

## Discriminación de trigo y cebada empleando imágenes satelitales ópticas y radar. Estudio de caso: partido de Coronel Rosales (Argentina)

*Wheat and barley discrimination using sar and optical satellite images. Case study: Coronel Rosales department (Argentina)*

Fabián Marini\*

Recibido: 03/07/2020. Aprobado: 13/11/2020. Publicado: 16/02/2021.

**Resumen.** El partido de Coronel Rosales (Buenos Aires, Argentina) se halla localizado dentro de la región pampeana austral, una de las de mayor relevancia agro productiva del país. En este contexto, el conocimiento de la superficie cultivada adquiere significativa importancia para la posterior planificación agrícola y económica. En tal sentido, la discriminación de cultivos mediante teledetección se dificulta cuando se trata de los de ciclo fenológico muy similar, como el trigo y la cebada. En este estudio se realizó una discriminación de dichos cultivos empleando imágenes de Radar de Apertura Sintética (SAR) Sentinel-1A SLC, imágenes ópticas Sentinel-2 y una combinación de ambos tipos de datos. Se incorporaron medidas de coherencia, textura e intensidad de retrodispersión extraídas de los datos SAR durante el ciclo fenológico completo. Sobre cada escena Sentinel-2 se obtuvo el Índice de Diferencia Normalizada de Vegetación (Normalized Difference Vegetation Index - NDVI). Se emplearon tres algoritmos de clasificación: Máxima Verosimilitud (Maximum Likelihood - MLC), Máquinas de Soporte Vectorial (Support Vector Machines - SVM) y Random Forest (RF). Los mejores resultados se obtuvieron al combinar imágenes ópticas y SAR empleando el clasificador RF. La combinación de las retrodispersiones VV y VH junto a la coherencia y la textura de las imágenes SAR, sumada al apilado de NDVI de imágenes ópticas, arrojó los máximos valores de precisión de la clasificación. El valor de F1 fue de 87.27% para el trigo y de 89.20% para la cebada.

**Palabras clave:** SAR, NDVI, trigo, cebada, teledetección.

**Abstract.** In Argentina, the farming industry is considered one of the main economic resources in terms of income and domestic market supply. Thus, the study, inventory, and knowledge of the cultivated surface area are key cornerstones for agricultural and economic planning. Agriculture focuses mainly on cereals such as wheat, barley, maize, oat, and sorghum, as well as on oilseeds such as soybeans, sunflower, and peanuts. The most important productive areas of Argentina include the Pampean region, where the Coronel Rosales Department is located (Buenos Aires, Argentina).

In this context, the knowledge of the cultivated surface area is particularly important to support agricultural and economic planning. In this regard, crop discrimination based on remote sensing is difficult for crops with highly similar phenological cycles, as is the case of wheat and barley. To address this issue, the standard satellite image classification methods have been based on the spectral response of each individual pixel using optical images. Crops are also monitored using Synthetic Aperture Radar (SAR) images; these have several advantages over optical imagery because radio waves are unaffected by the presence of clouds. This provides the benefit of recording satellite data throughout the whole phenological cycle.

\* Instituto Nacional de Tecnología Agropecuaria - INTA. Agencia de Extensión Bahía Blanca de la Estación Experimental Bordenave. San Andrés 800 - Campus Universitario. Bahía Blanca, Buenos Aires, Argentina. ORCID: Correo electrónico: marini.fabian@inta.gob.ar

The aim of this work is to discriminate wheat from barley crops grown in the Coronel Rosales Department by using SAR data, optical images, and the combination of both approaches. To this end, we used coherence (C), texture (T), and backscatter intensity images extracted from SAR data derived from the Sentinel-1A satellite over the whole phenological cycle of both winter crops. The optical images used were Sentinel-2, with six representative dates selected from the different phenological states of each culture. To have comparable parameters over time, we obtained the reflectance value for each band used, and the Normalized Difference Vegetation Index (NDVI) for each scene. SAR images from the Sentinel-1 satellite were also used, including seven dual polarization images (VV and VH), and the Single Look Complex (SLC) product.

Three classification algorithms were used: Maximum Likelihood (MLC), Support Vector Machines (SVM), and Random Forest (RF). To evaluate each classification, a confounding matrix was generated, from which two accuracy measurements are derived: Global Accuracy (P), i.e., the ratio between the total number of pixels correctly classified and the total number of pixels corresponding to field-based (true) classifications, and the F1 coefficient. The latter uses the accuracy percentages corresponding to the producer and the user, derived from the confounding matrix

## INTRODUCCIÓN

En la República Argentina, el sector agropecuario es considerado uno de los principales recursos económicos, tanto como generador de divisas como abastecedor de su mercado interno. De esto se deriva que el estudio, inventario y conocimiento de la superficie cultivada adquiere significativa importancia para la posterior planificación agrícola y económica. En dicho territorio, la agricultura se vincula principalmente a cereales como trigo, cebada, maíz, avena y sorgo y a oleaginosas como girasol, maní (cacahuete) y soja. Entre las regiones productoras más importantes del país se encuentra la región pampeana, dentro de la cual se halla emplazado el partido de Coronel Rosales (Buenos Aires, Argentina). No obstante, dicho partido se halla localizado en un área de clima semiárido, razón por la cual los cultivos alcanzan menor desarrollo que en el resto de la región pampeana.

Esta última característica, junto a la diversidad en las fechas de siembra y en la tecnología empleada, implica un desafío en la discriminación de cultivos mediante teledetección, especialmente cuando se trata de cultivos de ciclo fenológico

The study showed that the use of SAR data allowed an optimal discrimination of both winter crops. The combination VV + VH + C+ T yielded the best results for wheat (F1: 79.74%), while the combination C + T was the best for discriminating barley (F1: 84.94%). From the above, we can conclude that combining consistency, texture, and backscatter images improves classification accuracy. Besides, our results corroborate that optical data can be replaced by Sentinel-1A images when the scenes from the former are limited by the presence of clouds. Classification using optical images (NDVI image stacking) yielded optimal results using the MLC algorithm (P: 80.62%). In contrast, for winter crop discrimination, the highest F1 values were obtained using the RF method (82.95% for wheat and 84.16% for barley).

The best results of the overall classifications performed were obtained by combining optical images and SAR. The combination of all SAR images (VV + VH + C+ T) with NDVI stacking yielded the highest Overall Accuracy value (89.37%). For winter crop discrimination, the combination of Sentinel-1A data with optical data was also most accurate. The combination VV + VH + C+T+ NDVI yielded F1 values of 87.27% for wheat and 89.20% for barley using the RF algorithm.

**Keywords:** SAR, NDVI, wheat, barley, remote sensing.

muy similar como en el caso del trigo y la cebada. De hecho, ambos cultivos presentan un aspecto muy similar durante su etapa de máximo desarrollo, cuya identificación, incluso en el terreno, no siempre resulta inmediata (Figura 1). Para subsanar estos inconvenientes, los métodos habituales de clasificación de imágenes satelitales se han basado en la respuesta espectral individual de cada píxel generalmente empleando imágenes ópticas. En tal sentido, en la República Argentina se ha empleado con eficacia el Índice de Diferencia Normalizada de Vegetación (Normalized Difference Vegetation Index - NDVI) tanto para determinar diferentes usos del suelo como para discriminar cultivos (Volante *et al.*, 2006; Vázquez *et al.*, 2006; Marini, 2016; Marini y Ángeles, 2016).

En lo referente al monitoreo de cultivos utilizando imágenes Radar de Apertura Sintética (SAR), estos presentan diversas ventajas con respecto a los ópticos, siendo la principal el hecho de que las ondas de radio no se ven afectadas por la presencia de nubes. Esto brinda la oportunidad de contar con datos satelitales durante la totalidad del ciclo fenológico de los cultivos, es decir, desde su siembra hasta su cosecha. En tal sentido, la banda C se



Figura 1. Fotografía de un lote de trigo (izquierda) y de uno de cebada (derecha) en el partido de Coronel Rosales durante su etapa de máximo desarrollo. Fuente: fotografía propia.

considera una longitud de onda adecuada para la discriminación de cultivos (Mc Nairn *et al.*, 2009; Skriver *et al.*, 2011), ya que su retrodispersión SAR es muy sensible a los cambios, especialmente durante la etapa de desarrollo (Mc Nairn y Shang, 2016).

