

## DIFERENCIACIÓN DE PLANTACIONES FORESTALES EN ENTRE RÍOS (ARGENTINA): COMPARACIÓN DE MÉTODOS DE CLASIFICACIÓN APLICADOS A IMÁGENES SENTINEL-2 Y LANDSAT-8.

EVANGELINA GABRIELA AVOGADRO Y JOAN CRISTIAN PADRÓ GARCIA<sup>1</sup>

<sup>2</sup>Departamento de Geografía, Universitat Autònoma de Barcelona  
Campus de Bellaterra, Edifici B, Carrer de la Fortuna, s/n, 08193 Bellaterra, Catalunya,  
España.

[evangelinaavogadro@gmail.com](mailto:evangelinaavogadro@gmail.com), [JoanCristian.Padro@uab.cat](mailto:JoanCristian.Padro@uab.cat)

### RESUMEN

En Argentina las áreas forestales planificadas en parcelas con fines comerciales alcanzan 1.2 millones de hectáreas. En este estudio se plantea si la clasificación automática (CA) de imágenes de los sensores MSI (*MultiSpectral Imager*) de Sentinel-2 (S2) y OLI (*Operational Land Imager*) de Landsat-8 (L8) puede ser suficientemente exacta y fiable para identificar dos de los tipos de plantaciones más comunes en el departamento de Concordia (Entre Ríos, Argentina), los correspondientes a *Eucalyptus* y a *Pinus*, así como para identificar también sus superficies ya cosechadas. Se analizó qué combinación de CA y sensor es mejor y cuáles son las características espaciales y/o espectrales de S2 y L8 que pueden dar lugar a diferencias en la CA. Se compararon tres métodos de CA: supervisado paramétrico (mínima distancia euclidiana), supervisado no paramétrico (kNN) y no supervisado (IsoData Híbrido). El kNN, con Acierto Global de 91.4 % para S2, es el más preciso, debido principalmente a que es menos sensible a la variabilidad interna de las parcelas y porque es capaz de discriminar mejor dos categorías muy parecidas espectralmente. Se concluye que la CA es una herramienta con un alto grado de exactitud y fiabilidad que la convierte en útil para ser complementaria a la fotointerpretación. La resolución espectral y espacial de MSI no aporta una mejora relevante en la CA.

Palabras clave: MSI, OLI, MPF, INPF, fotointerpretación, clasificación automática.

Recibido: 15/05/2019

Aceptada versión definitiva: 28/12/2019

Editor al cargo: Dr. Pere Serra

Attribution-NonCommercial-NoDerivatives 4.0 International (CC BY-NC-ND 4.0)

© Los autores  
[www.geofocus.org](http://www.geofocus.org)

## COMPARISON OF CLASSIFICATION METHODS APPLIED TO SENTINEL-2 AND LANDSAT-8 IMAGES FOR THE DIFFERENTIATION OF FOREST PLANTATIONS IN ENTRE RÍOS, ARGENTINA.

### ABSTRACT

In Argentina, the forest plantations reach 1.2 million hectares. It is considered if the image automatic classification (CA) of the sensors MSI (MultiSpectral Imager) from Sentinel-2 (S2) and OLI (Operational Land Imager) from Landsat-8 (L8) can be accurate and reliable to identify two of the most common types of plantations in the department of Concordia (Entre Ríos, Argentina), those of *Eucalyptus* and those of *Pinus*, also considering the areas already harvested. It was analyzed which combination of CA and sensor is better, and which are spatial and/or spectral characteristics of S2 and L8 that explain these differences. The study area was the department of Concordia (Entre Ríos, Argentina). Three CA methods were compared: supervised parametric (minimum Euclidean distance), supervised nonparametric (kNN) and unsupervised (Hybrid IsoData). The kNN, with an Overall Accuracy of 91.4 % for S2 is the most accurate method, mainly because it is less sensitive to the internal variability of the plots and because it is able to discriminate better two very similar categories spectrally. It is concluded that the CA is a tool with a high degree of accuracy and reliability that makes it useful to be complementary to photointerpretation. The spectral and spatial resolution of MSI does not provide a relevant improvement in the CA.

Keywords: MSI, OLI, MFP, INPF, photointerpretation, automatic classification.

### 1. Introducción

En Argentina, la superficie del territorio forestada con fines productivos se estima en 1.2 millones de hectáreas teniendo como principales especies de cultivo los géneros *Pinus* L., *Eucalyptus* L'Hér, *Salix* L. y *Populus* L. (MINAGRO, 2016). Es la región mesopotámica, ubicada al noreste del país e integrada por las provincias de Misiones, Corrientes y Entre Ríos la zona núcleo de las especies forestales de rápido crecimiento (Frangi *et al.*, 2015), representando estas cerca del 80 % de las plantaciones forestales del país, con una total de 900 000 ha destinadas a esta actividad (IEA, 2016).

El sector forestal representa más del 1 % del Producto Interno Bruto (PIB) nacional y genera más de medio millón de empleos directos e indirectos (AFOA, 2012). Además, este sector cuenta con un gran potencial debido a la variedad de climas y suelos aptos, lo que permite obtener un rendimiento de las plantaciones forestales superior a la media mundial, y la capacidad de expandirse sin competir con otras actividades (Maslatón, 2011).

Un aspecto importante para entender la cadena foresto-industrial en Argentina es el relativo a la política pública nacional vinculada a la promoción forestal. Esta, vigente desde hace más de 60 años, ha permitido que la extracción de madera de los bosques implantados se duplicara en el período 1986-2011 (Idígoras, 2016). Un hecho trascendental se presenta en la década de 1970 con

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

---

la sanción de la Ley 21.695 de Crédito Fiscal, que sirvió como instrumento de promoción de las plantaciones a través de subsidios.

En el año 1998 se sanciona la Ley 25.080 de Inversiones para Bosques Cultivados, dirigida a fomentar la forestación y reforestación en áreas no ocupadas por bosques nativos, otorgando un tratamiento fiscal más favorable y subvenciones para el establecimiento de plantaciones (Zanetti *et al.*, 2017). La duración inicial de este instrumento del Estado fue pensado a 10 años, siendo prorrogada a través de la Ley 26.432 en el 2008 por otra década.

Durante el mes de diciembre de 2018, se sancionó la Ley 27.487 de prórroga y modificación de la Ley 25.080 por una nueva década, otorgando así sus beneficios hasta el año 2028. Entre los fundamentos para su prórroga se tuvo en consideración que la Argentina se adhirió al Acuerdo de París sobre Cambio Climático, en el cual el país se comprometió a lograr un patrimonio forestal de 2 millones de hectáreas para el año 2030 (ASORA, 2019).

## 2. Estado de la cuestión

A mediados de la década de 1990, en el ámbito de la Dirección de Producción Forestal (DPF), se conformó el *Área de Sistema de Información Geográfica (SIG) e Inventario Forestal* cuyo principal objetivo fuera el de monitorear las plantaciones forestales en todo el territorio nacional en el marco de la Ley 25.080. Por otro lado, el área fue la responsable de recibir y auditar la información generada en el Primer Inventario Nacional de Plantaciones Forestales y Establecimiento de un Banco de Datos (SSDFI, 2017). Toda la información recabada permitió proyectar la generación del actual Mapa de Plantaciones Forestales (MPF), cuyos principales objetivos son: (i) Identificar las plantaciones forestales existentes en el país y cuantificar su superficie y (ii) Disponer anualmente de una cobertura digital de plantaciones forestales que sirva de base para ejecutar inventarios tanto a nivel nacional como provincial (ASIF, 2018).

A partir de los lineamientos planteados en el artículo titulado "Aplicación de un Sistema de Información Geográfica para la ubicación y cuantificación de plantaciones forestales de *Eucalyptus* sp. y *Pinus* sp. en el Departamento de Concordia de la provincia de Entre Ríos" Clemente *et al.* (1997) y considerando la experiencia en reconocimiento de elementos patrones por parte de los operarios, se decidió implementar la metodología de fotointerpretación para la generación del MPF.

