



Ministerio
de Ganadería,
Agricultura y Pesca

Dirección General FORESTAL



Ministerio
de Ambiente

Dirección Nacional de Cambio Climático



Informe de Metodología y Resultados de la Cartografía de Bosque Nativo 2021

Indicador de desempeño asociado al Bono Indexado a
Indicadores de Cambio Climático.

KPI-2 Área de Bosque nativo en Hectáreas

Marzo 2023

ÍNDICE

1. INTRODUCCIÓN	3
2. MATERIALES Y MÉTODOS.....	4
2.1. Búsqueda y selección de datos	5
2.1.1. Datos satelitales	5
2.1.2. Selección de muestras de entrenamiento	9
2.2. Clasificación supervisada	14
2.2.1. Detección de cobertura forestal	15
2.2.2. Detección de bosque nativo.....	15
2.3. Post-clasificación.....	16
2.3.1. Segmentación.....	16
2.3.2. Cálculo de clase de segmentos	18
2.3.3. Edición post-clasificación	18
2.3.4. Análisis de exactitud.....	20
3. RESULTADOS	21
3.1. Análisis de exactitud	24
4. BIBLIOGRAFÍA	25

1. INTRODUCCIÓN

La Dirección General Forestal (DGF) del Ministerio de Ganadería Agricultura y Pesca (MGAP), en coordinación con la Dirección Nacional de Cambio Climático (DINACC) del Ministerio de Ambiente (MA), presentan el informe vinculado al indicador clave de desempeño de bosque nativo (KPI-2) del Bono Indexado a Indicadores de Cambio Climático (BIICC). Este KPI (KPI-2) se basa en estimaciones del área de bosque nativo (medido en hectáreas), mediante la aplicación de técnicas de mapeo satelital y sensoramiento remoto, siguiendo las disposiciones relevantes del Panel Intergubernamental del Cambio Climático (IPCC, 2006) y la Guía de Buenas Prácticas del IPCC (IPCC, 2003). Las metodologías utilizadas para calcular el desempeño de los KPIs serán las mismas que las empleadas por Uruguay para informar los datos de avance en las Contribuciones Determinadas a Nivel Nacional (CDN) a las Naciones Unidas.

El marco para la emisión del BIICC fue preparado en conjunto por el Ministerio de Economía y Finanzas (MEF), el Ministerio de Industria, Energía y Minería (MIEM), el Ministerio de Relaciones Exteriores (MRE), el MA y el MGAP. Constituye la piedra angular para el acceso de Uruguay al mercado de las finanzas soberanas sostenibles y, en términos más generales, busca ser pionero en un enfoque alternativo para el financiamiento de la deuda vinculada a la sostenibilidad. Uruguay busca implementar una estructura de premios y penalidades de tasas simétrica, vinculando el costo de capital del país al logro de sus objetivos climáticos y de conservación de la naturaleza establecidos en los compromisos asumidos en el Acuerdo de París. Apuntalando este marco está la intención de orientar las finanzas sostenibles en el logro de objetivos de desempeño climático específicos, materiales y visibles, anclados en un sistema robusto de reporte y verificación, e impulsados por las acciones, políticas e inversiones necesarias para cumplirlos. El Banco Interamericano de Desarrollo (BID) y el Programa de las Naciones Unidas para el Desarrollo (PNUD) brindaron asistencia técnica fundamental para concretar este proyecto.

En el presente documento se describe la metodología aplicada para la elaboración de la cartografía de cobertura de bosque nativo de Uruguay para el año 2021, a partir de técnicas de procesamiento de imágenes satelitales, utilizado para la estimación del KPI-2 del BIICC: Mantenimiento del área de bosque nativo (en hectáreas) con respecto al año de referencia (en %).

La elaboración de la cartografía fue coordinada por la División Evaluación e Información de DGF del MGAP junto con la Dirección Nacional de Cambio Climático del MA y realizada por un equipo integrado por 6 técnicos: un supervisor técnico de la cartografía y del equipo de intérpretes; una experta en estadística a cargo de la validación de la cartografía y cinco intérpretes con conocimiento en interpretación de usos/coberturas del suelo a partir de imágenes satelitales, que participaron de la edición post-clasificación y de la validación de la cartografía.

2. MATERIALES Y MÉTODOS

El flujo de trabajo propuesto tuvo como resultado la clasificación supervisada basada en objetos de imágenes satelitales adquiridas a través de los sensores Sentinel, capturadas por la Agencia Espacial Europea (ESA), para obtener una cartografía de cobertura de bosque nativo.

La clasificación de imágenes hace referencia a la tarea de extraer clases de información de una imagen multibanda y la metodología utilizada fue desarrollada específicamente y ajustada a las características de los bosques del territorio uruguayo.

Se trabajó con la plataforma de computación en la nube Google Earth Engine (GEE) (Gorelick et al., 2017), para el procesamiento y análisis de imágenes satelitales de acceso abierto, junto con los softwares QGIS y ArcGIS Pro para realizar los geoprocесamientos.

La metodología aplicada para la elaboración del mapa de bosque nativo constó de las siguientes etapas que serán detalladas más adelante en este informe y se esquematizan en la siguiente figura (Figura 1): Búsqueda y selección de datos; Clasificación supervisada; Post-clasificación; Análisis de exactitud.

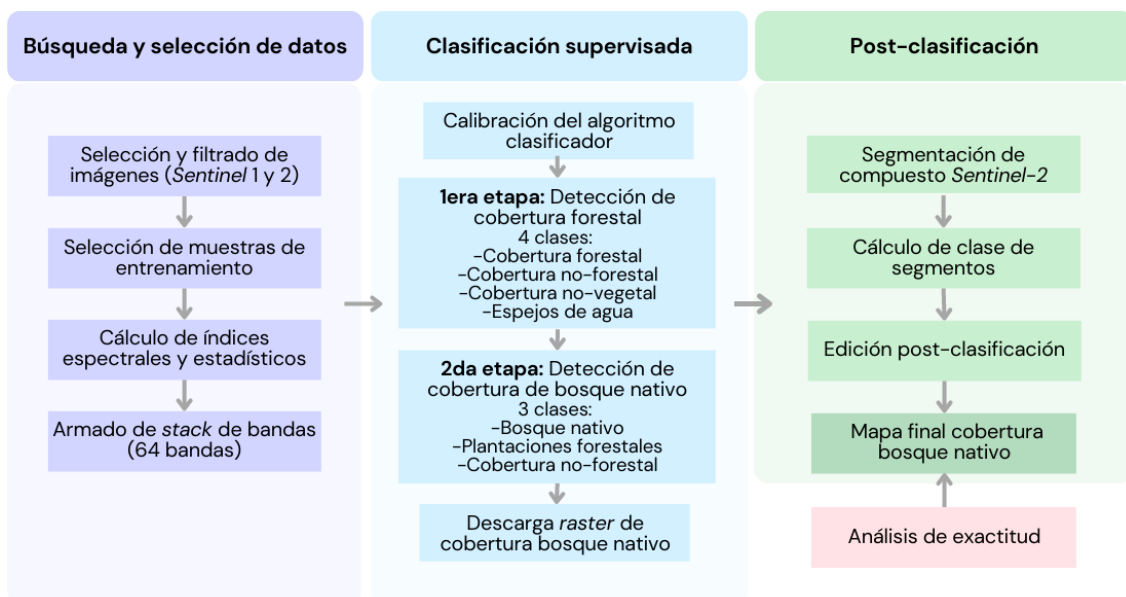


Figura 1. Esquema del proceso de elaboración de la cartografía de bosque nativo para el año 2021.