La mayor parte de los trabajos aplicados a detección de cultivos y uso del suelo con imágenes SAR solía efectuarse utilizando datos multiparamétricos (Blaes *et al.*, 2005; Loosvelt *et al.*, 2012; Jiao *et al.*, 2014; Chen *et al.*, 2015; Schmullius *et al.*, 2015), así como la fusión de datos SAR e imágenes ópticas (Mc Nairn *et al.*, 2009; Skakun *et al.*, 2015). No obstante, en los últimos años la Agencia Espacial Europea (ESA) ha lanzado el satélite SAR Sentinel-1A, cuyos datos son de disposición libre y gratuita. Esto generó que diversas investigaciones centradas en clasificaciones de cultivos empleasen series temporales Sentinel-1A aprovechando las mencionadas ventajas de la banda C de dicho satélite (Veloso *et al.*, 2017; Kenduiwo *et al.*, 2018; Whelen y Siqueira, 2018; Xu *et al.*, 2019). Esto implica tanto el empleo de diversos algoritmos de clasificación como la adición de medidas como textura y coherencia, que también han demostrado ser idóneas en

la detección de cultivos (Jia *et al.*, 2012; Yayusman y Nagasawa, 2015).

El objetivo de este trabajo consiste en discriminar dos cultivos de invierno de ciclos fenológicos similares como el trigo y la cebada en el partido de Coronel Rosales mediante el uso de datos SAR, de imágenes ópticas y de la combinación de ambos tipos de datos. Para cumplimentar dicho objetivo, se incorporaron imágenes de coherencia, textura e intensidad de retrodispersión extraídas de los datos SAR derivados del satélite Sentinel-1A durante el ciclo fenológico completo de ambos cultivos de invierno.

## ÁREA DE ESTUDIO

El Partido de Coronel Rosales se localiza en el suroeste de la provincia de Buenos Aires dentro de la región pampeana austral, una de las de mayor relevancia agro-productiva del país, y presenta una superficie de 1340 km<sup>2</sup> (Figura 2). Dicho partido posee una población de 62 152 habitantes (INDEC, 2011), siendo su cabecera la ciudad de

Punta Alta. Desde el punto de vista agroecológico, presenta dos unidades de paisaje con características geomorfológicas y edáficas bien diferenciadas. La primera de estas unidades ocupa el 31% del territorio y se halla conformada por una faja litoral de dunas costeras con alturas variables que en algunos sectores se intercala con áreas planas u onduladas interdunícolas. Los establecimientos agropecuarios localizados en esta unidad de paisaje son los de menor aptitud agrícola debido al predominio de suelos pertenecientes al Orden de los Entisoles (Suborden Psamentes) con textura arenosa y alta permeabilidad y susceptibilidad a la erosión eólica (INTA, 1989). La segunda unidad de paisaje ocupa la mayor parte del área de estudio y se caracteriza por relieves pedemontanos con una cubierta loésica de espesor variable conformando lomadas y ondulaciones con presencia de costras calcáreas superficiales o subsuperficiales (denominadas bajo el localismo *tosca*). El 47% de los establecimientos agropecuarios del partido se localizan en esta unidad y poseen un predominio de suelos pertenecientes al Orden de los Molisoles (Suborden Udoles) con una textura franca gruesa, escurrimiento medio y susceptible a erosión eólica (INTA, 1989).

El clima puede considerarse como templado de transición con temperaturas moderadas y una precipitación media anual de 602 mm (Valles y Silva Busso, 2016). No obstante, el régimen de precipitaciones suele ser errático, concentrándose durante la primavera y el verano, decreciendo en otoño y alcanzando los valores mínimos durante el invierno. Esta característica del régimen de precipitaciones, sumada a la baja capacidad de retención de agua de los suelos y a los períodos de sequía recurrentes, condicionan tanto la producción agropecuaria como la ganadera. La temperatura media anual es de 16.2 °C, siendo enero el mes más cálido (24 °C) y julio el más frío (7 °C) (RADAR, 2001). Los vientos son moderados registrándose velocidades medias entre 9 y 13 km/h con direcciones dominantes N-NO (Saldungaray *et al.*, 2012).

Las condiciones agroecológicas de la región definen la aptitud del partido para el desarrollo de actividades mixtas agrícola-ganaderas o ganadero-agrícolas. En lo concerniente a la agricultura, predominan los cultivos de invierno, en especial el trigo y la cebada de cosecha, y en menor medida algunos cultivos de verano como el sorgo, generalmente utilizado como forraje para la ganadería, y el maíz. No obstante, en los últimos años

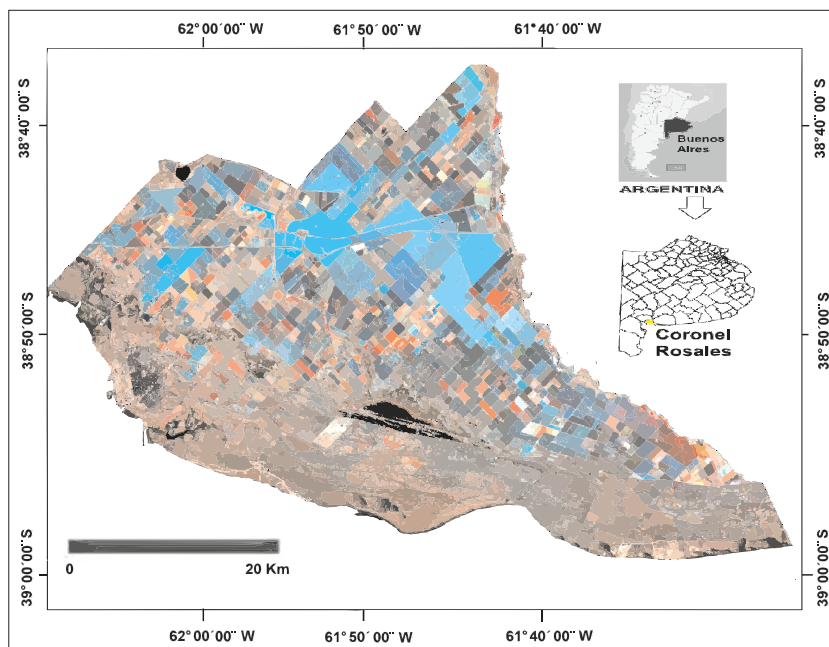


Figura 2. Imagen Sentinel-2 del partido de Coronel Rosales y su localización relativa. Fuente: elaboración propia.

las condiciones climáticas, las socioeconómicas y las políticas macroeconómicas han impactado notablemente en el sistema productivo provocando, entre 1988 y 2002, una disminución del 27% de los establecimientos agropecuarios (EAP) de menos de 500 ha (Álamo y Garabito, 2012) y un descenso del stock ganadero del 26% para el período 2008-2010 (Saldungaray *et al.*, 2012).

## DATOS

### Imágenes satelitales ópticas y SAR

Se utilizaron imágenes Sentinel-2 seleccionándose seis fechas representativas de los distintos estados fenológicos de cada cultivo (de acuerdo con la disponibilidad de las mismas y a la ausencia de nubes). Las fechas empleadas fueron las siguientes (escenas HNC, HNB, HPC y HPB): Año 2017: 21 de julio, 11 de septiembre, 29 de octubre, 18 de noviembre y 25 de diciembre. Año 2018: 7 de enero. Dichas escenas fueron descargadas de la página de la misión ESA - European Space Agency destinada a tal fin (<https://scihub.copernicus.eu>). Las imágenes fueron luego procesadas utilizando la proyección UTM 20 Sur (datum WGS 1984). A fin de contar con parámetros comparables en el tiempo, se obtuvo el valor de reflectancia en cada banda utilizada.

Por otra parte, se emplearon imágenes SAR del satélite Sentinel-1A. Esta misión opera en banda C (frecuencia central: 5.405 GHz) con una revisita que ocurre a los 6 días con los dos satélites en órbita en esta constelación. Sentinel-1A permite obtener imágenes en cuatro modos diferentes (European Space Agency - ESA, 2013): Stripmap (SM), Interferometric Wide Swath (IW), Extra-Wide Swath (EW) y Wave Mode (WM). En este estudio, se han empleado siete imágenes en modo IW con una polarización dual (producto Single Look Complex - SLC) cuyo detalle se presenta en la Tabla 1. El modo IW combina un ancho de escena de 250 km con una resolución moderada de 5 x 20 m.

### Recopilación de datos en el terreno

El trabajo en el terreno (noviembre de 2017) consistió en un relevamiento del partido de Coronel

Tabla 1. Principales características de las imágenes Sentinel-1A empleadas en este estudio.