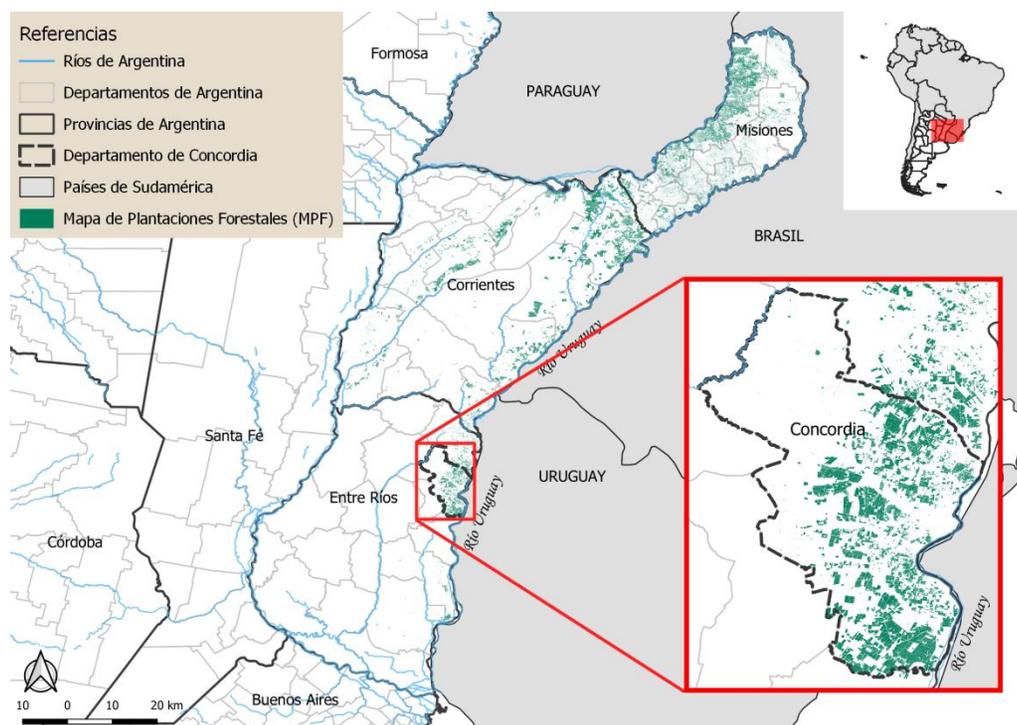
La fotointerpretación es un conjunto de técnicas visuales de análisis de una imagen empleadas para extraer información. Estas técnicas consisten en la observación del tono, la textura, la forma, las dimensiones, la ubicación y el contexto espacial, la disposición y orientación de los elementos, entre otros (Pons & Arcalís, 2012). La principal ventaja del análisis visual de imágenes, en relación con el análisis digital, es la capacidad de incorporar a la interpretación criterios "inteligentes", aprovechando los conocimientos, experiencias, cultura, sentido común, etc. del fotointérprete a la vez que obtiene buenos resultados con clases heterogéneas (bosques mixtos, urbanizaciones, etc.).

Por otra parte, los datos obtenidos de la teledetección se utilizan ampliamente en la generación de cartografía de la superficie terrestre a través de una variedad de enfoques de clasificación "análisis digital". Las técnicas de clasificación agrupan píxeles para mapear regiones

cartográficas basadas principalmente en características espectrales, luego la exactitud de dicho proceso se debe calcular para evaluar la aptitud de los datos obtenidos y la calidad de la clasificación (Yu *et al.*, 2008).

La implementación de imágenes satelitales para la generación de cartografía, con el fin de identificar aptitudes del suelo y en particular vinculada a la actividad forestal, no es una técnica reciente y su uso tiene aplicación a nivel mundial como lo menciona Moré *et al.* (2005). En el último quinquenio, y a partir del trabajo realizado por Hansen *et al.* (2013), es posible acceder a una serie temporal de Landsat que permite caracterizar la extensión y el cambio que los bosques han sufrido (nativos e implantados) desde el año 2000 a nivel global, lo cual significó un gran impacto en las técnicas de cartografía con datos abiertos y gratuitos que facilitan el acceso a la información.

Como se mencionó en párrafos anteriores, en Argentina el MPF fue planteado a partir de lo establecido por Clemente *et al.* (1997). Los avances en estas últimas dos décadas en materia satelital, particularmente en la capacidad de los sensores para diferenciar coberturas terrestres, plantea la inquietud si estos avances permiten representar de manera más eficiente la verdad terreno en la cartografía temática, de ahí la importancia del presente trabajo.



**Figura 1. Mapa de Plantaciones Forestales (MPF) de Argentina destacando el Departamento de Concordia, en la provincia de Entre Ríos.**

La hipótesis que surge es si la clasificación automática de imágenes captadas por los sensores MSI (*MultiSpectral Imager*) de Sentinel-2 (S2) y OLI (*Operational Land Imager*) de Landsat-8 (L8) pueden constituir una herramienta precisa y fiable para la identificación de las

existencias de plantaciones forestales, complementaria a la fotointerpretación empleada actualmente para la generación de la cartografía del MPF. Mientras que los objetivos son: (i) Determinar qué combinación de método de clasificación y sensor es el más preciso para diferenciar plantaciones forestales en el departamento de Concordia, Entre Ríos; (ii) Determinar cuáles son las características espaciales y/o espectrales de los sensores que pueden dar lugar a diferencias en la cartografía temática resultado de la CA.

### 3. Materiales y métodos

#### 3.1. Área de estudio

El área continental de la provincia de Entre Ríos constituye uno de los principales núcleos forestales de Argentina, con una superficie de bosques cultivados de 145 000 ha concentradas principalmente sobre una faja de 20 km de ancho al oeste del Río Uruguay, donde la especie preponderante es *Eucalyptus grandis* W. Hill ex Maiden (Ramilo *et al.*, 2015) y en menor medida *Eucalyptus dunni* Maiden, *Pinus elliottii* Engelm., *Pinus taeda* L. y *Eucalyptus globulus* Labill. (Díaz & Tesón, 2001).

El departamento de Concordia (Figura 1), lugar donde se llevó a cabo éste estudio, se caracteriza por concentrar más del 49 % de la producción forestal de la provincia (INTA, 2017). El clima en esta región es templado-cálido sin estación seca, con medias anuales de 18.7°C de temperatura y 1345.3 ± 287.7 mm de precipitación (Frangi *et al.*, 2015). Los suelos predominantes son los correspondientes al orden Molisol, seguidos en cuanto a superficie ocupada por Vertisoles y Entisoles (USDA, 1999). La fisiografía presenta pendientes suaves de 1 a 2 % generalmente largas, con sedimentos arcillosos sobre los cuales se depositan materiales arenosos (Paparotti & Gvozdenovich, 2007).

#### 3.2. Materiales

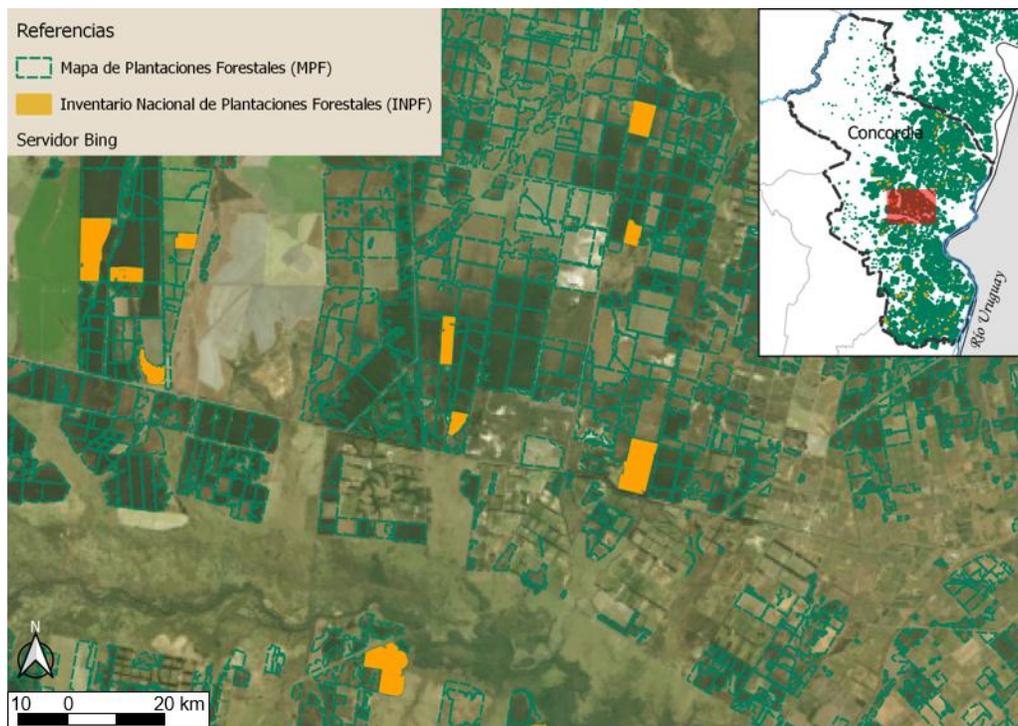
##### 3.2.1 Base cartográfica

La base cartográfica consistió en la cobertura vectorial del MPF y del Inventario Nacional de Plantaciones Forestales (INPF). La primera de ellas, son datos publicados en el sitio oficial de la Secretaria de Agroindustria de Argentina. Dicha cobertura fue generada a partir de la identificación de las plantaciones forestales y su correspondiente digitalización a través de entidades geográficas - polígonos- para luego proceder a la asignación de atributos. Estos, definidos por dos fuentes de información: (i) expedientes formulados al momento de acogerse a los beneficios que otorga la Ley y (ii) inferida a partir de la fotointerpretación. Por su parte, los datos provenientes del INPF (Figura 2) fueron brindados por el *Área SIG e Inventario Forestal* para llevar adelante el presente estudio y se conformó por información proveniente del chequeo a campo, llevado a cabo durante la campaña 2015-2016 a través de un diseño estratificado (INPF, 2017).