La descripción del proceso de análisis de exactitud, correspondiente a la validación de la cartografía y sus resultados, se incluye en el informe específico denominado: "Informe de Validación de la Cartografía de Bosque Nativo de Uruguay creado a partir de imágenes Sentinel 2021".

2.1. Búsqueda y selección de datos

2.1.1. Datos satelitales

La búsqueda de datos preparados para el análisis, intercalibrados y que cumplen con los requisitos de calidad geométrica y radiométrica, se realizó en la nube por medio de la plataforma GEE.

La selección de las escenas se realizó teniendo en cuenta factores como la presencia de nubes y la mayor cercanía posible entre las fechas de las distintas imágenes seleccionadas, tomando como referencia el período entre los meses de octubre 2021 y febrero 2022. Se seleccionaron series temporales de fechas próximas al período de primavera-verano para que la señal espectral que refleja la actividad fotosintética del bosque nativo sea clara. De esta forma, se evita el período de senescencia foliar de muchas especies que lo componen y se disminuyen los errores de clasificación por confusiones con otras coberturas, para obtener un mapeo más preciso del bosque nativo.

Se ha comprobado que la integración de imágenes satelitales SAR (radar de apertura sintética, por sus siglas en inglés) con imágenes multiespectrales (como pueden ser las imágenes Sentinel-2), puede lograr mejoras en las exactitudes de clasificaciones de uso/cobertura del suelo (e.g. Dobrinić et al., 2020; Heckel et al., 2020; Solórzano et al., 2021). Pensando en los objetivos del trabajo, se optó por fusionar datos satelitales de diferentes sensores (Sentinel-1 y Sentinel-2) en un mismo ambiente de trabajo. Se emplearon imágenes del sensor Sentinel-2 para aprovechar el potencial de discriminación espectral de sus recursos ópticos, combinando estos datos con imágenes del sensor Sentinel-1 (SAR) para la adquisición de datos libres de nubes.

Otro de los productos satelitales incorporados a la clasificación fue el modelo digital de elevación, de la misión *Shuttle Radar Topography Mission* (SRTM; Farr et al., 2007), a partir del cual se derivaron las siguientes variables topográficas: elevación (en metros) y pendiente (en grados). El SRTM es un producto mundial de libre acceso obtenido mediante interferometría de radar con una resolución espacial de 30 metros. El modelo fue adquirido para territorio de Uruguay, remuestreado a una resolución espacial de 10 metros y agregados al *stack* de datos dentro de la propia plataforma GEE. Este tipo de información topográfica, combinada con imágenes multitemporales, pueden ayudar a diferenciar el bosque nativo de otros usos del suelo que suelen generar confusión, y se han usado satisfactoriamente en clasificaciones por tipo de bosque (Liu et al., 2018; Hościło y Lewandowska, 2019).

Las imágenes de la colección Sentinel-1 *Ground Range Detected* (GRD) directamente disponibles en el catálogo de datos de GEE, ya se encuentran pre-procesadas en términos de ruido térmico, calibración radiométrica y corrección del terreno. De este sensor se emplearon imágenes de la banda C, con una resolución espacial de 10 metros en el modo descendente, en polarización dual (polarizaciones VH y VV por separado) adquiridas entre octubre de 2021 y febrero de 2022.

Posteriormente, a cada una de las polarizaciones se le aplicó un reductor de mediana para generar datos de series temporales (imagen compuesta mediana), que son menos susceptibles a las condiciones de adquisición de imágenes. La mediana de series temporales de imágenes es un indicador estadístico de uso común que se ha aplicado con éxito en la clasificación de usos del suelo (Mahdianpari et al., 2018; Liu et al., 2019).

Por otra parte, se confeccionó un compuesto de imágenes Sentinel-2 *MultiSpectral Instrument* (MSI), utilizando reductores para elegir los valores de medianas en el *stack* de píxeles de la colección. Esta colección se estructura de tal forma que, definiendo los parámetros de fechas y filtro de nubes, se seleccionan todas aquellas imágenes que cumplan con estos criterios, en este caso utilizando el período desde el 1° de octubre de 2021 al 1° de marzo de 2022 como filtro de fechas, obteniendo compuestos de imágenes completos para toda el área de interés, sin píxeles vacíos de información. Se utilizaron imágenes correspondientes al Nivel 2A (con correcciones radiométricas y atmosféricas). Los productos de Nivel 2A se entregan con una distancia de muestreo del suelo constante de 10, 20 y 60 metros, dependiendo de la resolución nativa de las diferentes bandas espectrales. Las imágenes multispectrales del sensor contienen 13 bandas espectrales: cuatro bandas a 10 metros, seis bandas a 20 metros y tres bandas a 60 metros de resolución espacial (Tabla 1).

Para la presente clasificación fueron seleccionadas todas las bandas de Sentinel-2, con resolución espacial de 10 y 20 metros (remuestreadas a 10 metros), con los valores de reflectancia a nivel de superficie (*Surface Reflectance*), es decir con correcciones atmosféricas ya incorporadas. Además de las bandas tradicionales del espectro visible e infrarrojo cercano (NIR), se trabajó con las bandas *Red Edge* (B5, B6, B7 y 8A), que están relacionadas con el contenido de clorofila de la vegetación, y con las bandas SWIR (B11 y B12), relacionadas con el contenido de agua. Dado que estas colecciones se encuentran corregidas geométrica y radiométricamente, la única corrección necesaria fue el enmascaramiento de los píxeles nubosos -nubes y sombras de nubes- de las imágenes. La presencia de nubes y sombras de nubes en las imágenes satelitales es uno de los inconvenientes a la hora de su procesamiento, por esta razón GEE cuenta con una función que permite filtrar o crear una máscara de píxeles nubosos. Este filtrado fue realizado utilizando la función *maskS2clouds* dentro de la plataforma GEE.

Tabla 1. Longitud de onda y resolución espacial de las bandas de Sentinel-2. Fuente: Instituto Geográfico Nacional de España (IGN).