Fecha de adquisición	Producto	Modo	Polarización
6 de septiembre de 2017	SLC	IW	VV/ VH
18 de septiembre de 2017	SLC	IW	VV/ VH
12 de octubre de 2017	SLC	IW	VV/ VH
30 de octubre de 2017	SLC	IW	VV/ VH
5 de noviembre de 2017	SLC	IW	VV/ VH
5 de diciembre de 2017	SLC	IW	VV/ VH
29 de diciembre de 2017	SLC	IW	VV/ VH

Rosales con ayuda de un GPS con el fin de obtener verdades de campo. Se recolectaron datos de cultivos de invierno (trigo y cebada de cosecha), así como de lotes con diferentes usos del suelo (campo natural, pastura, rastrojos de cultivos de invierno, pastizales y verdes invernales). De esta manera, se georreferenciaron 218 lotes que se agruparon en cinco categorías: 1) trigo, 2) cebada, 3) cultivos de verano de cosecha, 4) uso forrajero (incluye tanto pasturas implantadas como pastizales naturales de buen desarrollo y verdes de invierno) y 5) no laboreado (engloba a lotes que no evidenciaron manejo alguno durante la presente campaña agrícola). El 50% de las muestras recopiladas en el terreno fue utilizada como polígonos de entrenamiento y 50% restante se empleó en la validación de cada clasificación obtenida (Tabla 2). En el sector central de cada uno de los lotes de las cinco categorías

Tabla 2. Cantidad total de píxeles empleados por categoría para entrenar y para validar cada clasificador utilizado.

	Trigo	Cebada	Cultivos de verano	Uso forrajero	No laboreado
Píxeles de entrenamiento	7735	7431	2174	1580	3697
Píxeles de Validación	6748	6935	2321	1333	3711

involucradas, se delinearon áreas en forma de polígonos irregulares apoyándose visualmente en una imagen satelital Sentinel-2, constituyéndose así los mencionados polígonos de entrenamiento y de validación.

## METODOLOGÍA

### Preprocesamiento de imágenes ópticas y SAR

Las imágenes SAR Sentinel-1A fueron pre procesadas con el software SNAP 6.0, lo que incluyó la creación de una imagen multilook (*Multilooking*), filtrado de ruido speckle, geocodificación y calibración radimétrica. El filtro utilizado fue el Lee, que fue aplicado mediante una ventana de 3 x 3 píxeles para reducir el ruido speckle. Las imágenes SAR fueron remuestreadas a un tamaño de pixel de 20 metros de resolución espacial mediante una interpolación bilineal y los valores obtenidos de coeficiente de retrodispersión sigma cero fueron convertidos a decibelios (dB). Asimismo, se realizó una corrección de las distorsiones geométricas SAR utilizando el Modelo Digital de Elevación (MDE) SRTM 3 sec, que se descarga automáticamente de la web.

En el caso de las imágenes Sentinel-2, las correcciones atmosféricas se realizaron con el software QSIG. En cada una de éstas se calculó el Índice Normalizado de Diferencia de Vegetación (Normalized Difference Vegetation Index – NDVI). Dicho índice es la diferencia normalizada entre dos bandas: rojo e infrarrojo cercano (Rouse *et al.*, 1974). Los valores obtenidos oscilan entre los extremos 1 (vegetación muy densa) y -1 ausencia total de vegetación). Una vez obtenidos los valores de NDVI como bandas para cada fecha utilizada, se las reunió en una sola imagen multibanda (apilado o stacking) sobre la que se aplicaron posteriormente los diferentes métodos de clasificación.

### Atributos específicos

#### Textura

La textura (T) es un parámetro significativo que contribuye a mejorar la precisión en la clasificación de los datos SAR, pudiéndose cuantificar mediante una serie de diferentes medidas estadísticas. Asimismo, ha sido vastamente empleada en

la clasificación de cultivos (Jia *et al.*, 2012; Du *et al.*, 2015; Yayusman y Nagasawa, 2015; Balzter *et al.*, 2015). En este artículo se utilizó la Matriz de Co-Ocurrencia de Nivel Gris - GLCM (Haralick *et al.*, 1973), ampliamente utilizada para obtener entidades de textura. En tal sentido, se extrajeron las siguientes ocho medidas de textura: media, varianza, entropía, segundo momento angular, contraste, correlación, disparidad y homogeneidad.

#### Coherencia

Se denomina coherencia (C) al coeficiente de correlación que explica los pequeños cambios producidos en las distintas superficies (área vegetadas, no vegetadas, rocas, etc.) durante el intervalo de tiempo entre dos adquisiciones de SAR (Parihar *et al.*, 2014). En tal sentido, el uso de los productos en nivel SLC permitió la obtención de este parámetro, ya que contienen información de amplitud y de fase. Los valores de coherencia oscilan entre 0 y 1 y se relacionan con cambios en el píxel. Un coeficiente de coherencia elevado indica que dicho cambio es pequeño, mientras que un coeficiente de coherencia bajo señala un cambio significativo. Para el presente artículo se obtuvieron seis imágenes de coherencia utilizando los siguientes pares de datos SAR para 2017: 1) 6 y 18 de septiembre, 2) 18 de septiembre y 12 de octubre, 3) 12 y 30 de octubre, 4) 30 de octubre y 5 de noviembre, 5) 5 de noviembre y 5 de diciembre y 6) 5 y 29 de diciembre.

### Combinación de atributos

En virtud de lograr la mejor la precisión posible en la discriminación del trigo y de la cebada, se analizó la potencialidad de las diversas variables SAR y de las imágenes ópticas tanto en conjunto como por separado. Para ello, se consideraron diferentes combinaciones de variables (Tabla 3) que fueron identificadas con un número (ID)

### Clasificación

Las diferentes localidades que conforman el partido fueron enmascaradas en forma manual. Por otra parte, las lagunas y los cuerpos de agua de menor magnitud fueron discriminados empleando una clasificación No Supervisada mediante el método Isodata (Datos Auto Asociados Iterativamente).

Tabla 3. Diferentes combinaciones de imágenes SAR y ópticas empleadas para la discriminación de trigo y cebada.

ID	Combinación de bandas	Número de bandas	Tipo de imagen
1	Polarización VV bandas Sentinel-1A	7	SAR
2	Polarización VH bandas Sentinel-1A	7	SAR
3	Polarización dual (VV + VH) bandas Sentinel-1A	14	SAR
4	NDVI de imágenes Sentinel-2	6	Óptica
5	Polarización dual (VV + VH) bandas Sentinel-1A + NDVI de imágenes Sentinel-2	20	SAR + Óptica
6	Coherencia Polarización VV bandas Sentinel-1A	6	SAR
7	Coherencia Polarización VH bandas Sentinel-1A	6	SAR
8	Coherencia Polarización dual (VV+VH) bandas Sentinel-1A	12	SAR
9	Polarización dual (VV + VH) + Coherencia Polarización dual (VV + VH) bandas Sentinel-1A	26	SAR
10	Textura Polarización dual (VV + VH) de bandas Sentinel-1A	112	SAR
11	Polarización dual (VV + VH) + Textura Polarización dual (VV + VH) bandas Sentinel-1A	126	SAR
12	Coherencia Polarización dual (VV + VH) + Textura Polarización dual (VV + VH) de bandas Sentinel-1A	124	SAR
13	Polarización dual (VV + VH) + Coherencia Polarización dual (VV + VH) + Textura Polarización dual (VV + VH) de bandas Sentinel-1A	138	SAR
14	Polarización dual (VV + VH) + Coherencia Polarización dual (VV + VH) + Textura Polarización dual (VV + VH) bandas Sentinel-1A + NDVI de imágenes Sentinel-2	144	SAR + Óptica

Para discriminar cada una de las cinco categorías involucradas en este estudio, se emplearon tres reconocidos clasificadores: el método de Máxima Verosimilitud (Maximum Likelihood - MLC), el de Máquinas de Soporte Vectorial (Support Vector Machines - SVM) y el de Random Forest (RF). Para la clasificación de imágenes se empleó el software SNAP 6.0

Uno de los clasificadores paramétricos más empleados en teledetección ha sido el MLC (Foody *et al.*, 1992; Jia *et al.*, 2012). Este asume una determinada distribución estadística para cada clase valiéndose de un modelo probabilístico en donde las funciones de distribución de probabilidad siguen una distribución normal multivariante cuyos parámetros, vector de medias y matriz de covarianza, se estiman a partir de las muestras de

entrenamiento recopiladas. De esta manera, la clase a la que pertenece un determinado píxel quedará determinada mediante el cálculo de su probabilidad de pertenencia a todas las clases definidas, asignándose a aquella en la que se haya obtenido la máxima probabilidad (Ahmad y Qeegan, 2012).