El sistema de representación cartográfica empleado corresponde a la proyección conforme Gauss-Krüger y se adopta el Marco de Referencia Geodésico Nacional denominado POSGAR 94

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

(Posiciones Geodésicas Argentinas) que materializa en Argentina el Sistema de Referencia WGS 84 (SSDFI, 2017). Para homogeneizar la cartografía local con la información satelital en formato ráster, la capa vectorial fue reproyectada al sistema UTM huso 21S, dátum WGS84.



**Figura 2. Coberturas vectoriales del Mapa de Plantaciones Forestales (MPF) y del Inventario Nacional de Plantaciones Forestales (INPF) para un área determinada del Departamento de Concordia, Entre Ríos.**

### 3.2.2 Datos satelitales

Las imágenes utilizadas corresponden a Sentinel-2 del 05-11-2016 (órbita-granule R024-T21JUF) y Landsat-8 del 06-11-2016 (path-row 225-082). Ambas fueron seleccionadas por abarcar toda la zona de estudio, contener una mínima cobertura de nubes y fundamentalmente por la contigüidad de las fechas entre ambas imágenes, estableciendo así la menor separación temporal posible.

Para ser totalmente comparables, las imágenes que se adquirieron en diferentes fechas y mediante diferentes sensores se deben convertir en productos de reflectancia superficial mediante correcciones radiométricas (Padró *et al.*, 2017). Esto es motivado por las características del sensor, las condiciones atmosféricas, el ángulo solar y el ángulo de visión del sensor que pueden ocultar los cambios en la superficie terrestre (Chen *et al.*, 2005). A continuación se detallan características de los sensores empleados, así como el método de corrección radiométrica aplicado en cada uno de ellos.

### A) Sentinel-2

Sentinel-2A (S2A) y Sentinel-2B (S2B) son dos satélites de la ESA (*European Space Agency*) puestos en órbita el 23-06-2015 y el 07-03-2017, respectivamente. Las órbitas están diseñadas para garantizar un tiempo de revisita de aproximadamente cinco días en el ecuador, considerando los dos satélites (Mandanici & Bitelli, 2014). Ambos, cuentan con un sensor multiespectral denominado MSI de trece bandas (Tabla A, Apéndice 1) proporcionando imágenes de alta calidad radiométrica (12 bits) y tres resoluciones espaciales: 10 m, 20 m y 60 m (ESA, 2017). La serie incorpora tres bandas en la región del margen rojo que mejora la configuración de los sensores para estudios de aguas y vegetación (Delegido *et al.*, 2011; Delegido *et al.*, 2016). La RSRF (*Relative Spectral Response Function*) del MSI de S2A y S2B tienen ligeras diferencias, pero la configuración espectral es la misma (ESA, 2018).

La imagen Sentinel-2 (S2), empleada en este trabajo, fue descargada del servidor de la ESA en nivel L1C. Es decir, valores de reflectancia TOA (*Top Of Atmosphere*) y convertida a nivel L2A, a reflectancias BOA (*Bottom Of Atmosphere*), a través del método de corrección radiométrica SEN2COR. Al corregir las imágenes con este método todas las bandas, de 10 m y 20 m, son remuestreadas automáticamente a 20 m para ser empleadas en forma conjunta. Por otra parte, la corrección topográfica no constituiría un elemento crítico dentro del ámbito de estudio, puesto que es considerada una zona llana.

### B) Landsat-8

La serie de satélites Landsat, es una iniciativa de la NASA (*National Aeronautics and Space Administration*) y el USGS (*United States Geological Survey*), siendo el programa de mayor trayectoria y continuidad en la captación de datos a través de la teledetección, en el mundo (USGS, 2019). Landsat-8 (L8) es el satélite más reciente del programa; fue lanzado el 11-02-2013 y cuenta con dos sensores a bordo: El sensor OLI, del cual se obtuvo la imagen empleada en este trabajo, y el sensor TIRS (*Thermal Infrared Sensor*) (Markham *et al.*, 2014) no utilizado en este estudio al no tener su homólogo en S2. OLI colecta imágenes en nueve bandas espectrales con resolución espacial de 30 m (a excepción de la imagen pancromática, con 15 m) (Tabla A, Apéndice 1), un ciclo de repetición de 16 días y una resolución radiométrica reescalada de 12 bits a 16 bits (USGS, 2019).

Por su parte, el producto L8 empleado en este trabajo es del tipo Level 2A, es decir, se descargó del USGS corregido radiométricamente mediante el método LaSRC (USGS, 2019), que se basa en el algoritmo 6S y no realiza corrección topográfica.

## 3.3 Metodología

### 3.3.1. Máscara de NODATA y clases informacionales.

Debido a que la finalidad del presente trabajo es clasificar solo píxeles correspondientes a la cobertura vectorial del MPF, se realizó una máscara de NODATA. Esta se aplicó en ambas

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

---

imágenes, S2 y L8, permitiendo así discriminar entre aquellos píxeles que contenían información del MPF de los que no. De esta manera, quedan excluidos píxeles que podrían generar confusión al momento de realizar la clasificación, como pueden ser aquellos que corresponden a áreas urbanas u otros cultivos arbóreos no forestales, como pueden ser rodales de árboles frutales.

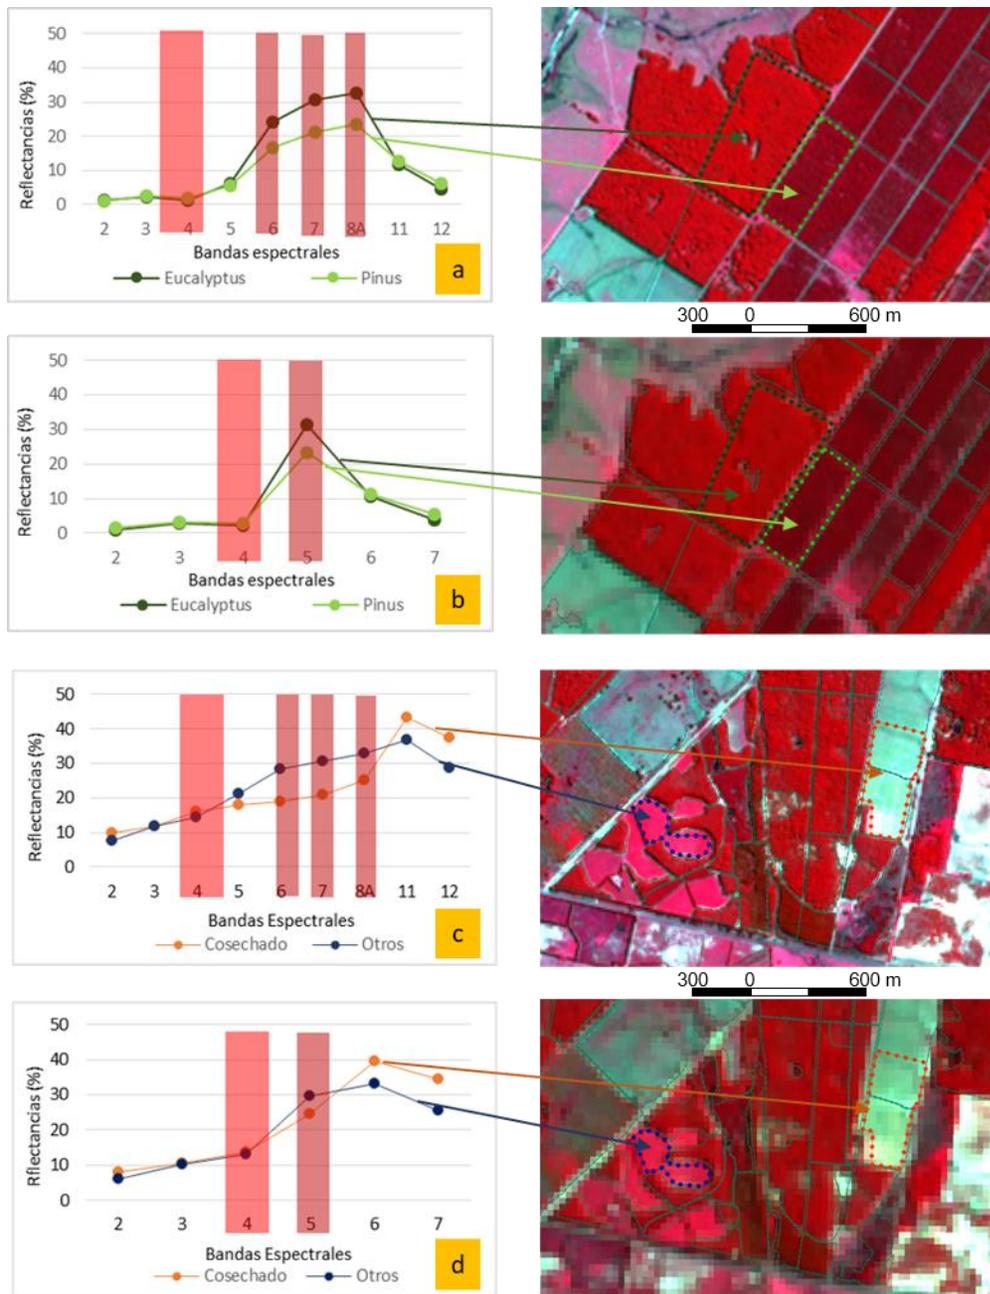
Para la determinación de las clases informacionales (categorías) que conformarían el mapa categórico, producto de la clasificación, se tuvieron en cuenta las categorías actualmente establecidas en el MPF: *Eucalyptus*, *Pinus*, *Cosechado* y *Otros*. Las dos primeras, incluyen rodales puros de cada una de las especies, mientras que la categoría *Cosechado* se conforma por aquella superficie en la cual constan registros de antiguas plantaciones forestales pero que al momento de realizar la clasificación se visualizan como suelo desnudo (Figura 3c y 3d). Por su parte, la categoría *Otros* representa aquella superficie compuesta por cultivos tales como: *Allium sativum* "ajo", *Allium fistulosum* L. "cebolla de verdeo", entre otros.