Banda Sentinel-2	Longitud de onda central (μm)	Resolución espacial (m)
Banda 1 - Coastal aerosol	0,443	60
Banda 2 - Azul	0,490	10
Banda 3 - Verde	0,560	10
Banda 4 - Rojo	0,665	10
Banda 5 - Vegetation Red Edge	0,705	20
Banda 6 - Vegetation Red Edge	0,740	20

Banda 7 - Vegetation Red Edge	0,783	20
Banda 8 - NIR	0,842	10
Banda 8A - Vegetation Red Edge	0,865	20
Banda 9 - Vapor de agua	0,945	60
Banda 10 - SWIR - Cirros	1,375	60
Banda 11 - SWIR	1,610	20
Banda 12 - SWIR	2,190	20

De manera similar a los datos de Sentinel-1, se aplicó un reductor de mediana temporal a todas las escenas de Sentinel-2, generando características ópticas estacionales para las tareas de clasificación. La función de reductor de mediana permite la producción de conjuntos de datos estacionales sin nubes, en los que también se eliminan los píxeles ruidosos, muy oscuros o muy brillantes. La imagen compuesta mediana de Sentinel-2 para las bandas del espectro visible (RGB) fue descargada en formato *raster* para su posterior segmentación.

Además, a partir de las bandas originales de las imágenes Sentinel-2, fueron calculados varios índices espectrales para agregar esta información en el *stack* multibanda e incorporarlos como datos de entrada para el algoritmo clasificador. Un índice espectral es un valor obtenido de los datos de sensoramiento remoto, a través de cálculos de bandas espectrales (Jackson y Huete, 1991). Los índices utilizados fueron NDVI (*Normalized Difference Vegetation Index*) (Rouse et al., 1974), EVI (*Enhanced Vegetation Index*) (Justice et al., 1998), NDWI (*Normalized Difference Water Index*) (Gao, 1996) y MSAVI (*Modified Soil-Adjusted Vegetation Index*) (Richardson y Wiegand, 1977).

El *stack* multibanda fue completado mediante el cálculo de indicadores estadísticos de la serie temporal (medianas, mínimos, máximos y varianza) para cada una de las bandas usadas de Sentinel-2 y para cada uno de los índices espectrales, durante toda la serie temporal de imágenes utilizadas (del 1° de octubre de 2021 al 1° de marzo de 2022). En particular para el NDVI, se agregaron también al *stack* multibanda, cuatro medianas mensuales para el período noviembre/2021 a febrero/2022. Estas métricas se pueden aplicar directamente a las bandas o los índices derivados de ellas, y pueden ser representativas de las diferentes etapas estacionales de la cobertura del suelo provocadas por regímenes fenológicos de la vegetación, regímenes hidrológicos o de uso del suelo (Muro et al., 2020). En total se contó con 64 bandas de datos satelitales que fueron utilizadas como elementos de entrada por el algoritmo clasificador, las cuales se resumen en la siguiente figura (Figura 2 y Figura 3).

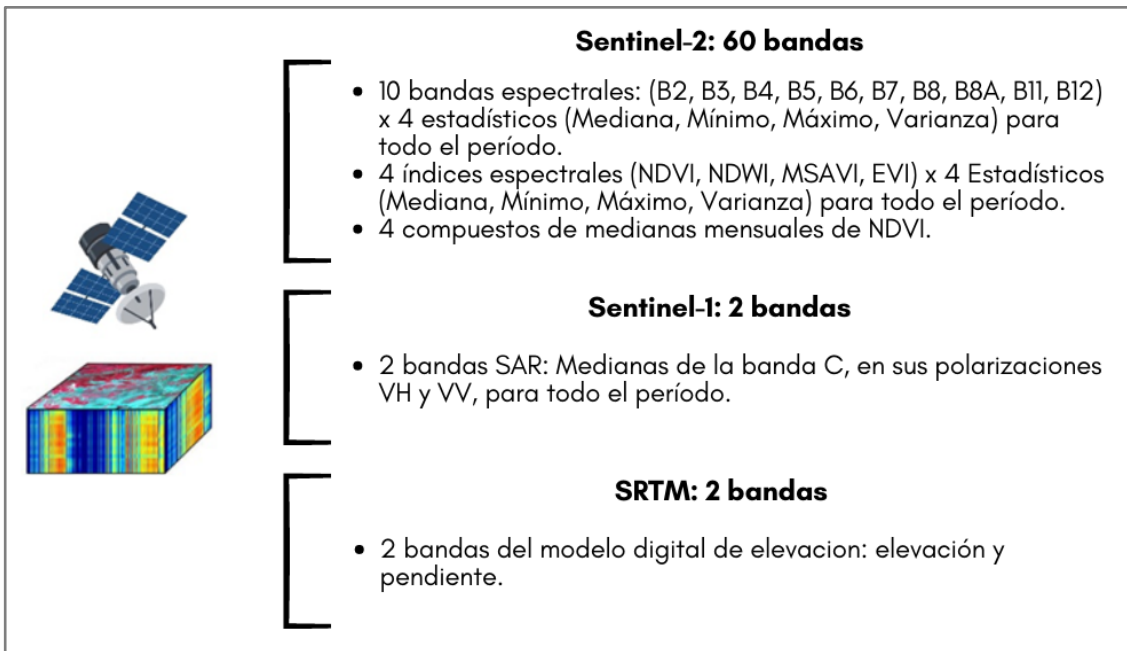


Figura 2. Resumen de datos satelitales utilizados por el algoritmo clasificador.

