Pauwels, V.R.N.; Verhoest, N.E.C.; Davidson, M. Crop Classification Using Short-Revisit Multitemporal SAR Data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2011**, *4*, 423–431. [[CrossRef](#)]
23. Bargiel, D. A new method for crop classification combining time series of radar images and crop phenology information. *Remote Sens. Environ.* **2017**, *198*, 369–383. [[CrossRef](#)]
24. Hariharan, S.; Mandal, D.; Tirodkar, S.; Kumar, V.; Bhattacharya, A.; Lopez-Sanchez, J.M. A Novel Phenology Based Feature Subset Selection Technique Using Random Forest for Multitemporal PolSAR Crop Classification. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2018**, *11*, 4244–4258. [[CrossRef](#)]



25. Kussul, N.; Lemoine, G.; Gallego, J.; Skakun, S.; Lavreniuk, M. Parcel based classification for agricultural mapping and monitoring using multi-temporal satellite image sequences. In Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS), Milan, Italy, 26–31 July 2015; pp. 165–168.
26. Mandal, D.; Kumar, V.; Bhattacharya, A.; Rao, Y.S.; Siqueira, P.; Bera, S. Sen4Rice: A processing chain for differentiating early and late transplanted rice using time-series sentinel-1 SAR data with google earth engine. *IEEE Geosci. Remote Sens. Lett.* **2018**, *15*, 1947–1951. [[CrossRef](#)]
27. Siachalou, S.; Mallinis, G.; Tsakiri-Strati, M. A Hidden Markov Models Approach for Crop Classification: Linking Crop Phenology to Time Series of Multi-Sensor Remote Sensing Data. *Remote Sens.* **2015**, *7*, 3633–3650. [[CrossRef](#)]
28. Canisius, F.; Shang, J.; Liu, J.; Huang, X.; Ma, B.; Jiao, X.; Geng, X.; Kovacs, J.M.; Walters, D. Tracking crop phenological development using multi-temporal polarimetric Radarsat-2 data. *Remote Sens. Environ.* **2017**, *210*, 508–518. [[CrossRef](#)]
29. Mascolo, L.; Lopez-Sanchez, J.M.; Vicente-Guijalba, F.; Nunziata, F.; Migliaccio, M.; Mazzarella, G. A Complete Procedure for Crop Phenology Estimation with PolSAR Data Based on the Complex Wishart Classifier. *IEEE Trans. Geosci. Remote Sens.* **2016**, *54*, 6505–6515. [[CrossRef](#)]
30. Brisco, B.; Brown, R.J.; Gairns, J.G.; Snider, B. Temporal Ground-Based Scatterometer Observations of Crops in Western Canada. *Can. J. Remote Sens.* **1992**, *18*, 14–21. [[CrossRef](#)]
31. Foody, G.M.; McCulloch, M.B.; Yates, W.B. Crop classification from C-band polarimetric radar data. *Int. J. Remote Sens.* **1994**, *15*, 2871–2885. [[CrossRef](#)]
32. Lee, J.-S.; Grunes, M.R.; Pottier, E. Quantitative comparison of classification capability: Fully polarimetric versus dual and single-polarization SAR. *IEEE Trans. Geosci. Remote Sens.* **2001**, *39*, 2343–2351.
33. Loosvelt, L.; Peters, J.; Skriver, H.; De Baets, B.; Verhoest, N.E.C. Impact of Reducing Polarimetric SAR Input on the Uncertainty of Crop Classifications Based on the Random Forests Algorithm. *IEEE Trans. Geosci. Remote Sens.* **2012**, *50*, 4185–4200. [[CrossRef](#)]
34. Deschamps, B.; McNairn, H.; Shang, J.; Jiao, X. Towards operational radar-only crop type classification: Comparison of a traditional decision tree with a random forest classifier. *Can. J. Remote Sens.* **2012**, *38*, 60–68. [[CrossRef](#)]
35. Larrañaga, A.; Álvarez-Mozos, J. On the added value of quad-pol data in a multi-temporal crop classification framework based on RADARSAT-2 imagery. *Remote Sens.* **2016**, *8*, 335. [[CrossRef](#)]
36. Sonobe, R.; Tani, H.; Wang, X.; Kobayashi, N.; Shimamura, H. Random forest classification of crop type using multi-temporal TerraSAR-X dual-polarimetric data. *Remote Sens. Lett.* **2014**, *5*, 157–164. [[CrossRef](#)]
37. McNairn, H.; Kross, A.; Lapen, D.; Caves, R.; Shang, J. Early season monitoring of corn and soybeans with TerraSAR-X and RADARSAT-2. *Int. J. Appl. Earth Obs. Geoinf.* **2014**, *28*, 252–259. [[CrossRef](#)]
38. Zhang, Y.; Zhang, J.; Zhang, X.; Wu, H.; Guo, M. Land Cover Classification from Polarimetric SAR Data Based on Image Segmentation and Decision Trees. *Can. J. Remote Sens.* **2015**, *41*, 40–50. [[CrossRef](#)]
39. Skakun, S.; Kussul, N.; Shelestov, A.Y.; Lavreniuk, M.; Kussul, O. Efficiency Assessment of Multitemporal C-Band Radarsat-2 Intensity and Landsat-8 Surface Reflectance Satellite Imagery for Crop Classification in Ukraine. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2016**, *9*, 3712–3719. [[CrossRef](#)]
40. Sonobe, R.; Tani, H.; Wang, X.; Kobayashi, N.; Shimamura, H. Discrimination of crop types with TerraSAR-X-derived information. *Phys. Chem. Earth* **2015**, *83–84*, 2–13. [[CrossRef](#)]
41. Zeyada, H.H.; Ezz, M.M.; Nasr, A.H.; Shokr, M.; Harb, H.M. Evaluation of the discrimination capability of full polarimetric SAR data for crop classification. *Int. J. Remote Sens.* **2016**, *37*, 2585–2603. [[CrossRef](#)]
42. Valcarce-Diñeiro, R.; Lopez-Sanchez, J.M.; Sánchez, N.; Arias-Pérez, B.; Martínez-Fernández, J. Influence of Incidence Angle in the Correlation of C-band Polarimetric Parameters with Biophysical Variables of Rain-fed Crops. *Can. J. Remote Sens.* **2018**, *44*, 643–659. [[CrossRef](#)]
43. Nafria, D.A.; del Blanco, V.; Bengoa, J.L. Castile and Leon Crops and Natural Land Map. In Proceedings of the WorldCover Conference, Frascati, Rome, Italy, 14–16 March 2017.
44. Cloude, S.R.; Pottier, E. A review of target decomposition theorems in radar polarimetry. *IEEE Trans. Geosci. Remote Sens.* **1996**, *34*, 498–518. [[CrossRef](#)]
45. Schubert, A.; Small, D.; Miranda, N.; Geudtner, D.; Meier, E. Sentinel-1A Product Geolocation Accuracy: Commissioning Phase Results. *Remote Sens.* **2015**, *7*, 9431–9449. [[CrossRef](#)]
46. Quinlan, J.R. *C4.5: Programs for Machine Learning*; Morgan Kaufmann Publishers, Inc.: San Mateo, CA, USA, 1992.