### 3.3.2. Información espectral

La dependencia de la reflectividad espectral con la longitud de onda está íntimamente relacionada con la naturaleza del material y es lo que hace posible el reconocimiento de materiales en teledetección (Gilbert *et al.*, 1997). Esto se materializa en Firmas Espectrales (FE), las cuales en la vegetación son consecuencia de la composición y tipo de superficie foliar que interactúa con la radiación del sol (Cavender-Bares *et al.*, 2017). Para corroborar si efectivamente las cuatro coberturas establecidas en el MPF, presentaban diferencias espectrales que permitieran su discriminación, se llevó adelante el cálculo de FE para cada una de ellas (Figura 3).

Además, se consideraron como variables a incorporar en la clasificación las bandas multiespectrales de cada imagen, detalladas en la Tabla A Apéndice 1, como así también el Índice de Vegetación denominado NDVI (*Normalized Difference Vegetation Index*). El NDVI establece una relación normalizada entre las bandas del Infrarrojo Cercano (IR cercano) y la banda del Rojo (Rouse *et al.*, 1974). El uso frecuente del NDVI para estudios como el aquí llevado a cabo, radica en que la vegetación activa tiene un comportamiento diferente en las bandas del Rojo y el IR cercano: en la región visible del espectro electromagnético, los pigmentos de las hojas absorben la mayor parte de la energía que reciben reflejando en forma mínima la energía solar recibida, mientras que en el IR cercano la absorción es muy baja y por lo tanto la reflectividad es mucho más elevada que en el Rojo. Por tal razón, se produce un contraste espectral entre estas bandas lo cual permite separar con claridad la vegetación de otras coberturas (Soria & Granados, 2005). Para la imagen S2 se emplearon tres NDVI resultado de la combinación de las bandas: 6-4, 7-4 y 8-4, dado que las bandas 6 y 7 están específicamente situadas en la región espectral del margen rojo, cuya finalidad es detectar cambios en el estado biológico de las plantas (Boochs *et al.*, 1990; Bing *et al.*, 2018), mientras que la banda 8 se considera ya en el IR cercano. Para L8 el NDVI se realizó entre las bandas 5-4 ya que en este sensor la banda 5 se encuentra en el IR cercano (Tabla A, Apéndice 1).

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>



**Figura 3.** Diferenciación de bandas para las categorías *Eucalyptus* y *Pinus* para S2 (a) y L8 (b). Diferenciación de bandas para las categorías *Cosechado* y *Otros* para S2 (c) y L8 (d).

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

---

### 3.3.3. Determinación de áreas de entrenamiento y áreas de test.

Las áreas de entrenamiento (AE) son una porción del terreno representativa de una clase informacional, que cuenta con características conocidas por el analista y que debe contener la información más relevante para el clasificador (Pons & Arcalís, 2012). Por su parte, las áreas de test (AT) se emplean para el cálculo de los valores de acierto de las clasificaciones realizadas (Salvador *et al.*, 1996).

En el presente trabajo las AE y AT se establecieron a partir de polígonos que integraban la cobertura vectorial del INPF, es decir, representan la verdad terreno. Condicionado por la cantidad de muestras disponible provenientes del INPF se estableció una distribución entre AE y AT para todas las categorías de 70 % - 30 %, respectivamente, siendo independientes unas de otras. Además, se tuvo en cuenta la similitud de tamaño entre todas las áreas a fin de evitar posibles sesgos en el clasificador.

### 3.3.4. Clasificación automática.

El proceso de clasificación, en el contexto de la teledetección, consiste en asignar a cada píxel de la imagen original una etiqueta correspondiente a una de las clases que, o bien predefinimos con anterioridad al proceso de clasificación o bien, por semejanza de características de los píxeles de la imagen a clasificar, se agrupan automáticamente en el proceso (Quirós, 2009). Para ello, se utilizan clasificadores, definidos como métodos, criterios o algoritmos que se emplean como mecanismo de asignación de estos píxeles o segmentos a cada categoría (Pons & Arcalís, 2012).

Para este trabajo se emplearon métodos estadísticos de clasificación representativos de tres familias de tratamiento estadístico de los datos, la supervisada paramétrica (mínima distancia euclidiana), la supervisada no paramétrica (kNN) y la no supervisada (IsoData Híbrido). A continuación, se describen cada uno de ellos:

#### A) *Supervisada paramétrica (mínima distancia euclidiana)*

La clasificación supervisada es empleada cuando se cuenta con una definición a priori de las categorías y se conocen casos (entidades) que corresponden a ellas (Paruelo *et al.*, 2014). En los métodos paramétricos, tendremos que definir el término patrón o muestra de entrenamiento como el modelo que caracteriza una clase y que es necesario para estimar la función de probabilidad asociada a cada clase (Quirós, 2009). En este trabajo el clasificador escogido fue el de *Mínima distancia Euclidiana*, el cual utiliza las AE para establecer la media de las clases seleccionadas para entonces ubicar cada píxel en la clase cuya media se encuentre más cercana a partir de la medida de distancia euclidiana.

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

---

#### B) Supervisada no paramétrica (kNN)

Por otro lado, se realizó una clasificación supervisada utilizando el clasificador por *número vecinos más próximos* -kNN- (*K Nearest Neighbours*), el cual asume que es plausible que los píxeles que se encuentran cercanos entre sí en el espacio estadístico pertenezcan a la misma clase informacional (Pons & Arcalís, 2012).

#### C) No supervisada (IsoData Híbrido)

En la clasificación no supervisada, las clases o categorías se definen considerando la similitud entre píxeles, no necesitan una fase de entrenamiento con datos etiquetados para encontrar la estructura interna de los datos con la que poder agruparlos en distintos grupos (Paoletti *et al.*, 2019). El software MiraMon 8 (Pons, 2004), con el cual se llevó adelante el proceso de clasificación no supervisada, se basa en el método IsoData (Duda & Hart, 1973), tomando los centros de *cluster* iniciales sobre el rango total del histograma (Salvador *et al.*, 1996). A partir del resultado obtenido, clases espectrales, se emplearon las AE utilizadas en las clasificaciones supervisadas, y de esta manera se llevó a cabo la agrupación de las clases determinadas por el IsoData en clases meramente categóricas: *Eucalyptus*, *Pinus*, *Cosechado* y *Otros*. Este proceso es el que denominamos IsoData Híbrido. La clasificación híbrida tiene la ventaja de utilizar los mejores aspectos de cada uno de los dos enfoques: la objetividad estadística de la clasificación no supervisada y el interés humano en las clases informacionales (Pons & Arcalís, 2012).

#### 3.3.5. Evaluación de la calidad

Para evaluar la calidad de una clasificación se puede emplear una matriz de confusión, la cual consiste en una tabla bidimensional que permite evaluar la calidad para cada clase por separado mediante el cálculo de errores de omisión y comisión (Salvador *et al.*, 1996). Mientras las filas son los valores de referencia "verdad-terreno", las columnas expresan los valores obtenidos por el clasificador. Los píxeles correctamente clasificados se encuentran ubicados en la diagonal de dicha matriz, mientras que aquellos por fuera son errores de asignación. Estos pueden ser de omisión o comisión, el primer caso se presenta cuando el clasificador no ubica en una categoría un píxel que pertenece a ella mientras que el segundo se debe a píxeles ubicados de forma equivocada en las categorías.