El SVM, por su parte, es uno de los clasificadores no paramétricos más utilizado en determinación del uso del suelo con imágenes satelitales en virtud de sus muy buenos resultados (Jia *et al.*, 2012; Pal y Foody, 2012). Las máquinas de soporte vectorial fueron originariamente desarrolladas para resolver problemas de clasificación binaria. Consisten en un conjunto de algoritmos de aprendizaje supervisado (Cortes y Vapnik, 1995), actualmente empleado en regresión, agrupamiento o multclasificación. El modo de operar de los SVM es mediante la selec-

ción de un hiperplano de separación equidistante de las muestras de entrenamiento más cercanos de cada clase, obteniéndose un margen máximo a cada lado de este. En el momento de definir dicho hiperplano, se consideran solo los ejemplos de entrenamiento de cada clase que se hallen comprendidos en la frontera de dichos márgenes, y que se denominan vectores soporte (Riobó Otero, 2012; Carmona Suárez, 2016).

Finalmente, se empleó el método Random Forest, basado en un conjunto de árboles de decisión y también aplicado con éxito en problemas de clasificación y regresión (Breiman, 2001). Este algoritmo incorpora la aleatoriedad en la construcción de cada clasificador individual, logrando mejorar la precisión en la clasificación. De hecho, esta técnica produce predicciones altamente precisas y permite manejar un gran número de variables de entrada sin proporcionar sobreajuste. Random Forest introduce aleatoriamente en cada nodo del árbol de decisión un conjunto de variables entre todas las originales y de éstas selecciona la mejor para realizar la partición. Tanto las variables como las reglas de división de los nodos son diferentes para cada árbol, lo que asegura su heterogeneidad, obteniéndose resultados diferentes. Los errores individuales de cada árbol de decisión quedan compensados, ya que la asignación final se realiza por mayoría (Larrañaga Urien, 2016). Este algoritmo requiere principalmente de dos parámetros: el número de variables utilizadas al azar para cada división (variables predictivas) y el número de árboles de clasificación. Para el primer caso, se ha utilizado el valor implementado por defecto por el software SNAP, es decir 5000. En el segundo caso se ha optado por el criterio propuesto por Belgiu y Dragut (2016), quienes han establecido que diversos estudios avalan el número de 500 árboles de decisión como el adecuado para obtener una óptima Precisión Global.

Para evaluar cada clasificación realizada se generó una matriz de confusión, en donde se compara el mapa obtenido de cada una de las clasificaciones de las imágenes satelitales con las verdades de campo. De dicha matriz se deriva la Precisión global (P), que proviene del cociente entre el total de píxeles correctamente clasificados sobre el total de píxeles

correspondientes a las verdades de campo (Jensen, 1986). Los resultados de la clasificación efectuada serán mejores cuanto más cercano al 100% sea el valor de P.

Asimismo, se obtuvieron los valores de F1. Esta medida es considerada aún de mayor significancia que P (Schuster *et al.*, 2015), y emplea los porcentajes de precisión del productor y precisión del usuario derivados de la matriz de confusión. Su fórmula de cálculo es:

$$F1 = 2 * \left( \frac{\text{precisión del productor} * \text{precisión del usuario}}{\text{precisión del productor} + \text{precisión del usuario}} \right)$$

Los valores de F1 oscilan entre 0 y 1. Valores cercanos a 1 indican muy buenos resultados y aquellos cercanos a 0 sugieren pobres resultados. En este trabajo, F1 se ha expresado en porcentaje (%).

## RESULTADOS Y DISCUSIÓN

### Análisis de variables multitemporales obtenidas de datos SAR

La Figura 3 presenta la evolución temporal de los valores de retrodispersión media expresados en decibeles (dB) para cada una de las cinco clases involucradas en este estudio. En líneas generales, los valores de la polarización VH son relativamente menores en comparación con los de VV. No obstante, en esta última polarización las cinco categorías (a excepción de la cebada en la imagen del 12 de octubre) exhiben oscilaciones entre fechas inferiores a 4 dB. La retrodispersión media de VH del trigo y de la cebada disminuye de -20.91 dB y -20.88 dB en la escena del 6 de septiembre a -21.71 dB y -22.77 dB en la del 12 de octubre respectivamente. En el caso de la retrodispersión VV, dicha disminución es más marcada, pasando de -14.68 dB y -15.38 dB en la escena del 6 de septiembre a -18.38 dB y -18.72 dB en la del 12 de octubre. Durante esta primera etapa de crecimiento de ambos cultivos, la principal influencia en la señal del radar es ejercida por el suelo. A medida que dichos cultivos invernales alcanzan su mayor grado de desarrollo, los valores de retrodispersión



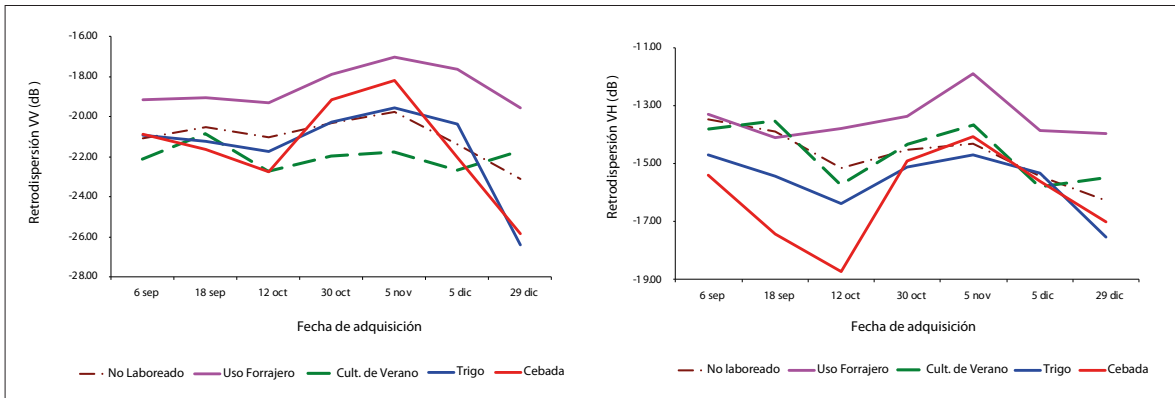


Figura 3. Evolución temporal de los valores de retrodispersión media (dB) para cada una de las cinco clases involucradas en este estudio. Polarizaciones VV y VH. Fuente: elaboración propia.

para ambas polarizaciones comienzan a aumentar, alcanzando sus picos máximos en la imagen del 5 de noviembre. Con el crecimiento gradual del trigo y de la cebada, la densidad de las hojas y de las varillas también aumenta gradualmente, por lo cual la superficie del suelo se cubre de modo uniforme. Por otra parte, la retrodispersión en la polarización VV para ambos cultivos fue mayor que la de VH, porque tanto el trigo como la cebada poseen una estructura vertical que incide más en la primera de dichas polarizaciones durante el proceso de desarrollo. Una vez que ambos cultivos han sido cosechados (imagen del 29 de diciembre), la mayor influencia en la señal del radar vuelve a ser la ejercida por el suelo, especialmente en la polarización VH, menos sensible a la estructura de estas plantas.

La Figura 4 exhibe la serie temporal de los valores medios de coherencia para cada una de las cinco clases involucradas en este estudio. El trigo y la cebada presentan, en líneas generales, los valores de coherencia más bajos de las cinco categorías para ambas polarizaciones. El primero de estos alcanza su mayor valor durante el par de datos del 30 de octubre al 5 de noviembre para la polarización VV (0.28), coincidentemente con su mayor desarrollo. Esto se condice con lo señalado por Blaes *et al.* (2005), quienes encontraron una fuerte correlación entre la altura del trigo de invierno y su valor de coherencia. No ocurre lo mismo con la cebada, cuyo máximo valor de coherencia ocurre durante el par de datos del 5 al 29 de diciembre (0.28). De modo opuesto a los cultivos invernales, los cultivos de verano exhiben los valores de coherencia más ele-




Figura 4. Valores promedio de coherencia para cada una de las cinco clases involucradas en este estudio. Polarizaciones VV y VH. Fuente: elaboración propia.

vados, especialmente en la polarización VV (0.42). Esto último tiene que ver con el escaso cambio experimentado en los lotes de tales cultivos durante esta etapa fenológica (barbecho y siembra) en la que aún no alcanzan su mayor grado de desarrollo.