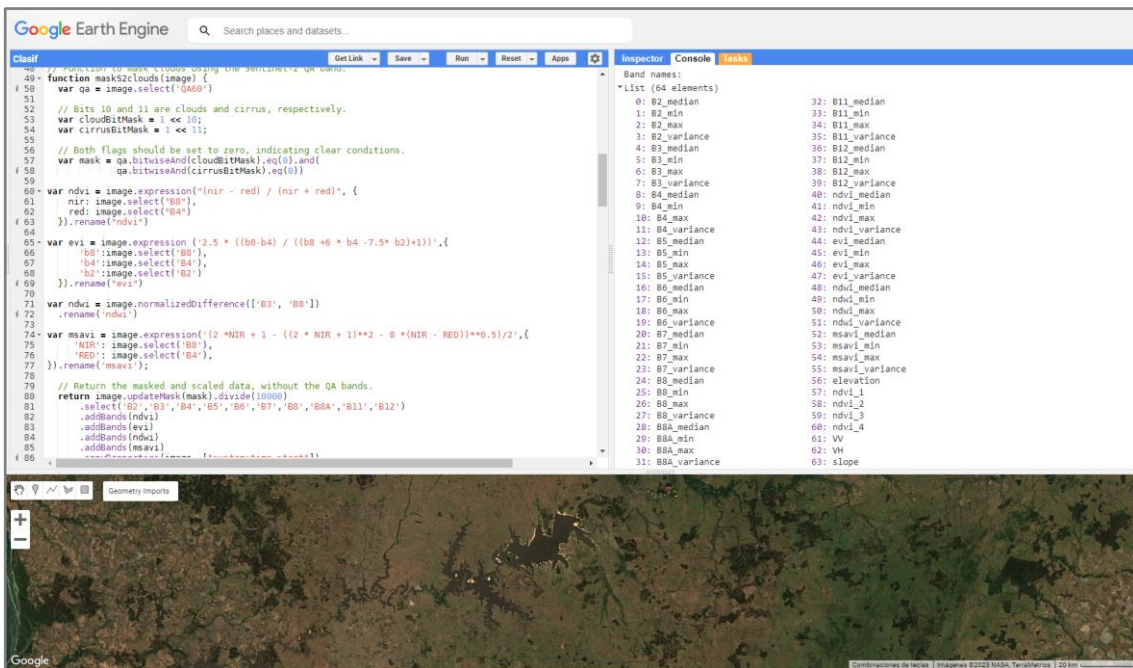


Figura 3. Captura de pantalla de Google Earth Engine, visualizando las bandas utilizadas para la clasificación.

2.1.2. Selección de muestras de entrenamiento

Para el diseño de la leyenda de la clasificación, se partió de las siguientes definiciones conceptuales para distinguir entre las diferentes categorías de uso/cobertura del suelo:

Bosque nativo: se refiere a áreas cubiertas por asociaciones vegetales en las que predomina el componente arbóreo, que mantienen sus características naturales. Se incluyen en esta categoría todos los tipos de bosque nativo.

Tanto para la selección de muestras de entrenamiento como para la edición post-clasificación, se utilizó la siguiente definición operativa de bosque nativo: área con cobertura de copas de especies nativas mayor o igual al 30% y una superficie terrestre mínima de 0,5 ha. Esta definición no considera la altura de los árboles ni otros umbrales, como por ejemplo ancho mínimo.

Plantaciones forestales: áreas predominantemente ocupadas por árboles implantados de especies exóticas, mayoritariamente de los géneros *Pinus* y *Eucalyptus*. Esta clase abarca tanto las plantaciones comerciales en pie, montes de abrigo y sombra de árboles exóticos, así como bosques protectores implantados.

*Las dos clases anteriores “Bosque nativo” y “Plantaciones forestales” conforman la categoría “Cobertura forestal” utilizada en la primera etapa de la clasificación.

Cobertura no-forestal: esta clase comprende aquellas áreas que al momento de captura de las respectivas imágenes satelitales se encontraban provistos de biomasa aérea pero sin un componente arbóreo predominante (pastizales naturales, humedales, matorrales o arbustales, cultivos agrícolas, cultivos hortícolas, pasturas implantadas y áreas urbanizadas cubiertas con vegetación herbácea o arbustiva, sin un componente arbóreo predominante).

Cobertura no-vegetal: esta clase comprende aquellas áreas que al momento de captura de las respectivas imágenes satelitales no se encontraban provistos de biomasa aérea (suelo desnudo, área urbanizada y arena).

Espejos de agua: comprende los cuerpos de agua continentales, tanto los de origen natural como los artificiales. Dada la resolución espacial de las imágenes empleadas y dentro de los alcances del proceso de clasificación supervisada, se incluyeron algunos cursos de agua cuyo ancho de canal fuera de al menos 10 m.

A continuación, se muestran algunos ejemplos (Figura 4 y Figura 5) de las categorías de la leyenda utilizada para la elaboración del mapa de bosque nativo, a través de una visualización de imágenes Google Earth (izquierda), comparándolas con subescenas Sentinel-2 (derecha), en una visualización falso color (combinación B8/B11/B3):




Figura 4. Visualización de imágenes Google Earth y subescenas Sentinel-2, ejemplificando la clase correspondiente a bosque nativo: a) bosque fluvial o ribereño; b) bosque de quebrada; c) bosque de parque; d) bosque serrano.




Figura 5. Visualización de imágenes Google Earth y subescenas Sentinel-2, ejemplificando las clases correspondientes a: a) Cobertura no-vegetal (área urbanizada); b) Cobertura no-forestal (cultivo agrícola); c) Plantaciones forestales; d) Espejos de agua.

Algunos de los desafíos que conlleva el mapeo de los bosques nativos en Uruguay son: la baja superficie relativa que ocupan con respecto al total del territorio; la confusión con plantaciones forestales de especies exóticas, tanto comerciales como no comerciales; la baja densidad de árboles en algunos casos (bosques de parque); la fragmentación y distribución en “parches” de ciertos bosques (bosques serranos) (Betancourt, 2021).

A su vez, existe cierta similitud en la respuesta espectral de algunos bosques nativos (principalmente en zonas riparias) con la de ciertos humedales del país, lo que dificulta aún más su discriminación mediante técnicas de sensoramiento remoto.

Dadas las características de estos ecosistemas y la complejidad que implica delimitarlos de forma precisa mediante sensoramiento remoto, es muy posible que una clasificación basada en píxeles que intente predecir áreas de cobertura de bosque nativo, esté incluyendo posibles falsos positivos (e.g. plantaciones forestales, cobertura de árboles de especies exóticas, matorrales o arbustales, humedales). A continuación, se presentan algunos ejemplos de posibles confusiones entre distintas clases de cobertura vegetal, que pueden dificultar la teledetección del bosque nativo en Uruguay (Figura 6).




Figura 6. Visualización de imágenes Google Earth y subescenas Sentinel-2, ejemplificando algunas coberturas de suelo que suelen confundirse con bosque nativo: a) humedales; b) plantación forestal joven; c) mezcla de especies arbóreas exóticas y nativas.

Teniendo en cuenta los desafíos mencionados anteriormente, se tuvo especial cuidado en la selección de la muestra de entrenamiento para la presente clasificación.

La selección de muestras de entrenamiento se realizó mediante digitalización manual de polígonos de entrenamiento en la plataforma GEE en base a interpretación visual precisa de los compuestos de imágenes Sentinel-2, (en sus visualizaciones de color verdadero y falso color) para el período de estudio. Además, se utilizaron también imágenes satelitales de alta resolución, disponibles en los mapas base de Google Earth dentro de la plataforma GEE, como información complementaria.

Sobre estos compuestos se seleccionaron polígonos ubicados sobre los tipos de coberturas que representan las distintas clases que se pretenden diferenciar en cada una de las etapas de la clasificación. Se consideraron sitios homogéneos para la recolección de muestras de referencia para mitigar el efecto de los píxeles mixtos, al evitar áreas fragmentadas o de coberturas de suelo heterogéneas.

Los polígonos de entrenamiento fueron distribuidos de manera homogénea y aleatoria en el territorio, intentando abarcar todas las regiones del país y tipos de bosque, como puede observarse en la Figura 7.