Para evaluar la exactitud del clasificador, es decir, la concordancia en la asignación de los píxeles se aplicó el estadístico Índice Kappa (IK), que da cuenta de la contribución del azar en la confiabilidad del mapa (Mas *et al.*, 2003). Este, se emplea para evaluar la concordancia de métodos cuyo resultado es categórico, con dos o más clases (Borràs *et al.*, 2017) como en este caso.

## 4. Resultados

Las tablas que se presentan a continuación muestran los resultados obtenidos en matrices de confusión con el fin de evaluar el grado de acierto de los estadísticos aplicados en cada modelo de

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

clasificación. Los números observados en las tablas representan píxeles. A igual ámbito de estudio, S2 presenta una resolución espacial de 20 m mientras que para L8 es de 30 m, por esta razón varía la cantidad de píxeles entre ambas imágenes, siendo de 5431 para S2 y de 2415 para L8.

Por otra parte, en la Figura 4 se pueden apreciar los mapas categóricos, para un área determinada, obtenidos como resultado de la aplicación de los tres métodos de clasificación aplicados a las dos imágenes empleadas en este trabajo.

**Tabla 1. Matriz de Confusión para evaluar la calidad de la clasificación Supervisada con Mínima Distancia Euclidiana en S2 para la diferenciación de plantaciones forestales en Entre Ríos, Argentina.**

	<i>Eucalyptus</i>	<i>Pinus</i>	Cosechado	Otros	Total	Error por comisión	Exactitud usuario
<i>Eucalyptus</i>	1588.0	62.0	0.0	0.0	1650.0	3.8	96.2
<i>Pinus</i>	101.0	1029.0	0.0	6.0	1136.0	9.4	90.6
Cosechado	0.0	0.0	1366.0	273.0	1639.0	16.7	83.3
Otros	107.0	296.0	17.0	586.0	1006.0	41.7	58.3
Total	1796.0	1387.0	1383.0	865.0	5431.0		
Error por omisión	11.6	25.8	1.2	32.3			
Exactitud productor	88.4	74.2	98.8	67.7			
	Índice Kappa 0.8		$\sigma^2$ Kappa 4.33055E-05		Acierto global 84.10 %		

En la Tabla 1 se presentan los resultados de la clasificación supervisada utilizando el clasificador de la Mínima Distancia Euclidiana para la imagen S2. En esta se pueden evidenciar errores de comisión y omisión excesivamente altos para la categoría *Otros* siendo 41.7 % y 32.3 %, respectivamente. Así también de omisión para *Pinus*, siendo del 25.8 %. Aún así, este clasificador presenta muy buen comportamiento para la categoría *Cosechado* con un 98.8 % de exactitud. El IK para esta combinación sensor-clasificador es de 0.8. En cambio, cabe señalar que si bien no existe confusión entre la categoría *Cosechado* y las categorías forestales, sí que existe un error de comisión del 16 % con la categoría *Otros*. Este hecho es debido a la similitud de la categoría *Cosechado* con algunas superficies desnudas que se encuentran en áreas de test categorizadas como *Otros*, y el clasificador considera que son áreas cosechadas. Estos errores se podrían corregir en un post-procesado que combine los píxeles clasificados como *Cosechado* con los píxeles que

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

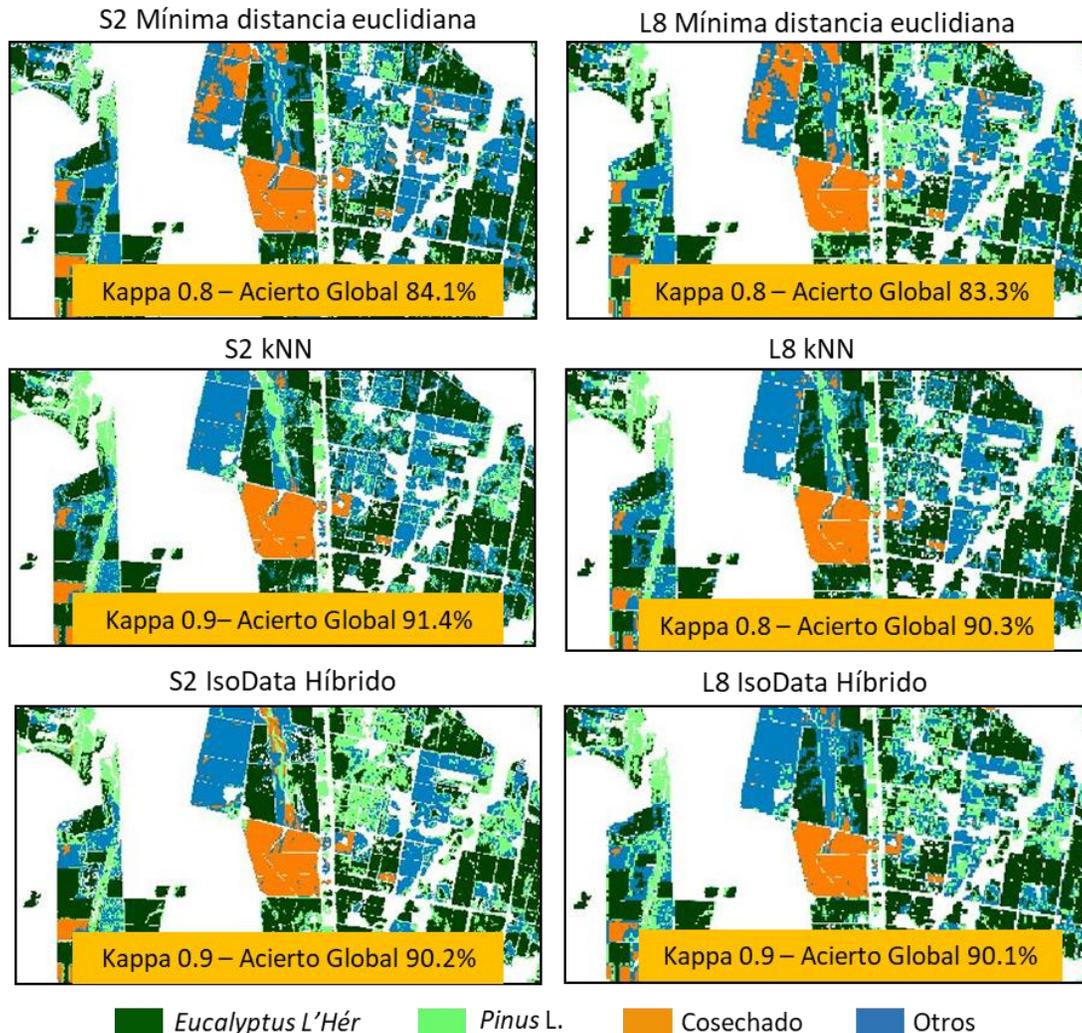
previamente estaban clasificados como forestales, pues sólo se considerarían cosechadas aquellas áreas que en una clasificación anterior eran plantaciones.

**Tabla 2. Matriz de Confusión para evaluar la calidad de la clasificación Supervisada con Mínima Distancia Euclidiana en L8 para la diferenciación de plantaciones forestales en Entre Ríos, Argentina.**

	<i>Eucalyptus</i>	<i>Pinus</i>	Cosechado	Otros	Total	Error por comisión	Exactitud usuario
<i>Eucalyptus</i>	742.0	98.0	0.0	0.0	840.0	11.7	88.3
<i>Pinus</i>	42.0	402.0	0.0	0.0	444.0	9.5	90.5
Cosechado	0.0	0.0	619.0	135.0	754.0	17.9	82.1
Otros	7.0	120.0	0.0	250.0	377.0	33.7	66.3
Total	791.0	620.0	619.0	385.0	2415.0		
Error por omisión	6.2	35.2	0.2	35.1			
Exactitud productor	93.8	64.8	99.8	64.9			
	Índice Kappa 0.8		$\sigma^2$ Kappa 1.02252E-04		Acierto global 83.30 %		

La Tabla 2 (Clasificación Supervisada con Mínima Distancia Euclidiana en imagen L8) también muestra valores superiores a los esperados para la categoría *Pinus* (35.2 %) en error de omisión, siendo el error por comisión más aceptable ya que es inferior al 10 %. La categoría *Cosechado* presenta un valor casi perfecto en la exactitud del productor, aunque supera el 15 % en error de comisión. El IK es de 0.8 con un acierto global de todos los píxeles del 83.3 %.

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>



**Figura 4. Representación de un área de los mapas categóricos obtenidos para todos los métodos de clasificación aplicados en ambas imágenes.**

La evaluación de la precisión del clasificador de kNN para la imagen S2 (Tabla 3), con un acierto global del 91.40 %, es el más elevado. *Eucalyptus* tiene un acierto del usuario superior al 98 % indicando una alta precisión para asignar píxeles en esta categoría. La categoría *Otros* es la de valores más altos para ambos tipos de errores. De la verdad terreno se clasifican a la perfección los píxeles de *Cosechado*. Por su parte, la categoría *Pinus* tiene valores aceptables de exactitud tanto del usuario como del productor.