### Análisis de variables obtenidas de imágenes satelitales ópticas

La Figura 5 muestra la serie temporal del NDVI promedio para cada cobertura terrestre. Como se observa, los valores de NDVI para trigo y cebada se incrementan paulatinamente desde julio a octubre, en donde se observan los valores más elevados (0.74 y 0.69, respectivamente) en correspondencia con su mayor grado de crecimiento. Luego dichos valores disminuyen paulatinamente hasta alcanzar sus mínimos (0.20 y 0.23, respectivamente) durante el período de cosecha. Las tres clases restantes se caracterizan por exhibir menor oscilación a lo largo del ciclo fenológico. Esta diferencia de comportamiento en la evolución de dicho ciclo entre un cultivo y un lote con otro uso de suelo ha sido ampliamente utilizada en la clasificación remota (Karale *et al.*, 2014).

### Clasificación y precisión de imágenes y variables SAR

La precisión general y la medida F1 para las cinco clases involucradas en este estudio utilizando clasificadores MLC, RF y SVM se muestra en la Tabla 4.

En líneas generales, RF es el clasificador que ha obtenido los mejores resultados en comparación a

MLC y SVM, en términos de F1 (Tabla 4). En lo referente a la discriminación de trigo y de cebada, éste también ha resultado el clasificador óptimo. No obstante, todas las medidas de F1 para trigo y cebada que utilizan la polarización única (ID 1 y 2) fueron inferiores al 69.29%. Mejores resultados se obtuvieron de la combinación de las polarizaciones VV y VH (ID 3) que tomando cada polarización por separado (ID 1 y 2). En este caso, los valores de F1 se incrementan a 74.89% para el trigo y 81.93% para la cebada. Esto se debe principalmente a que la suma de dos polarizaciones con diferentes mecanismos de dispersión proporciona información más rica de dispersión de ondas de radar, en este caso en cultivos de invierno, mejorando la precisión de la clasificación.

Con el fin de explorar completamente los datos de Sentinel-1A buscando mejorar la precisión de la clasificación, se incorporaron como nuevas variables la información de textura y coherencia. La Tabla 4 muestra que la precisión de la clasificación en principio no mejora al emplear imágenes de coherencia, tanto para cada polarización por separado (ID 6 y 7) como para la unión de VH y VV (ID 8). Sin embargo, al analizar la imagen de la coherencia aplicada a VV y VH combinada con los valores de dichas polarizaciones por separado (ID 9), los valores de F1 se incrementan. En el caso del trigo, alcanzan el 78.20% y para la cebada el 84.73%, empleando RF. En este sentido, estudios anteriores refieren a mejoras en la clasificación al combinan medidas de intensidad de retrodisper-

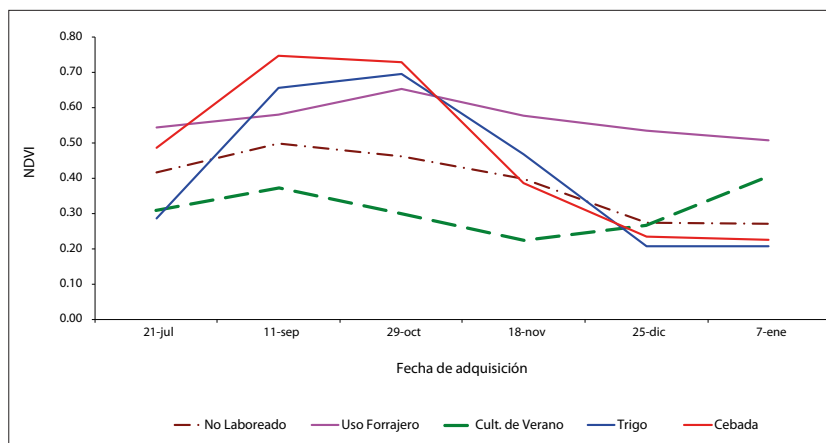


Figura 5. Evolución de los valores de NDVI promedio para cada categoría involucrada en este estudio.

Tabla 4. Precisión Global y medida F1 para 14 combinaciones de imágenes SAR y ópticas utilizando los clasificadores MLC, RF y SVM.

Clasificador	ID	Medida F1					Precisión
		No laboreado	Cultivo de verano	Uso forrajero	Trigo	Cebada	
MLC	1	58.92	59.12	28.20	59.71	73.91	61.21
	2	47.11	78.15	47.21	66.54	65.32	62.60
	3	63.25	80.02	52.61	69.90	76.62	70.76
	4	77.89	91.75	80.86	78.43	79.69	80.62
	5	80.49	94.40	90.58	81.64	78.80	82.81
	6	58.92	59.12	28.20	59.71	73.91	61.21
	7	34.64	26.88	16.54	36.68	49.04	37.73
	8	46.25	48.43	24.18	49.89	64.82	51.26
	9	69.23	83.46	50.51	73.93	81.80	75.34
	10	50.57	76.61	27.76	17.80	67.96	52.79
	11	51.38	77.62	28.12	19.02	68.47	53.50
	12	51.38	77.62	28.13	19.02	68.48	53.50
	13	60.99	80.75	24.07	27.70	69.66	57.93
	14	81.01	95.75	77.68	61.08	71.66	73.91
SVM	1	71.06	20.78	46.38	62.07	76.73	63.86
	2	51.42	47.62	80.89	67.97	67.69	65.47
	3	65.11	51.46	83.73	71.65	78.97	73.11
	4	79.13	90.05	50.01	82.54	80.85	79.16
	5	82.72	87.41	88.34	80.53	81.76	82.86
	6	71.06	20.78	46.38	62.07	76.73	63.86
	7	25.81	7.88	18.72	43.00	50.85	39.93
	8	46.52	23.80	56.91	57.67	68.65	57.34
	9	63.99	57.95	76.60	75.79	81.98	74.65
	10	71.57	63.29	85.10	76.91	80.56	77.17
	11	71.47	61.36	85.24	76.72	80.88	77.12
	12	67.09	64.08	77.70	79.12	83.16	77.07
	13	67.02	63.17	77.84	78.48	82.95	76.75
	14	87.35	84.70	92.87	84.64	85.12	86.35
RF	1	39.06	13.24	50.79	53.81	65.92	52.68
	2	56.42	60.85	81.82	69.26	69.29	68.07
	3	67.11	62.09	82.03	74.89	81.93	75.78
	4	75.44	89.57	25.51	82.95	84.15	77.65
	5	75.06	96.20	33.14	86.48	86.57	80.23
	6	39.20	12.68	50.69	54.13	66.62	52.93
	7	26.54	7.72	16.96	42.42	47.03	37.98
	8	46.90	13.13	55.63	56.68	67.30	56.29
	9	72.25	66.14	81.95	78.20	84.73	78.97
	10	70.21	61.40	82.64	77.90	83.77	77.90
	11	70.54	62.50	82.61	78.26	83.68	78.09
	12	76.25	62.60	84.06	79.16	85.15	80.20
	13	73.53	65.33	82.65	79.74	84.94	79.74
	14	89.66	96.48	90.55	87.27	89.20	89.37

sión con coherencia (Parihar *et al.*, 2014; Sonobe *et al.*, 2015). Cuando a las imágenes de intensidad de retrodispersión se les añadieron las de textura (ID 11), los valores de F1 son similares a los que solo involucran esta última medida (ID 10), obteniéndose valores de F1 de 78.26% para el trigo y 83.68% para la cebada empleando RF (P: 78.09). Del mismo modo, las combinaciones que involucran coherencia y textura (ID 12) arrojan valores de P y F1 análogos a los mencionados, incluso al incorporar la polarización dual (ID 13). Estos resultados corroboran la utilidad tanto de la coherencia como de la textura como parámetros idóneos para la clasificación de datos SAR. En lo referente a la precisión general de la clasificación, los mejores resultados se obtuvieron empleando la combinación de imágenes de coherencia y textura (ID 12), con un valor de P de 80.20.

