

UNIVERSIDAD DE LA REPÚBLICA

FACULTAD DE AGRONOMÍA

**DETECCIÓN DE SISTEMAS SILVOPASTORILES EN URUGUAY
MEDIANTE CLASIFICACIÓN DE IMÁGENES SATELITALES SENTINEL-2**

por

Javier CARDOZO GIORDANO

Facundo SELLANES PEÑA

**Trabajo final de grado
presentado como uno de los
requisitos para obtener el
título de Ingeniero Agrónomo**

MONTEVIDEO

URUGUAY

2026

Este Trabajo Final de Grado se distribuye bajo licencia

“Creative Commons **Reconocimiento - No Comercial - Sin Obra Derivada**”.



PAGINA DE APROBACIÓN

Trabajo final de grado aprobado por:

Director:

Ing. Agr. (Mag.) Iván Rizzo

Codirector:

Ing. Agr. (Dr.) Jaime González Tálice

Tribunal:

Ing. Agr. (Mag.) Iván Rizzo

Ing. Agr. (Dr.) Andres Hirigoyen

Ing. Agr. (Mag.) Gina Dogliotti

Fecha:

20 de mayo de 2026

Estudiantes:

Javier Cardozo Giordano

Facundo Sellanes Peña

AGRADECIMIENTOS

Agradecer al Ing. Agr. (Mag.) Iván Rizzo por su gran ayuda a la hora de la realización de este trabajo, el cual hubiera sido mucho más difícil por la complejidad y las herramientas utilizadas las cuales escapan al contenido de la carrera.

Además, agradecer al Ing. Agr. (Dr.) Jaime González por su disponibilidad a la hora de la realización de las correcciones finales de este trabajo.

Finalmente agradecer a nuestras familias y amigos los cuales fueron fundamentales para el cumplimiento de toda nuestra etapa académica cursada en la Facultad de Agronomía.

TABLA DE CONTENIDOS

PAGINA DE APROBACIÓN.....	3
AGRADECIMIENTOS	4
LISTA DE TABLAS Y FIGURAS	7
RESUMEN.....	8
ABSTRACT	9
1 INTRODUCCIÓN	10
2 OBJETIVOS.....	11
2.1 Objetivos generales	11
2.2 Objetivos específicos.....	11
3 REVISIÓN BIBLIOGRÁFICA.....	12
3.1 Producción forestal en Uruguay.....	12
3.2 Crecimiento y aportes del sector	12
3.3 Superficie plantada por especie y destinos de producción	13
3.4 Sistemas agroforestales.....	14
3.5 Sistema silvopastoril.....	15
3.5.1 Distribución geográfica y características estructurales de los SSP	15
3.6 Sensores remotos.....	17
3.7 Resolución espectral	18
3.8 Resolución espacial	19
3.9 Resolución temporal	19
3.10 Sentinel-2	20
3.11 Índices de vegetación.....	22
3.12 Clasificación de imágenes satelitales	22
3.12.1 Clasificación supervisada y no supervisada	22
3.13 Random Forest	23
3.14 Support Vector Machine.....	24
3.15 Google Earth Engine	25
4 METODOLOGÍA.....	27
4.1 Caracterización del área de estudio	27
4.2 Adquisición de imágenes satelitales.....	29
4.3 Clasificación supervisada.....	29

4.4	Validación de la clasificación	30
5	RESULTADOS	32
5.1	Clasificación de SSP	32
5.2	SSP Clasificación de especies dentro de rodales de SSP	41
6	DISCUSIÓN	50
7	CONCLUSIÓN	55
8	BIBLIOGRAFÍA	56