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

**Tabla 3. Matriz de Confusión para evaluar la calidad de la clasificación con kNN en S2 para la diferenciación de plantaciones forestales en Entre Ríos, Argentina.**

	<i>Eucalyptus</i>	<i>Pinus</i>	Cosechado	Otros	Total	Error por comisión	Exactitud usuario
<i>Eucalyptus</i>	1717.0	22.0	0.0	9.0	1748.0	1.8	98.2
<i>Pinus</i>	50.0	1256.0	0.0	91.0	1397.0	10.1	89.9
Cosechado	0.0	0.0	1383.0	155.0	1538.0	10.1	89.9
Otros	29.0	109.0	0.0	610.0	748.0	18.4	81.6
Total	1796.0	1387.0	1383.0	865.0	5431.0		
Error por omisión	4.4	9.4	0.0	29.5			
Exactitud productor	95.6	90.6	100	70.5			
	Índice Kappa 0.9		$\sigma^2$ Kappa 1.85661E-05		Acierto global 91.40 %		

La Tabla 4, con un acierto global del 90.3 % y un IK 0.9 también se establece entre los clasificadores más destacados de los seis evaluados. Presenta errores de omisión inferiores al 10 % para las categorías *Eucalyptus* y *Pinus*, pero al mismo tiempo esta última se acerca a un valor de 15 % en error por comisión.

**Tabla 4. Matriz de Confusión para evaluar la calidad de la clasificación con kNN en L8 para la diferenciación de plantaciones forestales en Entre Ríos, Argentina.**

	<i>Eucalyptus</i>	<i>Pinus</i>	Cosechado	Otros	Total	Error por comisión	Exactitud usuario
<i>Eucalyptus</i>	1675.0	50.0	0.0	0.0	1725.0	2.9	97.1
<i>Pinus</i>	113.0	1251.0	0.0	93.0	1457.0	14.1	85.9
Cosechado	0.0	0.0	1383.0	188.0	1571.0	12.0	88.0
Otros	8.0	86.0	0.0	584.0	678.0	13.0	87.0
Total	1796.0	1387.0	1383.0	865.0	5431.0		
Error por omisión	6.7	9.8	0.0	32.5			
Exactitud productor	93.3	90.2	100.0	67.5			
	Índice Kappa 0.9		$\sigma^2$ Kappa 2.99E-05		Acierto global 90.30 %		

En la Tabla 5 (IsoData Híbrido con S2), para un total de 5431 píxeles evaluados se observa que el mayor error por omisión se da en la categoría *Otros*. En contraposición, se encuentra la categoría *Cosechado*, en la cual el clasificador no presenta dudas al momento de asignar los píxeles en esta clase. Por su parte, las categorías *Eucalyptus* y *Pinus* tiene un error de 6.7 % y 9.8 %, respectivamente. *Pinus* presenta una sobreestimación de píxeles, con un valor del error que ronda el 15 % mientras que para el género *Eucalyptus* el porcentaje es menor al 3 %. Para este clasificador el IK presenta un valor de 0.9.

**Tabla 5. Matriz de Confusión para evaluar la calidad de la clasificación No Supervisada IsoData Híbrido en S2 para la diferenciación de plantaciones forestales en Entre Ríos, Argentina.**

	<i>Eucalyptus</i>	<i>Pinus</i>	Cosechado	Otros	Total	Error por comisión	Exactitud usuario
<i>Eucalyptus</i>	1675.0	50.0	0.0	0.0	1725.0	2.9	97.1
<i>Pinus</i>	113.0	1251.0	0.0	93.0	1457.0	14.1	85.9
Cosechado	0.0	0.0	1383.0	188.0	1571.0	12.0	88.0
Otros	2.0	85.0	0.0	584.0	671.0	13.0	87.0
Total	1796.0	1387.0	1383.0	865.0	5431.0		
Error por omisión	6.7	9.8	0.0	32.5			
Exactitud productor	93.3	90.2	100.0	67.5			
	Índice Kappa 0.9		$\sigma^2$ Kappa 2.99E-06		Acierto global 90.20 %		

Finalmente, la Tabla 6 (IsoData Híbrido con Imagen L8) muestra un error de omisión de la categoría *Pinus* muy elevado (15 %) en comparación *Eucalyptus* que presenta un valor inferior a 5 %. Al mismo tiempo, la exactitud del clasificador para esta categoría es muy cercana al 100 %. Para esta imagen el clasificador también presenta un IK de 0.9 como es el caso del mismo clasificador aplicado a la imagen S2.

**Tabla 6. Matriz de Confusión para evaluar la calidad de la clasificación No Supervisada IsoData Híbrido en L8 para la diferenciación de plantaciones forestales en Entre Ríos, Argentina.**

	<i>Eucalyptus</i>	<i>Pinus</i>	Cosechado	Otros	Total	Error por comisión	Exactitud usuario
<i>Eucalyptus</i>	753.0	8.0	0.0	0.0	762.0	1.1	98.9
<i>Pinus</i>	24.0	525.0	0.0	5.0	554.0	5.2	94.8
Cosechado	0.0	0.0	619.0	98.0	717.0	13.7	86.3
Otros	14.0	87.0	0.0	282.0	383.0	26.4	73.6
Total	791.0	620.0	619.0	385.0	2415.0		
Error por omisión	4.8	15.3	0.2	26.8			
Exactitud productor	95.2	84.7	99.8	73.2			
	Índice Kappa 0.9		$\sigma^2$ Kappa 6.58E-05		Acuerdo global 90.10 %		

## 5. Discusión

Este trabajo plantea que la clasificación automática de imágenes provenientes de S2 y L8 puede constituir una herramienta precisa y fiable para la identificación de las existencias de plantaciones forestales, complementaria a la fotointerpretación empleada actualmente para la generación de la cartografía del MPF.

En primer lugar, solo el clasificador de Mínima Distancia Euclidiana, para ambas imágenes, presentó valores de acierto global menores al 88 %, valor obtenido por Clemente *et al.* (1997). De este modo, se podrían considerar los dos clasificadores restantes como mejoras al estudio realizado por esos autores. Tal como fue documentado por Borràs *et al.* (2017) y Delegido *et al.* (2016), el clasificador mediante el método kNN muestra mayor exactitud que las restantes metodologías.

Si bien los valores obtenidos son aceptables, una alternativa para mejorar el desempeño del clasificador sería aumentar las AE como así también la heterogeneidad de las clases preestablecidas, como menciona Hastie *et al.*, (2009). También resultaría interesante la aplicación de un filtrado a partir de indicadores estadísticos como la varianza y la media para cada polígono, según lo establece Moré *et al.* (2005).

Se observa, que tanto en el actual trabajo como en el realizado por Clemente *et al.* (1997), en forma general, los mayores errores al momento de clasificar píxeles se corresponden con la categoría *Otros*, mientras que la categoría *Cosechado* representa la menor cantidad de errores por

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

---

omisión. Por otra parte, se resalta una mejora en el acierto de clasificación para las categorías *Eucaliptus* y *Pinus*, en comparación con el trabajo realizado por los autores antes mencionados. En referencia a las clases informacionales, éstas fueron tomadas de las ya establecidas en el MPF y si bien se corroboró que presentaran diferencias espectrales se concuerda con Quirós (2009) en que las mismas no han sido definidas *a priori* para separar clases espectrales y que de haber sido así es seguro que el listado de categorías hubiera sido algo distinto. Es decir, resultaría conveniente a los fines del trabajo, establecer en primer lugar las clases espectrales y a partir de allí las informacionales.

Con respecto a la utilización de imágenes satelitales de alta resolución, los tres métodos de clasificación vinculados a S2 mostraron mayores niveles de exactitud que los obtenidos por L8, siendo las diferencias menores al 1 % para todas las clasificaciones. Si bien se podría considerar que la obtención de mejores valores en S2 se debe principalmente a las variables incorporadas estratégicamente en su sensor MSI (ESA, 2017) existen trabajos como el realizado por Bing *et al.*, (2018) en el cual concluyen que no son las tres bandas del margen rojo las que aumenta la precisión sino la banda del IR cercano (8A). En la misma línea, Mandanici & Bitelli (2014) confirman que esta banda es la opción óptima desde el punto de vista espectral para acoplar con las de L8. Esto permitiría explicar también, en cierta parte, los mejores resultados obtenidos en este trabajo en comparación con Clemente *et al.* (1997) ya que estos autores utilizaron imágenes provenientes del sensor TM (*Thematic Mapper*) de Landsat-5 el cual presenta para la banda del IR cercano una menor resolución espectral (mayor amplitud) que S2 y L8 (Tabla A, Apéndice 1).