Cabe acotar que al emplear el clasificador SVM tanto sobre información de textura como en la combinación de datos SAR del ID 13, los resultados obtenidos fueron similares al aplicar el método RF, obteniéndose un valor de F1 levemente superior para el trigo (78.48%) y levemente inferior (82.95%) para la cebada (P: 76.75). Los resultados hasta aquí expuestos, tanto para los clasificadores RF como SVM, indican que los datos SAR por sí solos cumplen aceptablemente los requisitos de precisión de clasificación para cultivos de invierno. Aunque con ciertas limitaciones, estos pueden reemplazar el uso de imágenes ópticas. Para el resto de las otras tres categorías involucradas, el

clasificador RF también fue el más eficaz utilizando la combinación ID 12 para discriminar las clases uso forrajero (F1: 84.06%) y no laboreado (F1: 76.25%). Por su parte, los cultivos de verano exhiben en todos los casos valores de F1 inferiores a los de las dos clases mencionadas, alcanzando su máximo valor de F1 en la combinación ID 13 (65.33%). Los mejores resultados para los cultivos estivales empleando dicha combinación de datos se obtuvieron utilizando MLC (80.75%), aunque los valores de la clasificación general fueron muy pobres (P: 57.93). La dificultad de discriminar tales cultivos guarda relación con el escaso grado de desarrollo que los mismos alcanzan durante esta etapa fenológica. En este caso, y a diferencia de lo que ocurre con los cultivos de invierno, el SAR no es sensible a cambios en la estructura morfológica (Gao *et al.*, 2018).

#### Clasificación y evaluación de la clasificación empleando imágenes satelitales ópticas

La clasificación empleando solo imágenes ópticas (ID 4) aplicando el NDVI arrojó mejores resultados que las imágenes SAR solas, a pesar de que el trigo y la cebada poseen ciclos fenológicos similares. No obstante, la mayor separabilidad entre dichos cultivos de produce durante el período de su máximo desarrollo (Figura 6). También se aprecia, a diferencia de las imágenes de radar, que los tres métodos empleados exhiben resultados similares. En lo que a la clasificación general se refiere, los valores de P oscilan entre 77.65% para el método

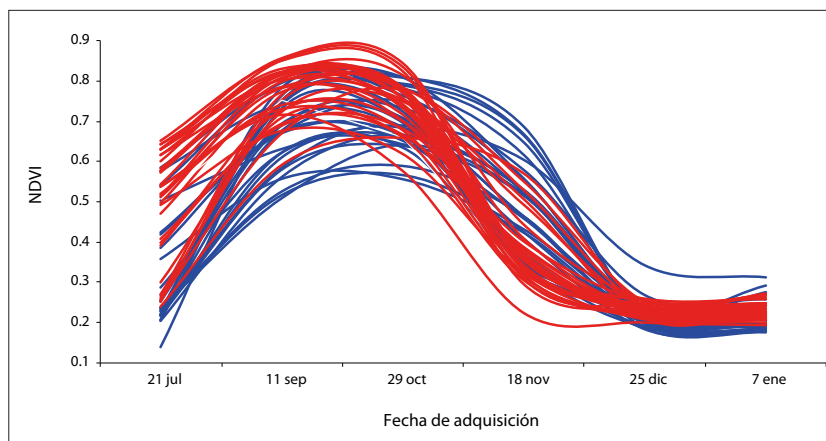


Figura 6: Evolución del NDVI para diversos lotes de trigo (en azul) y de cebada (en rojo) en el partido de Coronel Rosales, campaña 2017. Fuente: elaboración propia.

RF y 80.62% aplicando MLC. En cuanto a la separabilidad de ambos cultivos de invierno, los tres métodos empleados también presentan resultados análogos. No obstante, el mejor algoritmo que separa los cultivos de invierno es RF, con un valor de F1 de 82.95% para el trigo y de 86.57% para la cebada.

### Clasificación empleando datos SAR e imágenes ópticas

La precisión de la clasificación de los cultivos de invierno utilizando la combinación ID 5, es decir VV y VH de datos SAR junto a la información de los datos ópticos (apilado de NDVI) mejoró con respecto a la de estos últimos por sí solos, con valores de F1 de 86.48% para el trigo y de 86.57% para la cebada empleando el método RF. Del mismo modo, la precisión general de la clasificación también supera al valor para las imágenes ópticas multitemporales, especialmente al aplicar SVM, aumentando del 79.19% al 82.86%. Para el resto de las clases también mejoraron las precisiones de clasificación, en particular en el caso de los cultivos de verano, que alcanzaron un valor de F1 de 96.20% aplicando RF. En el caso de la categoría uso forrajero, el máximo valor de F1 para esta combinación de datos se registra empleando MLC (90.58%), mientras que los lotes no laboreados han sido discriminados mejor con SVM (F1: 82.98%). Estos resultados corroboran diversos estudios previos en donde también se ha demostrado que la precisión de la clasificación podría mejorarse cuando se combinan las imágenes SAR con las ópticas (Blanes et al., 2005; Mc Nairn et al., 2009; Ban y Jacob, 2013; Skakun et al., 2015). En tal

sentido, Zhou et al. (2017) señalan que la razón podría deberse a que mientras las imágenes ópticas contienen abundante información espectral, los datos SAR aportan más información de textura espacial. De esta manera, la combinación de ambas imágenes compensaría los defectos de cada una de ellas en la identificación de cultivos, mejorando la precisión de la clasificación.

Finalmente, se llevó a cabo una clasificación sobre una combinación integral (ID 14) que involucra los datos SAR del ID 13 sumados a la información de NDVI de las imágenes ópticas (ID 4). Como se muestra en la Tabla 4, la precisión de la clasificación tanto para el trigo como para la de cebada, es la más elevada de todas las clasificaciones efectuadas. Esto se verifica empleando el algoritmo RF, con valores de F1 de 87.27% para el trigo y de 89.20% para la cebada. Debido a que esta clasificación fue la que mejores resultados obtuvo, su correspondiente matriz de confusión se exhibe en la Tabla 5.

Aunque en menor medida, el método SVM obtiene valores de F1 ligeramente inferiores para ambos cultivos invernales (84.64% y 85.12% para trigo y cebada, respectivamente). Para el resto de las categorías, ambos logaritmos muestran óptimos resultados, reflejados en porcentajes de F1 que superan el 84%. En tal sentido, los cultivos de verano alcanzan un 96.48% empleando RF sobre esta combinación de datos. La clasificación resultante de emplear el método RF sobre la combinación integral de datos SAR e imágenes ópticas (ID 14) se muestra en la Figura 7.

De los resultados expuestos se evidencia que la combinación de imágenes ópticas y SAR multi-

Tabla 5. Matriz de confusión de la clasificación realizada sobre una combinación integral (ID 14) empleando el clasificador RF.

Clase	No laboreado	Uso forrajero	Cultivo de verano	Trigo	Cebada
No laboreado	87.72	2.40	0.95	4.30	3.37
Uso forrajero	0,00	96.77	0.56	0.80	4.94
Cultivo de verano	8.53	0,00	98.49	0,00	0,00
Trigo	0,00	0,00	0,00	90.34	6.97
Cebada	3.75	0.83	0,00	4.56	84.72
Total	100.00	100.00	100.00	100.00	100.00

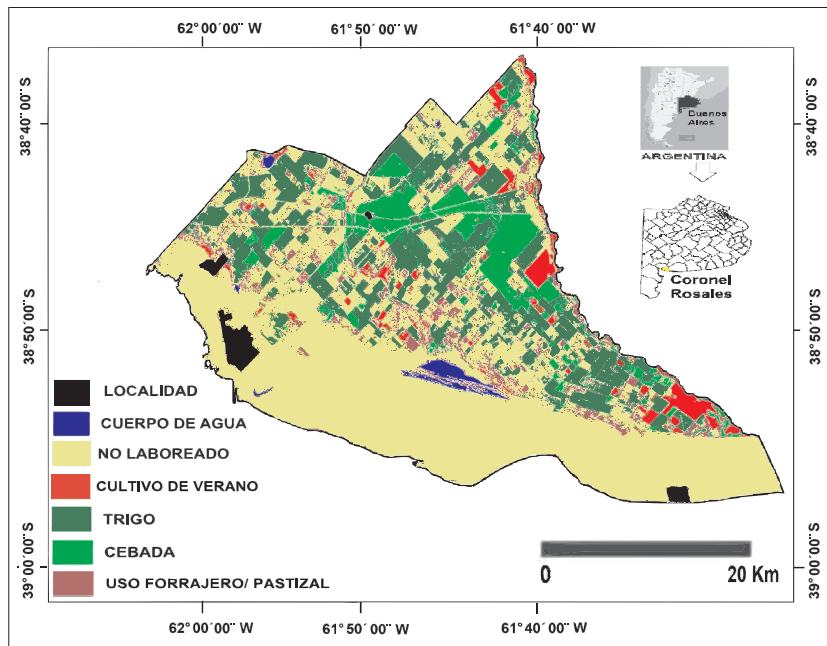


Figura 7. Clasificación resultante de emplear el método RF sobre una combinación integral de datos SAR e imágenes ópticas (NDVI) en el partido de Coronel Rosales. Fuente: elaboración propia a partir de dichas imágenes satelitales.

temporales mejora la precisión de la discriminación de cultivos. De hecho, algunos autores señalan que cuando dicha precisión es superior al 85%, la clasificación del cultivo es confiable (Foody, 2002; De Wit y Clevers, 2004; Skakun *et al.*, 2015). Esto último ha podido corroborarse en el presente estudio al emplear dicha combinación de datos, reforzando la potencialidad de las imágenes SAR en la mejora de la precisión de la clasificación. Asimismo, las imágenes de radar no solo se erigen como sustituto de imágenes las ópticas, sino también como una fuente de datos suplementaria, especialmente cuando la presencia de nubes imposibilita la adquisición de imágenes ópticas (Chen y Pei, 2007; Jia *et al.*, 2012).