El número de polígonos de entrenamiento en una primera corrida del clasificador, fue asignado de forma aproximadamente equitativa para cada una de las clases definidas, en las dos etapas de la clasificación. Luego en base a juicio de experto, se agregó mayor número de muestras de las clases de interés y de mayor heterogeneidad espectral (clases del estrato forestal y cobertura no-forestal), en sitios donde se observaba confusión entre clases, y de esta manera concentrar los esfuerzos en el ajuste de la exactitud de estas clases.

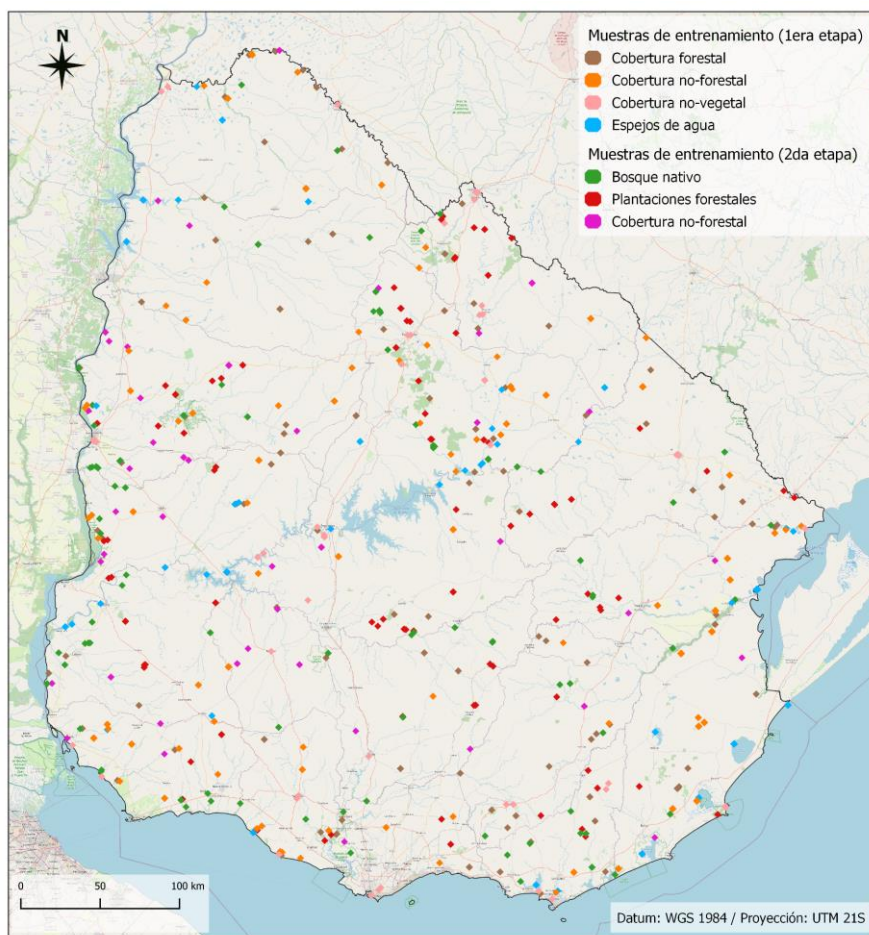


Figura 7. Ubicación de las muestras de entrenamiento seleccionadas, discriminadas por clase.

En total fueron digitalizados 498 polígonos para entrenar el algoritmo clasificador de las dos etapas de la clasificación, siendo cada píxel (10 metros de lado) dentro de estos polígonos las unidades de muestreo.

Como se detalla en el siguiente apartado, el mapa de bosque nativo fue realizado mediante dos clasificaciones supervisadas: la primera para obtener una capa base de la cobertura forestal y la segunda para diferenciar entre bosque nativo y plantaciones forestales con el fin de lograr una mejor discriminación entre estas dos clases.

En la primera etapa se interpretaron: 102 polígonos para la clase “Cobertura forestal” (14.823 píxeles); 89 polígonos de la clase “Cobertura no-forestal” (12.472 píxeles); 46 polígonos para la clase “Cobertura no-vegetal” (6.550 píxeles); 41 polígonos de “Espejos de agua” (6.955 píxeles). Para la segunda etapa, trabajando dentro del área de “Cobertura forestal”, se definieron: 93 polígonos de la clase “Bosque nativo” (10.195 píxeles); 83 polígonos de “Plantaciones forestales” (9.207 píxeles); 44 polígonos de “Otras coberturas/Cobertura no-forestal” (5.887 píxeles), correspondiendo a sitios de confusión de la primera clasificación, donde interpretando las imágenes de referencia no se observaba cobertura predominante de árboles.

Tabla 2. Tabla resumen de muestras de entrenamiento seleccionadas para cada clase.

Clase	Cantidad de polígonos	Cantidad de píxeles
1era etapa		
Cobertura forestal	102	14.823
Cobertura no-forestal	89	12.472
Cobertura no-vegetal	46	6.550
Espejos de agua	41	6.955
2da etapa		
Bosque nativo	93	10.195
Plantaciones forestales	83	9.207
Cobertura no-forestal	44	5.887

2.2. Clasificación supervisada

La clasificación de los datos satelitales digitales es el proceso en el que los píxeles de la imagen se agrupan en clases o categorías individuales en función de su similitud en los valores de los datos (Chuvieco, 2010). La clasificación supervisada utiliza información espectral obtenida de muestras correspondientes a distintos tipos de cobertura para clasificar toda una imagen o un mosaico de imágenes. En este caso, el clasificador utilizó la información de la combinación de bandas e índices establecidos de cada imagen que compone el *stack* (Figura 2), asignándole una clase a cada píxel de la imagen compuesta. Esta etapa se llevó a cabo también en la plataforma de GEE.

Para la generación de una capa correspondiente a la cobertura de bosque nativo, se optó por un esquema de clasificación en dos niveles. En la primera etapa (Detección de cobertura forestal) se aplicó una clasificación supervisada para distinguir un estrato forestal (que abarca el área cubierta por plantaciones forestales y por bosques nativos o naturales), diferenciándolo del resto de coberturas del suelo, para luego enmascarar sobre esta capa y aplicar una nueva clasificación supervisada. La segunda etapa (Detección de bosque nativo) consistió en distinguir el bosque nativo dentro de la máscara de cobertura forestal. De esta forma, la leyenda para la primera clasificación consistió de cuatro clases: Espejos de agua, Cobertura forestal, Cobertura no-forestal y Cobertura no-vegetal. La leyenda para la segunda etapa de la clasificación consistió en tres clases: Bosque Nativo, Plantaciones forestales y Otras coberturas/Cobertura no-forestal (en esta clase se trató de clasificar sitios de confusión de la primera etapa de la clasificación, donde la cobertura no correspondía a cobertura forestal).