Otro aspecto a destacar es el vinculado a las resoluciones de los dos sensores empleados. Si bien S2 presenta mejoras a nivel espectral y espacial, respecto a L8, también presenta una mejor resolución temporal. Si se tiene en consideración lo planteado por Chuvieco (1995), respecto a que los tres tipos de resolución están relacionados de manera que, a mayor resolución espacial, normalmente disminuye la temporal, y es previsible que disminuya también la espectral, se explicaría entonces la similitud de los resultados obtenidos entre ambos sensores.

Existen numerosos trabajos que analizan la correlación entre las bandas multiespectrales de los programas Landsat y Sentinel-2 lo cual, entre otras cosas, permite aumentar la resolución temporal como así también reemplazar imágenes en caso de ser necesario. Si bien la intención de este trabajo no fue analizar dicho aspecto, lo que se pretendió aquí fue retomar lo analizado por Clemente *et al.* (1997) y evaluar los avances en los sensores en las últimas dos décadas; en caso que la metodología de clasificación automática sea incorporada para genera el MPF resultaría interesante como siguiente paso analizar la correlación de imágenes de los distintos programas para diferenciar cobertura boscosa en Argentina, trabajo que hasta la actualidad no ha sido registrado.

## 6. Conclusiones

Por todo lo antes presentado, se concluye que la clasificación automática de imágenes satelitales es una herramienta con un alto grado de precisión y fiabilidad que la convierte en útil para responder a los objetivos planteados en el MPF, es decir, brinda la posibilidad de obtener cartografía para identificar las plantaciones y cuantificar su superficie al mismo tiempo que permite ser actualizada anualmente. Hasta el momento esta metodología resulta complementaria y factible

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

---

de llevar adelante (principalmente por su rapidez y bajo costo) con la empleada actualmente en el *Área SIG e Inventario Forestal*. Será necesario ampliar esta investigación, ya sea evaluando en forma comparativa el método de fotointerpretación con el automático para tomar la decisión del cambio de metodologías, evaluar el uso combinado de ambos sensores para aumentar así la resolución temporal y/o considerar el uso de otros clasificadores o de imágenes proveniente de otros sensores. Por su parte, el clasificador kNN y sensor S2 son los recomendados, a partir de los resultados obtenidos. La mejora en la resolución espacial y espectral de S2, se encuentra equiparada por una mejor resolución radiométrica en L8.

### Referencias bibliográficas

AFOA. (2012): Asociación Forestal Argentina. Publicación en el Diario El Intransigente, sección Argentina. *José Urtubey sobre la forestación en la Argentina "Sólo se industrializa el 50%"*. <http://www.elintransigente.com/argentina/2012/2/11/urtubey-sobre-forestacion-argentina-solo-industrializa-121861.html> [Última consulta: mayo de 2017].

ASIF. (2018). Área SIG e Inventario Forestal. Dirección de Producción Forestal. *Elaboración de un Mapa de Plantaciones Forestales (MPF) para la República Argentina de Actualización Permanente*. <http://areasigeyinventarioforestal.blogspot.com/p/actividades.html> [Última consulta: mayo de 2019].

ASORA. (2019): ASORA Revista "La prórroga de la Ley una oportunidad de ser un país forestal" <http://asorarevista.com.ar/noticias-blog/423-la-prorroga-de-la-ley-da-la-oportunidad-de-ser-un-pais-forestal> [Última consulta: abril de 2019].

Bing, W.; Kun, J.; Shunlin, L.; Xianhong, X.; Xiangqin, W. Xiang, Z.; Yunjun, Y. & Z. Xiaotong (2018): *Assessment of Sentinel-2 MSI Spectral Band Reflectances for Estimating Fractional Vegetation Cover*. *Remote Sens.* 2018, 10 (12), 1927.

Boochs, F.; Kupfer, G.; Dockter, K.; & W. KÜHbauch (1990): *Shape of the red edge as vitality indicator for plants*. *Int. J. Remote Sens.* 1990, 11, 1741–1753.

Borràs, J., Delegido, J., Pezzola, A., Pereira, M., Morassi, G. & G. Camps-Valls (2017): *Land use classification from Sentinel-2 imagery*. *Revista de Teledetección*, 48, pp. 55-66.

Cavender-Bares, J.; Gamon, J. A.; Hobbie, S. E.; Madritch, M. D.; Meireles, J. E.; Schweiger, A. K., & P. A. Townsend (2017): *Harnessing plant spectra to integrate the biodiversity sciences across biological and spatial scales*. *American journal of botany*, 104 (7), pp. 966.

Chen, X.; Vierling, L. & D. Deering (2005): *A simple and effective radiometric correction method to improve landscape change detection across sensors and across time*. *Remote Sensing of Environment*, 98, pp. 63-79.

Chuvieco, E. (1995): *Fundamentos de Teledetección Espacial*. Ediciones RIALP S. A. Madrid. Segunda Edición: julio 1995. Pp.95.

Clemente, N. I.; Medvescig, M. & M. Larrieu (1997): *Aplicación de un sistema de información geográfica para la ubicación y cuantificación de plantaciones forestales de Eucalyptus sp. y Pinus*

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

---

*sp. en el Departamento de Concordia en la Provincia de Entre Ríos.* Secretaría de Agricultura, Ganadería, Pesca y Alimentación, pp. 1-7.

Delegido, J.; Verrelst, J.; Alonso, L. & J. Moreno (2011): *Evaluation of Sentinel-2 RedEdge Bands for Empirical Estimation of Green LAI and Chlorophyll.* Content. Sensors, n. 11, pp. 7063-7081.

Delegido, J.; Tenjo, C.; Ruiz-Verdu, A.; Pereira-Sandoval, M.; Pasqualotto, N.; Gibaja, G.; Verrelst, J.; Peña, R.; Urrego, P.; Borràs, J.; Sanchis Muñoz, J.; Pezzola, A.; Mosquera, Z.; Quinto, Z.; Gómez, J. & J. Moreno (2016): *Aplicaciones de Sentinel-2 a estudios de vegetación y calidad de aguas continentales.* Conferencia: XVII Simposio Internacional en Percepción Remota y Sistemas de Información Geográfica (SELPER) en Puerto Iguazú, Argentina.

Díaz, D. & Tesón N. (2001): *Unidades de Manejo Forestal en los Departamentos Federación, Concordia y Colón del Nordeste de Entre Ríos.* INTA EEA Concordia, pp. 11

Duda, R. O. & P. E. Hart (1973): *Pattern Classification and Scene Analysis.* John Wiley and Sons, Nueva York, cap. 6, Unsupervised Learning and Clustering, pp. 226-227.

ESA. (2017): European Space Agency. [http://www.esa.int/esl/ESA\\_in\\_your\\_country/Spain/](http://www.esa.int/esl/ESA_in_your_country/Spain/) [Última consulta: julio de 2017].

ESA. (2018). European Space Agency. <https://earth.esa.int/web/sentinel/technical-guides/sentinel-2-msi/performance> [Última consulta: mayo de 2019].

Frangi, G.; Pérez, C.; Goya, J.; Tesón, N.; Barrera & M. Arturi (2015): *Modelo integral de una plantación de Eucalyptus grandis de primer ciclo en Concordia, Entre Ríos.* XXIX Jornadas Forestales de Entre Ríos Concordia, septiembre de 2015, pp. 3-4.

Gilabert, M. A.; González-Piqueras, J. & García-Haro, J. (1997): *Acerca de los Índices de Vegetación.* Revista de Teledetección, N° 8. 1997, pp. 1.

Hansen, M.C.; Potapov, P.V.; Moore, R.; Hancher, M.; Turubanova, S. A.; Thau, D.; Stehman, S. V.; Goetz, S. J.; Loveland, T. R.; Kommareddy, K.; Egerov, A.; Chini, L.; Justice, C.O.; & J.R.G. Townshend (2013): *High-Resolution Global Maps of 21st-Century Forest Cover Change.* Science 15 Nov 2013: Vol. 342, Issue 6160, pp. 850-853.

Hastie, T.; Tibshirani, R. & Friedman, J. (2009): *The Elements of Statistical Learning: Data Mining, Inference, and Prediction,* 2nd ed.; Springer: New York, NY, USA. <https://doi.org/10.1007/978-0-387-84858-7>

IEA. (2016): *Informe del Estado del Ambiente.* Coordinación de Información Ambiental del Ministerio de Ambiente y Desarrollo Sustentable de la Nación, pp. 324-370.

Idígoras, G. (2016): *Análisis tecnológico y prospectivo sectorial.* Prospectiva tecnológica 2025 del complejo foresto-industrial, pp. 1-14.

INPF. (2017): *Inventario Nacional de Plantaciones Forestales.* Entre Ríos - Área Continental. Ministerio de Agroindustria, Diciembre 2017. [https://www.agroindustria.gob.ar/sitio/areas/ss\\_desarrollo\\_foresto\\_industrial/censos\\_inventario/](https://www.agroindustria.gob.ar/sitio/areas/ss_desarrollo_foresto_industrial/censos_inventario/) [Última consulta: mayo de 2019].