## CONCLUSIONES

En líneas generales, los resultados obtenidos en este trabajo corroboran que el empleo de datos multitemporales que involucren la combinación de imágenes ópticas y SAR es idóneo para la discriminación de cultivos. En tal sentido y de manera específica, se evidencian las siguientes consideraciones finales:

1. De los tres algoritmos de clasificación empleados, RF obtuvo los mejores resultados para la discriminación de trigo y cebada. Esto también es válido para las clasificaciones generales, tal como se desprende de los valores de Precisión Global.
2. Quedó demostrado que el uso de datos SAR del satélite Sentinel-1A permitió discriminar de manera óptima los cultivos de invierno. La combinación VV + VH + C+ T (ID 13) arrojó los mejores resultados para el trigo (F1: 79.74%) y la combinación C + T (ID 12) resultó la más idónea para separar la cebada (F1: 84.94%). De esto último se desprende que la combinación de imágenes de coherencia, textura y retrodispersión mejoran la precisión de la clasificación. Asimismo, tales resultados corroboran que los datos ópticos pueden ser reemplazados por imágenes Sentinel-1A cuando las escenas de los primeros se vean limitadas por la presencia de nubes.
3. La clasificación utilizando imágenes ópticas (ID 4 - apilado de imágenes de NDVI) obtuvo óptimos resultados empleando el método MLC (P: 80.62%). En cambio, para la discriminación de cultivos de invierno, los valores

más elevados de F1 se obtuvieron aplicando el método RF (82.95% para trigo y 84.16% para cebada).

4. Los mejores resultados de todas las clasificaciones llevadas a cabo se obtuvieron al combinar imágenes ópticas y SAR. En tal sentido, la combinación de todas las imágenes SAR (VV + VH + C+ T) con el apilado de NDVI (ID 14) arrojó los máximos valores de Precisión Global (89.37%).
5. En el caso particular de la discriminación de cultivos de invierno, también la combinación de datos Sentinel-1A con datos ópticos resultó la más precisa. Para la cebada, la combinación VV + VH + C+T+ NDVI (ID 14) obtuvo valores de F1 de 87.27% para el trigo y de 89.20% para la cebada empleando el algoritmo RF.

## REFERENCIAS

- Ahmad, A. y Quegan, S. (2012). Analysis of Maximum Likelihood classification technique on Landsat 5 TM satellite data of tropical land covers. *Proceedings - IEEE International Conference on Control System, Computing and Engineering*, 280-285. DOI: 10.1109/ICCSCE.2012.6487156.
- Álamo, M. y Garabito, C. (2012). Cambios socio-territoriales en el espacio rural del partido de Coronel Rosales en los últimos años. *Actas Primeras Jornadas Nacionales del Ambiente*, Ed. Facultad de Ciencias Humanas (UNICen), Tandil, 433-446.
- Balzter, H., Cole, B., Thiel, C. y Schmullius, C. (2015). Mapping CORINE Land Cover from Sentinel-1A SAR and SRTM Digital Elevation Model Data using Random Forests. *Remote Sensing*, 7, 14876-14898. DOI: 10.3390/rs71114876.
- Ban, Y. y Jacob, A. (2013). Object-Based Fusion of Multitemporal Multiangle ENVISAT ASAR and HJ-1B Multispectral Data for Urban Land-Cover Mapping. *IEEE Trans. Geoscience Remote Sensing*, 51(4). DOI: 10.1109/TGRS.2012.2236560.
- Belgiu, M. y Dragut, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sensing*, 114, 24-31. DOI: 10.1016/j.isprsjprs.2016.01.011
- Blaes, X., Vanhalle, L. y Defourny, P. (2005). Efficiency of crop identification based on optical and SAR image time series. *Remote Sensing Environment* 96, 352-365. DOI: 10.1016/j.rse.2005.03.01
- Breiman, L., (2001): Random forests. *Machine Learning*, 45:5-32. DOI: 10.1023/A:1010933404324
- Carmona Suárez, E. (2016): *Tutorial sobre Máquinas de Vectores Soporte (SVM)*. Dpto. de Inteligencia Artificial, ETS de Ingeniería Informática, Universidad Nacional de Educación a Distancia (UNED), Madrid, España. Disponible en [https://www.researchgate.net/publication/263817587\\_Tutorial\\_sobre\\_Maquinas\\_de\\_Vectores\\_Soporte\\_SVM](https://www.researchgate.net/publication/263817587_Tutorial_sobre_Maquinas_de_Vectores_Soporte_SVM)
- Chen, J., Lin, H. y Pei, Z. (2007). Application of ENVISAT ASAR Data in Mapping Rice Crop Growth in Southern China. *IEEE Geoscience Remote Sensing Letters*, 4, 431-435. DOI: 10.1080/01431160802609700
- Chen, S.W., Li, Y.Z. y Wang, X.S. (2015). Crop discrimination based on polarimetric correlation coefficients optimization for PolSAR data. *International Journal of Remote Sensing*, 36, 4233-4249. DOI: 10.1080/01431161.2015.1079345
- Cortes, C. y Vapnik, V. (1995). Support vector networks. *Machine Learning*, 20:273-297. DOI: 10.1007/BF00994018
- De Wit, A.J.W. y Clevers, J.G.P.W. (2004). Efficiency and accuracy of per-field classification for operational crop mapping. *Int. J. Remote Sensing*, 25, 4091-4112. DOI: 10.1080/01431160310001619580
- Du, P.J., Samat, A., Waske, B., Liu, S.C. y Li, Z.H. (2015). Random Forest and Rotation Forest for fully polarized SAR image classification using polarimetric and spatial features. *ISPRS J. Photogramm. Remote Sensing*, 105, 38-53. DOI: 10.1016/j.isprsjprs.2015.03.002
- European Space Agency (ESA). (2013). *Technical Guides Sentinel-1 SAR*. <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-1-sar/sar-instrument/acquisition-modes>
- Foody, G.M., Campbell, N.A., Trodd, N.M. y Wood, T.F. (1992): Derivation and applications of probabilistic measures of class membership from the maximum-likelihood classification. *Photogrammetric Engineering and Remote Sensing*, 58: 1335-1341. DOI: 10.1007/BF02990835.
- Foody, G.M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing Environment*, 80, 185-201. DOI: 10.1016/S0034-4257(01)00295-4.
- Gao, H., Wang, C., Wang, G., Zhu, J., Tang, Y., Shen, P., y Zhu, Z. (2018). A Crop Classification Method Integrating GF-3 PolSAR and Sentinel-2A Optical Data in the Dongting Lake Basin. *Sensors* (Basel, Switzerland), 18(9), 3139. DOI: 10.3390/s18093139
- Haralick, R.M., Shanmugam, K. y Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, pp. 610-621. DOI: 10.1109/TSMC.1973.4309314.