2.2.1. Detección de cobertura forestal

La primera etapa de la clasificación consta de una estratificación inicial en cuatro clases de cobertura de suelo: Espejos de agua, Cobertura forestal, Cobertura no-forestal y Cobertura no-vegetal.

A partir de esta clasificación se crea una “máscara” para extraer todas aquellas zonas cuya cobertura corresponde a los estratos de bosque (plantado o nativo). Para esto se seleccionaron muestras de entrenamiento para cada estrato, sobre los tipos de coberturas que representan las distintas clases que se pretenden diferenciar en esta etapa. La clasificación supervisada se basa en toda la información del *stack* multibanda, obtenida de las muestras de entrenamiento correspondientes a distintos tipos de uso/cobertura de suelo, para clasificar todo el compuesto de imágenes.

Se utilizó la plataforma GEE, aplicando el modelo no-paramétrico de clasificación *Random Forest* (Breiman, 2001) con 100 árboles de decisión como parámetro principal y el subconjunto mencionado de muestras de entrenamiento. Este algoritmo es una poderosa herramienta de clasificación con tendencia a una alta tasa de precisión, capacidad de manejar grandes conjuntos de datos y es menos intensivo desde el punto de vista computacional que otros métodos (Gislason et al., 2006). *Random Forest* es un método de aprendizaje que opera promediando una gran cantidad de árboles de decisión generados aleatoriamente para un modelo final único con baja varianza y alta precisión (Breiman, 2001; Liaw y Wiener, 2002).

2.2.2. Detección de bosque nativo

Una vez que se cuenta con una capa “máscara” del estrato de cobertura forestal, se pasa a clasificar el mismo entre tres clases: Bosque Nativo, Forestación y Otras coberturas/Cobertura no-forestal. Para esto se realiza un proceso muy similar al anterior, con el mismo algoritmo clasificador de *Random Forest* (y mismos parámetros), pero con las muestras de entrenamiento correspondientes a la segunda etapa de la clasificación (Tabla 2), y enmascarando por el mosaico anterior de forma tal que se clasifican sólo los píxeles correspondientes al área donde existe cobertura arbórea. La selección de las muestras de entrenamiento para la clasificación también se hizo por medio de interpretación visual, basándose en la imagen compuesta e imágenes de alta resolución disponibles.

En esta etapa de la clasificación se aplicó la herramienta de *majority*, la cual consiste en un filtro de píxeles para eliminar el llamado efecto “sal y pimienta” o de píxeles aislados, logrando suavizar el producto resultante. Como resultado se obtuvo una capa correspondiente a los bosques considerados en el alcance de la presente actividad (es decir, solo la categoría “Bosque nativo”), la cual fue descargada en formato *raster* para su posterior procesamiento.

2.3. Post-clasificación

2.3.1. Segmentación

Para realizar un análisis de imágenes basado en objetos, se procedió a segmentar la imagen compuesta Sentinel-2, mediante la herramienta de segmentación del software ArcGIS Pro, en base a su información espectral.

El análisis de imágenes basado en objetos proporciona una metodología alternativa al análisis basado en píxeles, utilizando una combinación de forma y tamaño, además de la información espectral, para clasificar los datos de la imagen (Hay et al., 2005). Los objetos o segmentos son regiones, que se producen por uno o más criterios de homogeneidad en una o más dimensiones (Blaschke, 2010). Estos objetos se originan mediante un proceso de segmentación de imágenes en el cual píxeles cercanos entre sí y con similares características espectrales se agrupan en un segmento, representando entidades del terreno.

Idealmente, una imagen segmentada representará objetos discretos, al mismo tiempo que los representará completa y separadamente de los objetos vecinos. Un grupo de píxeles vecinos (agrupados en base a su homogeneidad espectral y a su arreglo espacial) puede representar mejor las características de los objetos que píxeles individuales (Whiteside et al., 2011), además de hacer más fácil el manejo de los datos generados. Una de las ventajas de la segmentación es que crea objetos que representan tipos de cobertura terrestre que pueden ser espectralmente variables a nivel de píxel y, por lo tanto, elimina el llamado efecto “sal y pimienta” típico de las clasificaciones basadas en píxeles (Whiteside et al., 2011).

Los parámetros utilizados para segmentar el compuesto de imágenes Sentinel-2 fueron: Rango Espacial (20), Detalle Espectral (18) y Tamaño mínimo de segmentos (50).

El Rango Espacial refiere al nivel de importancia que se le desea adjudicar a la proximidad entre las características de las imágenes, con un rango de valores que va de 1 a 20. Los valores pequeños producen resultados uniformes y espacialmente más suaves entre áreas agrupadas, mientras que los valores más altos son más apropiados cuando los elementos de interés son pequeños y deben combinarse (Wessel et al., 2018).

El Detalle Espectral establece el nivel de importancia dado a las diferencias espectrales de las características de las imágenes, con valores de 1 a 20. Los valores más bajos dan lugar a un mayor suavizado y a tiempos de procesamiento más largos, mientras que valores altos son apropiados para características que deben clasificarse por separado pero que tienen características espectrales algo similares (Wessel et al., 2018; ESRI, 2022).

El parámetro Tamaño mínimo de segmentos está directamente relacionado con su unidad mínima de mapeo. Los segmentos más pequeños de este tamaño se fusionan con su segmento vecino que mejor se ajuste. Las unidades se expresan en píxeles y al tratarse en este caso de 50 píxeles, la unidad mínima de mapeo equivale a 0,5 hectáreas, tal como fue expresado en la definición operativa de bosque nativo.

El resultado es un conjunto finito de objetos, que carecen aún de una categoría de la leyenda, la cual se asigna en un posterior proceso de clasificación. Tanto los productos de la segmentación (archivo vectorial), como de la clasificación supervisada, fueron exportados para la posterior aplicación de ediciones/correcciones en ambiente SIG.

A continuación, se muestra un sitio ejemplo de la imagen compuesta Sentinel-2 (Figura 8) y el resultado luego de la segmentación de la misma (Figura 9).



Figura 8. Visualización en color verdadero (combinación B4/B3/B2) de subescena Sentinel-2.




Figura 9. Ejemplo de segmentación de imagen Sentinel-2, con visualización en color verdadero de base.

2.3.2. Cálculo de clase de segmentos

En esta fase del proceso se empleó la herramienta de estadística de zona en el software QGIS, con el objetivo de asignarle una clase a cada objeto (segmento) mediante un cálculo del estadístico de mayoría, determinando la clase mayoritaria de cada uno, tratándose en este caso de las clases Bosque nativo/No bosque.