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

INTA. (2017): Instituto Nacional de Tecnología Agropecuaria. *El sector Forestal de Entre Ríos y el área Forestal de la EEA Concordia*. Reunión Consorcio Forestal. [http://inta.gob.ar/sites/default/files/inta\\_concordia\\_sector\\_forestal\\_en\\_entre\\_rios.pdf](http://inta.gob.ar/sites/default/files/inta_concordia_sector_forestal_en_entre_rios.pdf) [Última consulta: mayo de 2017].

Mandanic, M. & Bitelli, G. (2014): *Preliminary Comparison of Sentinel-2 and Landsat 8 Imagery for a Combined Use*. *Sensores Remotos* 2016, 8, 1014. <https://www.mdpi.com/2072-4292/8/12/1014/html> [Última consulta: mayo de 2019].

Markham, B.; Barsi, J.; Kvaran, J.; Ong, N.; Kaita, E.; Biggar, S.; Czapla-Myers, J.; Mishra, N. & Helder. (2014): *Landsat-8 Operational Land Imager Radiometric Calibration and Stability*. *Remote Sensing*, 6, pp. 12275-12308.

Mas, J. F.; Díaz Gallego, J. R. & A. Pérez Vega (2003): *Evaluación de la confiabilidad temática de mapas o de imágenes clasificadas: una revisión*. *Investigaciones Geográficas, Boletín del Instituto de Geografía, UNAM*. N° 51, México, pp. 53-72.

Maslatón, C. G. (2011): *Plan Estratégico Industrial 2020*. Instituto Nacional de Tecnología Industrial (INTI), pp. 123-138.

MINAGRO. (2016): Ministerio de Agroindustria. Portal de Datos Abiertos del Ministerio de Agroindustria. Fecha de Actualización 02/09/2016. <https://datos.magyp.gob.ar/> [Última consulta: julio de 2017].

Moré Gómez, G.; Pons Fernández, X.; Burriel Moreno, J. A.; Castells Ferré, R.; Ibàñez Martí, J. J. & X. Roijals Lara. (2005): *Diferenciación de cubiertas forestales para el MSCS a partir de la clasificación de imágenes Landsat*. *Actas de la I Reunión de Inventario y Teledetección Forestal*. *Cuad. Soc. Esp. Cienc. For.* 19 pp. 153-162.

Müller-Wilm, U. (2016): *Sentinel-2 MSI-Level-2A Prototype Processor Installation and User Manual*. S2PAD-VEGA-SUM-0001, Issue 2.2.

Padró, J. C.; Pons, X.; Aragonés, D.; Díaz-Delgado, R.; García, D.; Bustamante, J.; Pesquer, L.; Domingo-Marimon, C.; González-Guerrero, O.; Cristóbal, J.; Doktor, D. & M. Lange (2017): *Radiometric Correction of Simultaneously Acquired Landsat-7/Landsat-8 and Sentinel-2A Imagery Using Pseudoinvariant Areas (PIA): Contributing to the Landsat Time Series Legacy*. *Remote Sens.* 2017, 9(12), 1319 <https://doi.org/10.3390/rs9121319> [Última consulta: mayo de 2019].

Paoletti, M. E.; Haut, J. M.; Plaza, J. & A. Plaza (2019): *Estudio comparativo de Técnicas de Clasificación de Imágenes Hiperespectrales*. *Revista Iberoamericana de Automática e Informática Industrial* 16 (2019) 129-137 pp. 130.

Paparotti, O. & Gvozdenovich, J. (2007): *Caracterización de zonas y subzonas RIAP Entre Ríos*. Instituto Nacional de Tecnología Agropecuaria (INTA), pp. 15-16.

Paruelo, J.M., Di Bella, C. & M. Mikovic (2014): *Percepción remota y sistemas de información geográfica*. *Sus aplicaciones en Agronomía y Ciencias Ambientales*. Capítulo 7 *Clasificación de datos espectrales*, pp. 162-185.

Pons, X. (2004): *MiraMon*. Sistema de Información Geográfica y software de Teledetección. Centro de Investigación Ecológica y Aplicaciones Forestales, CREAM. Bellaterra. ISBN: 84-931323-4-9.

Avogadro E. G. y Padró J. C. (2019): "Diferenciación de plantaciones forestales en EntreRíos (Argentina): Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8", *GeoFocus (Artículos)*, n° 24, p 117-139. ISSN: 1578-5157 <http://dx.doi.org/10.21138/GF.652>

---

Pons, X. & Arcalís, A. (2012): *Diccionario terminológico de teledetección*. Barcelona: Instituto Cartográfico de Cataluña: Enciclopedia Catalana, 2012, pp. 597. ISBN 978-84-393-9008-4; 978-84-412-2249-6. <http://www.termcat.cat/ca/diccionaris-en-linia/197> [Última consulta: mayo de 2019].

Quirós Rosado, E.M. (2009): *Clasificación de imágenes multiespectrales ASTER mediante funciones adaptativas*. Tesis Doctoral. Universidad de Extremadura, pp. 18-151.

Ramilo, D.; Dalla Tea, F.; Gasparri, M.; Bunse, G. & S. Nuñez (2015): *Ensayo exploratorio de álamos en Concordia a los 8 y 46 meses*. XXIX Jornadas Forestales de Entre Ríos Concordia, Septiembre de 2015, pp. 1-5.

Rouse, J.W.; Haas R.H.; Schell J.A. & D. W. Deering (1974): *Monitoring vegetation systems in the Great Plains with ERTS*, In: S.C. Freden, E.P. Mercanti, and M. Becker (eds) Third Earth Resources Technology Satellite-1 Symposium. Volume I: Technical Presentations, NASA SP-351, NASA, Washington, D.C, pp. 309-317.

Soria Ruiz, J. & Granados Ramírez, R. (2005): *Relación entre los índices de vegetación obtenidos de los sensores AVHRR del satélite NOAA y TM del Landsat*. Revista Científica Multidisciplinaria de Prospectiva. 2005. ISSN 1405-0269. Pp. 168.

Salvador, R.; Pons, X. & F. Diego (1996): *Validación de un método de corrección radiométrica sobre diferentes áreas montañosas*. Revista de Teledetección N° 7, pp. 2-5.

SSDFI. (2017): Subsecretaría de Foresto Industria. <http://forestindustria.magyp.gob.ar/> [Última consulta: mayo de 2017].

USDA. (1999): *Soil Survey Staff. Soil taxonomy: a basic system of soil classification for making and interpreting soil surveys*. In: Natural Resources Conservation Service, 2nd edition. U.S. Department of Agriculture Handbook, pp. 436.

USGS. (2019): United States Geological Survey. <https://landsat.usgs.gov/> [Última consulta: mayo de 2019].

Yu, Q., Gong, P., Tian, Y., Pu, R. & J. Yang (2008): *Factors Affecting Spatial Variation of Classification Uncertainty in an Image Object-based Vegetation Mapping*. Photogrammetric Engineering & Remote Sensing Vol. 74, No. 8, August 2008, pp.1007-1018.

Zanetti, E. A.; Gómez, J.J; Mostacedo S. J. & O. Reyes (2017): *Cambio climático y políticas públicas forestales en América Latina Una visión preliminar*. Unidad de Cambio Climático, de la División de Desarrollo Sostenible y Asentamientos Humanos de la Comisión Económica para América Latina y el Caribe (CEPAL), en el marco de las actividades del Programa EUROCLIMA (CEC/14/001), pp. 21-106.

## APÉNDICE 1

**Tabla A. Características de las bandas espectrales de los sensores MSI y OLI empleadas en el presente trabajo y las bandas del sensor TM (Thematic Mapper) empleadas por Clemente *et al.* (1997).**

	Nº Banda	Intervalo de Longitud de Onda (nm)	Resolución Espacial (m)	Propósito
Sentinel-2 MSI*	2	457-522	10	Azul
	3	543-577	10	Verde
	4	650-680	10	Rojo
	5	697.5-712.5	20	Margen rojo
	6	732.5-747.5	20	Margen rojo
	7	775-795	10	Margen rojo
	8A	855-875	20	IR cercano
	11	1565-1655	20	IR onda corta -1
	12	2100-2280	20	IR onda corta -2
Landsat-8 OLI*	2	452-512	30	Azul
	3	533-590	30	Verde
	4	636-673	30	Rojo
	5	851-879	30	IR cercano
	6	1566-1651	30	IR onda corta -1
	7	2107-2294	30	IR onda corta -2
	Landsat-5 TM**	1	452-518	30
2		528-626	30	Verde
3		626-710	30	Rojo
4		776-904	30	IR cercano
5		1567-1785	30	IR cercano
7		2096-2350	30	IR medio

Fuente: \* Elaborado a partir de Markham *et al.* (2014) y Müller-Wilm (2016).

\*\* Elaborado a partir de Padró *et al.* (2017)