- INDEC - Instituto Nacional de Estadísticas y Censos. (2011). *Censo 2010*. En [https://www.indec.gov.ar/ftp/cuadros/poblacion/censo2010\\_tomo1.pdf](https://www.indec.gov.ar/ftp/cuadros/poblacion/censo2010_tomo1.pdf).
- INTA - INSTITUTO NACIONAL DE TECNOLOGÍA AGROPECUARIA. (1989). *Mapa de Suelos de la Provincia de Buenos Aires*. Buenos Aires. Instituto de Suelos - INTA. 525 pp.
- Jensen, J.R. (1986). *Introductory digital image processing*. New Jersey, Prentice-Hall, 379 pp.
- Jia, K., Li, Q.Z., Tian, Y.C., Wu, B.F., Zhang, F.F. y Meng, J.H. (2012). Crop classification using multi configuration SAR data in the North China Plain. *International Journal of Remote Sensing*, 33: p. 170–183. DOI: 10.1080/01431161.2011.587844.
- Jiao, X., Kovacs, J.M., Shang, J., Mc Nairn, H., Walters, D., Ma, B. y Geng, X. (2014). Object-oriented crop mapping and monitoring using multi-temporal polarimetric RADARSAT-2 data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 96, 38-46. DOI: 10.1016/j.isprsjprs.2014.06.014.
- Karale, Y., Mohite, J. y Jagyasi, B. (2014). Crop Classification Based on Multi-Temporal Satellite Remote Sensing Data for Agro-Advisory Services. *Asia-Pacific Remote Sensing*. 9260, 926004. DOI: 10.1117/12.2069278.
- Kenduiwo, B.K., Bargiel, D. y Soergel, U. (2018). Crop-type mapping from a sequence of Sentinel-1 images. *International Journal Remote Sensing*, 39, 6383-6404. DOI: 10.1080/01431161.2018.1460503.
- Larrañaga Urien, A. (2016): *Clasificación de cultivos a partir de observaciones de teledetección radar. Aplicación a zonas de secano y regadío de Navarra*. Tesis Doctoral. Programa de Doctorado en Ingeniería y Arquitectura. Ediciones Universidad Pública de Navarra, España, 105 pp.
- Loosvelt, L., Peters, J., Skriver, H., Lievens, H., Van Coillie, F., De Baets, B. y Verhoest, N. (2012). Random Forests as a tool for estimating uncertainty at pixel-level in SAR image classification. *International Journal of Applied Earth Observation and Geoinformation*, 19, 173-184. DOI: 10.1016/j.jag.2012.05.011.
- Marini, M.F. (2016): Mapeo y discriminación de cultivos de verano en el partido de Coronel Suárez empleando imágenes satelitales Landsat 8 OLI. *Actas del Octavo Congreso de la Ciencia Cartográfica- Instituto Geográfico Nacional*. Capital Federal. 2 al 4 de noviembre.
- Marini M.F. y Ángeles, G.R. (2016). Discriminación de diferentes cultivos de verano en el partido de Guaminí utilizando imágenes satelitales Landsat 8 OLI. *Terceiras Jornadas de Tecnología de Información Geográfica del Sur Argentino*. Bahía Blanca, Argentina. 24-26.
- Mc Nairn, H., Champagne, C., Shang, J., Holmstrom, D. y Reichert, G. (2009). Integration of optical and Synthetic Aperture Radar (SAR) imagery for deliv-
- ering operational annual crop inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64, 434-449. DOI: 10.1016/j.isprsjprs.2008.07.006.
- Mc Nairn, H. y Shang, J.A. (2016). Review of Multitemporal Synthetic Aperture Radar (SAR) for Crop Monitoring. *Multitemporal Remote Sensing*, Switzerland, pp. 317-340. DOI: 10.1007/978-3-319-47037-5\_15.
- Pal, M. y Foody, G.M. (2012). Evaluation of SVM, RVM & SMLR for accurate image classification with limited ground data. *Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5: p. 1344-1355. DOI: 10.1109/JSTARS.2012.2215310.
- Parihar, N., Das, A., Rathore, V.S., Nathawat, M.S. y Mohan, S. (2014). Analysis of L-band SAR backscatter and coherence for delineation of land-use/land-cover. *International Journal Remote Sensing*, 35, 6781–6798. DOI: 10.1080/01431161.2014.965282.
- RADAR - Red Agroeconómica de Administración de Recursos, (2001): *Zonas Agroecológicas de RADAR*, Boletines Informativos N° 6 a 9. Edición del Convenio INTA - Bolsa de Cereales y Cámara Arbitral de Cereales de Bahía Blanca.
- Riobó Otero, V. (2012): *Reconocimiento de localizaciones mediante Máquinas de Soporte Vectorial*. Proyecto fin de carrera. Escuela Politécnica Superior Ingeniero Industrial. Universidad Carlos III, Madrid. Disponible en <https://core.ac.uk/download/pdf/30046270.pdf>
- Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W. y Harlan, J.C. (1974): *Monitoring the vernal advancement of retrogradation of natural vegetation*. NASA/OSFC. Final Report. Oreenbello MD, 371 pp.
- Saldungaray, C., Adúriz, M. y Conti, V., (2012). *Caracterización del sector agropecuario de los Partidos de Bahía Blanca y Coronel Rosales*. Ed. Dto. de Agronomía (UNS), Bahía Blanca, 49 p.
- Schmullius, C., Thiel, C., Pathe, C. y Santoro, M. (2015). Radar time series for land cover and forest mapping. *Remote Sensing Digital Image Analysis*, 22, 323–356. DOI: 443.webvpn.fjmu.edu.cn/10.1007/978-3-319-15967-6\_16.
- Schuster, C., Schmidt, T., Conrad, C., Kleinschmit, B. y Forster, M. (2015). Grassland habitat mapping by intra-annual time series analysis—Comparison of RapidEye and TerraSAR-X satellite data. *International Journal of Applied Earth Observation and Geoinformation*, 34, 25–34. DOI: 10.1016/j.jag.2014.06.004.
- Skakun, S., Kussul, N., Shelestov, A.Y., Lavreniuk, M. y Kussul, O. (2015). Efficiency Assessment of Multi-temporal C-Band Radarsat-2 Intensity and Landsat-8 Surface Reflectance Satellite Imagery for Crop Classification in Ukraine. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9, 1–8. DOI: 10.1109/JSTARS.2015.2454297.



- Skriver, H., Mattia, F., Satalino, G., Balenzano, A., Pauwels, V.R.N., Verhoest, N.E.C. y Davidson, M. (2011). Crop Classification Using Short-Revisit Multitemporal SAR Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4, 423-431. DOI: 10.1109/JSTARS.2011.2106198.
- Sonobe, R., Tani, H., Wang, X., Kobayashi, N. y Shimamura, H. (2015). Discrimination of crop types with TerraSAR-X-derived information. *Physics and Chemistry of the Earth A/B/C*, 83-84, 2-13. DOI: 10.1109/JSTARS.2011.2106198.
- Valles, S. y Silva Busso, A. (2016). Aspectos hidrogeológicos de la zona costera entre pehuén-co y punta alta, provincia de buenos aires. *IX Congreso Argentino de Hidrogeología y VII Seminario Hispano-Latinoamericano Sobre Temas Actuales de la Hidrología Subterránea*. Catamarca, Argentina, 177 pp.
- Vázquez, P., Masuelli, S. y Platzcek, G. (2006). *Determinación de patrones espectrales para distintos usos del suelo en ambientes heterogéneos*. Publicación Técnica / Instituto Nacional de Tecnología Agropecuaria. Centro Regional Buenos Aires Sur. Estación Experimental Agropecuaria Cuenca del Salado. 34 p.
- Veloso, A., Mermoz, S., Bouvet, A., Toan, T.L., Planells, M., Dejoux, J.F. y Ceschia, E. (2017). Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sensing Environment*, 199, 415-426. DOI: 10.1016/j.rse.2017.07.015.
- Volante, J. N., Bianchi, A. R., Paoli, H. P., Noé, Y., Elena, H. J, y Cabral, C. M. (2006). *Análisis de la dinámica del uso del suelo agrícola del Noroeste Argentino mediante teledetección y Sistemas de Información Geográfica*. Período 2000-2005. Instituto Nacional de Tecnología Agropecuaria (ed) Salta, Argentina, 70 p.
- Whelen, T. y Siqueira, P. (2018). Time-series classification of Sentinel-1 agricultural data over North Dakota. *Remote Sensing Letters*, 9, 411-420. DOI: 10.1080/2150704X.2018.1430393.
- Xu, L., Zhang, H., Wang, C., Zhang, B. y Liu, M. (2019). Crop Classification Based on Temporal Information Using Sentinel-1 SAR Time-Series Data. *Remote Sensing*, 11, 53. DOI: 10.3390/rs11010053.
- Yayusman, L.F. y Nagasawa, R. (2015). ALOS-Sensor data integration for the detection of small holders oil palm plantation in Southern Sumatra, Indonesia. *Journal of the Japanese Agricultural Systems Society*, 31, 27-40. DOI: 10.14962/JASS.31.2\_27.
- Zhou, T., Pan, J., Zhang, P., Wei, S. y Han, T. (2017). Mapping Winter Wheat with Multi-Temporal SAR and Optical Images in an Urban Agricultural Region. *Sensors*, 17(6):1210. DOI: 10.3390/s17061210.