Para ello se partió del archivo vectorial (formato *shapefile*) generado en el paso anterior y la clasificación de bosque nativo en formato *raster*, descargados de la plataforma GEE. Este proceso generó una nueva columna en el archivo vectorial de entrada -en este caso, en el archivo que contiene los segmentos- con el valor binario de la clase numérica mayoritaria para cada uno de los segmentos (1=Bosque nativo; 0=No bosque). La categoría “No bosque” del mapa preliminar engloba todos los segmentos donde la cobertura mayoritaria pertenece al resto de las coberturas de suelo que no son “Bosque nativo”.

2.3.3. Edición post-clasificación

Una vez obtenidos los segmentos categorizados (Bosque nativo/No bosque) se realizó una revisión, por parte de un equipo de cinco intérpretes, en la cual se verifica si su clasificación se encuentra acorde a lo observado en la información de apoyo (imágenes satelitales y aéreas de alta resolución). Para la revisión de los segmentos categorizados se elaboró una cuadrícula que permitió mantener un orden para el trabajo de edición y se dividió el territorio en cinco zonas, asignándole una zona a cada uno de los intérpretes.

Las correcciones se realizaron mediante interpretación visual de segmentos mal clasificados en la etapa anterior, en base a imágenes de alta resolución disponible (Google Satellite, ESRI Satellite, ortofotografías aéreas de la Infraestructura de Datos Espaciales de Uruguay [IDEUy]) y el compuesto de imágenes Sentinel-2 del mismo período de fechas utilizado para la clasificación. A dichos objetos mal clasificados se les asignó la clase correcta de tipo de cobertura (Bosque nativo/No bosque).

Para esta etapa se respetaron los criterios de la definición operativa de bosque nativo, mencionada anteriormente en el documento. Al tratarse de varios intérpretes, estos fueron capacitados y estuvieron en comunicación durante todo el proceso, para garantizar la coherencia y acordar un enfoque común para etiquetar dichos casos de segmentos mal clasificados.

Todas las etapas de la metodología detalladas anteriormente, fueron desarrolladas con el fin de sortear las dificultades que implica el mapeo preciso de los bosques nativos de Uruguay y su diferenciación de otros tipos de uso/cobertura del suelo que pueden presentar similitudes en cuanto a su comportamiento espectral, medido a través de sensores remotos.

En esta última etapa de edición post-clasificación, el objetivo fue corregir aquellas confusiones que aún presentaba el mapa preliminar. En particular, ciertas confusiones que pudieran persistir entre bosque nativo y plantaciones forestales se diferencian en esta etapa a partir de la interpretación visual en base a diferencias en la textura, forma del rodal y esquema de plantación.

A continuación, se muestra un sitio como ejemplo del proceso de edición visual post-clasificación de los segmentos (Figura 10). Allí se observa el caso de un segmento mal clasificado en el mapa preliminar como “No bosque” que cumplía con los criterios de la definición operativa de bosque nativo, al cual se le asignó manualmente la clase de “Bosque nativo” (Figura 10(c); segmento color violeta). Se observan también dos segmentos (Figura 10(c); segmentos color naranja), los cuales habían sido mal clasificados en el mapa preliminar como “Bosque nativo” y que fueron catalogados como “No bosque” en el mapa final, por no cumplir con el mínimo porcentaje de cobertura arbórea nativa de la definición operativa. El resto de los segmentos del mapa preliminar fueron interpretados como bien clasificados tanto para la clase “Bosque nativo” (Figura 10(b, c, d); segmentos color verde), como para la clase “No bosque”.




Figura 10. Ejemplo del proceso de edición post-clasificación: a) subescena Sentinel-2 en color verdadero; b) resultado preliminar del mapa de bosque nativo (en verde); c) resultado preliminar, resaltando segmentos mal clasificados, como Bosque nativo (en naranja) y como No bosque (en violeta); d) resultado post-edición del mapa de bosque nativo (en verde).

Las modificaciones necesarias (cambios de una clase a otra) se realizaron directamente en la tabla de atributos del archivo vectorial que contiene los segmentos (formato *shapefile*) con el software QGIS. Una vez finalizada la edición de los segmentos, se llevó a cabo una etapa de post-procesamiento del mapa, donde realizaron correcciones geométricas y topológicas también en QGIS.

2.3.4. Análisis de exactitud

El último paso de esta metodología consiste en validar o evaluar el mapa elaborado, de manera de estimar la exactitud temática de la clasificación. Los detalles metodológicos y resultados se presentan en el documento “Informe de Validación de la Cartografía de Bosque Nativo de Uruguay creado a partir de imágenes Sentinel 2021”.

La evaluación de la exactitud temática consiste en comparar la información del mapa con información de referencia considerada muy confiable, generalmente basada en muestreo de sitios de verificación, cuya clasificación se obtiene a partir de observaciones de campo o del análisis de imágenes satelitales más detalladas, que aquellas utilizadas para generar el mapa (Peralta-Higuera et al., 2001).

Para ello, se utilizó como información de referencia o “verdad de campo” una fuente de información de las distintas coberturas de la tierra independiente y de mayor resolución espacial que la utilizada para generar la clasificación (imágenes de Google Earth, ESRI, ortofotografías aéreas de la IDEUy). Cabe destacar que si bien el relevamiento aerofotogramétrico de la IDEUy de completa cobertura nacional fue realizado durante el período 2017-2018, las fotografías aéreas tomadas son de muy alta definición (resolución espacial de 0,2 metros).

La evaluación se realizó aplicando un muestreo aleatorio, estratificado por clase, considerando como unidad de análisis los segmentos del mapa. Para cada segmento de la muestra de validación se comparó la clase asignada en el mapa de cobertura de bosque nativo con la clase asignada a partir de la interpretación visual de imágenes de alta resolución (información de referencia o “verdad de campo”). Con los resultados obtenidos, se procedió a construir la matriz de confusión y calcular el porcentaje de acierto global, la exactitud del productor y usuario del mapa, con sus correspondientes intervalos de confianza (Olofsson et al., 2014).

3. RESULTADOS

A partir de la metodología detallada anteriormente, se obtuvo como resultado el siguiente mapa (Figura 11) de la cobertura de bosque nativo de Uruguay, para el año 2021 (resaltando su representación para mejor visualización). De acuerdo al mapa resultante, la misma ocupa una superficie de *847.181 ha*, correspondiendo aproximadamente al 4,84% de la superficie total del territorio terrestre del país.

También se presentan dos visualizaciones del mapa final a mayor escala, para dos sitios ejemplo con cobertura de bosque nativo, empleando fotografías aéreas de muy alta resolución (IDEUy) como imagen de base (Figuras 12-15).




Figura 11. Cartografía de cobertura de bosque nativo en Uruguay, para el año 2021.



Figura 12. Visualización de ortofotografías aéreas (IDEUy), para un sitio ejemplo con cobertura de bosque nativo fluvial y plantaciones forestales.




Figura 13. Visualización del resultado de la cartografía (en verde), para un sitio ejemplo con cobertura de bosque nativo fluvial y plantaciones forestales, con ortofotografías aéreas (IDEUy) de base.