47. Champagne, C.; McNairn, H.; Daneshfar, B.; Shang, J. A bootstrap method for assessing classification accuracy and confidence for agricultural land use mapping in Canada. *Int. J. Appl. Earth Obs. Geoinf.* **2014**, *29*, 44–52. [[CrossRef](#)]
48. Powers, R.P.; Hay, G.J.; Chen, G. How wetland type and area differ through scale: A GEOBIA case study in Alberta's Boreal Plains. *Remote Sens. Environ.* **2012**, *117*, 135–145. [[CrossRef](#)]
49. Freund, Y.; Schapire, R.E. Experiments with a New Boosting Algorithm. In *Machine Learning: Proceedings of the Thirteenth International Conference*; Bari, Italy, 1996; Morgan Kaufmann Publishers Inc.: San Francisco, CA, USA, 1996; pp. 148–156.
50. Congalton, R.G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sens. Environ.* **1991**, *37*, 35–46. [[CrossRef](#)]
51. Story, M.; Congalton, R.G. Accuracy assessment: A user's perspective. *Photogramm. Eng. Remote Sens.* **1986**, *52*, 397–399.
52. Cohen, J. A Coefficient of Agreement for Nominal Scales. *Educ. Psychol. Meas.* **1960**, *20*, 37–46. [[CrossRef](#)]
53. Balzter, H.; Cole, B.; Thiel, C.; Schmulius, C. Mapping CORINE Land Cover from Sentinel-1A SAR and SRTM Digital Elevation Model Data using Random Forests. *Remote Sens.* **2015**, *7*, 14876–14898. [[CrossRef](#)]
54. Son, N.T.; Chen, C.F.; Chen, C.R.; Minh, V.Q. Assessment of Sentinel-1A data for rice crop classification using random forests and support vector machines. *Geocarto Int.* **2018**, *33*, 587–601. [[CrossRef](#)]
55. Kussul, N.; Lemoine, G.; Gallego, F.J.; Skakun, S.V.; Lavreniuk, M.; Shelestov, A.Y. Parcel-Based Crop Classification in Ukraine Using Landsat-8 Data and Sentinel-1A Data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2016**, *9*, 2500–2508. [[CrossRef](#)]
56. Sonobe, R.; Yamaya, Y.; Tani, H.; Wang, X.; Kobayashi, N.; Mochizuki, K.I. Assessing the suitability of data from Sentinel-1A and 2A for crop classification. *GISci. Remote Sens.* **2017**, *54*, 918–938. [[CrossRef](#)]
57. Zhou, T.; Pan, J.; Zhang, P.; Wei, S.; Han, T. Mapping winter wheat with multi-temporal SAR and optical images in an urban agricultural region. *Sensors* **2017**, *17*, 1210. [[CrossRef](#)] [[PubMed](#)]
58. Rosenthal, W.D.; Blanchard, B.J. Active microwave responses: An aid in improved crop classification. *Photogramm. Eng. Remote Sens.* **1984**, *50*, 461–468.
59. Veloso, A.; Mermoz, S.; Bouvet, A.; Le Toan, T.; Planells, M.; Dejoux, J.F.; Ceschia, E. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sens. Environ.* **2017**, *199*, 415–426. [[CrossRef](#)]
60. Skriver, H. Signatures of polarimetric parameters and their implications on land cover classification. In *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, Barcelona, Spain, 23–27 July 2007; pp. 4195–4198.



© 2019 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).