Figura 14. Visualización de ortofotografías aéreas (IDEUy), para un sitio ejemplo con cobertura de bosque nativo de quebrada.




Figura 15. Visualización del resultado de la cartografía (en verde), para un sitio ejemplo con cobertura de bosque nativo de quebrada, con ortofotografías aéreas (IDEUy) de base.

3.1. Análisis de exactitud

Como fuera mencionado, los resultados del análisis de exactitud de la presente cartografía se incluyen en el documento “Informe final de la validación de la cartografía de bosque nativo de Uruguay, creado a partir de imágenes Sentinel 2021”.

4. BIBLIOGRAFÍA

Betancourt, A. (2021). *Evaluación del riesgo de los principales ecosistemas boscosos de Uruguay*. Tesis de Maestría en Ciencias Ambientales. Facultad de Ciencias. Udelar. Montevideo.

Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 65(1), 2-16.

Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.

Chuvieco, E. (2010). *Teledetección ambiental: la observación de la tierra desde el espacio*. Ed. Ariel. Barcelona. 608 p.

Congalton, R.G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote sensing of environment*, 37(1), 35-46.

Dobrinić, D., Medak, D., y Gašparović, M. (2020). Integration of multitemporal Sentinel-1 and Sentinel-2 imagery for land-cover classification using machine learning methods. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 91-98.

ESRI (2022). ArcGIS Pro Documentation: Segmentation. <https://pro.arcgis.com/en/pro-app/latest/help/analysis/image-analyst/segmentation.htm>.

Farr, T. G., Rosen, P. A., Caro, E., Crippen, R., Duren, R., Hensley, S., ... y Alsdorf, D. (2007). The shuttle radar topography mission. *Reviews of geophysics*, 45(2).

Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote sensing of environment*, 80(1), 185-201.

Gao, B.C. (1996). NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote sensing of environment*, 58(3), 257-266.

Gislason, P. O., Benediktsson, J. A., y Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern recognition letters*, 27(4), 294-300.

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., y Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of Environment*, 202, 18-27.

Hay, G. J., Castilla, G., Wulder, M. A., y Ruiz, J. R. (2005). An automated object-based approach for the multiscale image segmentation of forest scenes. *International Journal of Applied Earth Observation and Geoinformation*, 7(4), 339-359.

Heckel, K., Urban, M., Schratz, P., Mahecha, M. D., y Schullius, C. (2020). Predicting forest cover in distinct ecosystems: The potential of multi-source Sentinel-1 and-2 data fusion. *Remote Sensing*, 12(2), 302.

Hościło, A., y Lewandowska, A. (2019). Mapping forest type and tree species on a regional scale using multi-temporal Sentinel-2 data. *Remote Sensing*, 11(8), 929.

IPCC (2003). Good Practice Guidance for Land Use, land-Use Change and Forestry. Penman J., Gytarsky M., Hiraishi T., Kruger D., Pipatti R., Buendia L., Miwa K., Ngara T., Tanabe K. y Wagner F. (eds). Intergovernmental Panel on Climate Change (IPCC), IPCC/IGES, Hayama, Japan.

IPCC (2006). 2006 IPCC Guidelines for National Greenhouse Gas Inventories. Eggleston H.S., Buendia L., Miwa K., Ngara T. y Tanabe K. (eds). Intergovernmental Panel on Climate Change (IPCC), IPCC/IGES, Hayama, Japan.

Jackson, R. D., y Huete, A. R. (1991). Interpreting vegetation indices. *Preventive veterinary medicine*, 11(3-4), 185-200.

Justice, C. O., Vermote, E., Townshend, J. R., Defries, R., Roy, D. P., Hall, D. K., ... y Barnsley, M. J. (1998). The Moderate Resolution Imaging Spectroradiometer (MODIS): Land remote sensing for global change research. *IEEE transactions on geoscience and remote sensing*, 36(4), 1228-1249.

Liaw, A., y Wiener, M. (2002). Classification and regression by randomForest. *R news*, 2(3), 18-22.

Liu, Y., Gong, W., Hu, X., y Gong, J. (2018). Forest type identification with random forest using Sentinel-1A, Sentinel-2A, multi-temporal Landsat-8 and DEM data. *Remote Sensing*, 10(6), 946.

Liu, C. A., Chen, Z. X., Yun, S. H. A. O., Chen, J. S., Hasi, T., y PAN, H. Z. (2019). Research advances of SAR remote sensing for agriculture applications: A review. *Journal of integrative agriculture*, 18(3), 506-525.

Mahdianpari, M., Salehi, B., Mohammadimanesh, F., Homayouni, S., y Gill, E. (2018). The first wetland inventory map of newfoundland at a spatial resolution of 10 m using sentinel-1 and sentinel-2 data on the google earth engine cloud computing platform. *Remote Sensing*, 11(1), 43.

Muro, J., Varea, A., Strauch, A., Guelmami, A., Fitoka, E., Thonfeld, F., ... y Waske, B. (2020). Multitemporal optical and radar metrics for wetland mapping at national level in Albania. *Heliyon*, 6(8), e04496.

Olofsson, P., Foody, G., Herold, M., Stehman, S., Woodcock, C. y Wulder, M. (2014). Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148, 42-57.

Peralta-Higuera, A., Palacio, J. L., Mas, G. B. J., Velázquez, A., Victoria, A., Bermúdez, R., ... y Prado, J. (2001). Nationwide Sampling of Mexico with Airborne Digital Cameras: an Image Database to Validate the Interpretation of Satellite Data. American Society for Photogrammetry and Remote Sensing. In *18th Biennial Workshop on Color Photography & Videography in Resource Assessment. Amherst, Massachusetts* (pp. 1-9).

Rouse, J. W., Haas, R. H., Schell, J. A. y Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA special publication*, 351, 309.

Richardson, A.J., y Wiegand, C.L. (1977). Distinguishing vegetation from soil background information. *Photogrammetric engineering and remote sensing*, 43(12), 1541-1552.

Solórzano, J. V., Mas, J. F., Gao, Y., y Gallardo-Cruz, J. A. (2021). Land use land cover classification with U-net: Advantages of combining sentinel-1 and sentinel-2 imagery. *Remote Sensing*, 13(18), 3600.

Stehman, S. (1996). Estimating the kappa coefficient and its variance under stratified random sampling. *Photogrammetric Engineering and Remote Sensing*, 62(4), 401-407.

Wessel, M., Brandmeier, M., y Tiede, D. (2018). Evaluation of different machine learning algorithms for scalable classification of tree types and tree species based on Sentinel-2 data. *Remote Sensing*, 10(9), 1419.

Whiteside, T. G., Boggs, G. S., y Maier, S. W. (2011). Comparing object-based and pixel-based classifications for mapping savannas. *International Journal of Applied Earth Observation and Geoinformation*, 13(6), 884-893.