LISTA DE TABLAS Y FIGURAS

Tabla 1 Comparación del satélite Sentinel-2 con otros de capacidades parecidas	20
Tabla 2 Características de las 13 bandas espectrales captadas por Sentinel-2	21
Tabla 3 Matriz de validación de la clasificación supervisada de superficie para detectar SSP	36
Tabla 4 Resultados de indicadores de PC, PP y F1 para la clasificación supervisada de SSP	37
Tabla 5 Matriz de validación de la clasificación supervisada de superficie para detectar SSP	40
Tabla 6 Matriz de validación de la clasificación supervisada por especie dentro de los SSP	41
Tabla 7 Resultados de indicadores de PC, PP y F1 para la clasificación de especies	42
Tabla 8 Valores de firma espectral y desvío estándar por especie para las bandas utilizadas	48
Figura 1 Estructura del algoritmo RF.	24
Figura 2 Mapa de la zona de estudio con cuadrícula Sentinel-2 y especies presentes en los SSP	28
Figura 3 Diagrama de flujo de trabajo para la clasificación supervisada	31
Figura 4 Mapa con clasificación supervisada para detección SSP	33
Figura 5 Mapas de con clasificación de SSP en predio individual	34
Figura 6 Mapa tomado de Qgis con presencia del predio forestal cercano al pueblo de Reboledo	35
Figura 7 Gráfico de firma espectral por clase para las 4 bandas de Sentinel-2 utilizadas	38
Figura 8 Mapa clasificación supervisada para especies en los rodales de SSP plantados con <i>E. benthamii</i>	43
Figura 9 Mapa clasificación supervisada para especies en los rodales de SSP plantados con <i>E. globulus</i>	44
Figura 10 Mapa clasificación supervisada para especies en los rodales de SSP plantados con <i>E. globulus</i>	45
Figura 11 Mapa clasificación supervisada para especies en los rodales de SSP plantados <i>E. grandis</i>	46
Figura 12 Gráfico de firma espectral por especie de <i>Eucalyptus</i> para las 4 bandas de Sentinel-2 utilizadas	47

RESUMEN

El crecimiento del sector forestal en Uruguay ha impulsado el interés por integrar actividades forestales y ganaderas, aumentando la superficie destinada a sistemas silvopastoriles (SSP). Sin embargo, pese a su implementación desde hace años, aún existe limitada información sobre su desempeño. El objetivo de este estudio fue identificar y caracterizar SSP mediante el uso de imágenes satelitales multiespectrales del satélite Sentinel-2, por medio de una clasificación supervisada basada en el algoritmo Random Forest (RF). Se buscó distinguir los SSP del resto de las coberturas y clasificar las diferentes especies presentes en los rodales.

Para el desarrollo del trabajo se utilizó la cartografía de SSP disponible, la cual proporciona información relevante sobre los rodales, como la especie plantada, la estructura del sistema y el año de plantación. Asimismo, se empleó Google Earth Engine (GEE), una plataforma de libre acceso que ofrece una amplia biblioteca de imágenes Sentinel-2, herramientas de filtrado, gran capacidad de procesamiento mediante los servidores de Google y una consola en JavaScript que facilita la implementación de procesos de clasificación. Como resultado de la clasificación de coberturas, se obtuvieron valores de 0,87 en precisión del consumidor (PC), 0,86 en precisión del productor (PP) y 0,87 en F1-Score (F1) para la clase SSP. A nivel general, la clasificación alcanzó una exactitud global (EG) de 0,95 y un índice Kappa de 0,94. En contraste, la clasificación por especies presentó un desempeño considerablemente inferior, con una EG de 0,58 y un índice Kappa de 0,5. Los resultados por especie fueron heterogéneos: *Eucalyptus benthamii* obtuvo el mejor desempeño (F1 = 0,79), seguido por *E. grandis* (0,60) y *E. smithii* (0,55), mientras que *E. globulus*, *E. maidenii* y *E. dunnii* mostraron valores inferiores a 0,55. A pesar de estas limitaciones, el estudio demuestra que es viable clasificar SSP y sus especies mediante el uso de imágenes Sentinel-2. No obstante, la complejidad de estos sistemas y la baja resolución espacial de las imágenes dificultan la discriminación entre algunas de las especies.

Palabras clave: silvopastoreo, Sentinel-2, Google Earth Engine, Random Forest, *Eucalyptus*

ABSTRACT

The growth of the forestry sector in Uruguay has increased interest in integrating forestry and livestock activities, leading to an expansion of the area under silvopastoral systems (SPS). However, despite their implementation over several years, limited information is still available regarding their performance. The objective of this study was to identify and characterize SPS using multispectral satellite imagery from the Sentinel-2 satellite through a supervised classification based on the Random Forest (RF) algorithm. The aim was to distinguish SPS from other land cover types and to classify the different tree species present within the stands.

For the development of this study, the available SPS cartography was used, which provides relevant information on the stands, such as planted species, system structure, and year of establishment. In addition, Google Earth Engine (GEE) was employed, an open-access platform that offers a large archive of Sentinel-2 imagery, filtering tools, high processing capacity through Google servers, and a JavaScript-based console that facilitates the implementation of classification processes. As a result of the land cover classification, consumer's accuracy (CA) of 0.87, producer's accuracy (PA) of 0.86, and an F1-score of 0.87 were obtained for the SPS class. Overall, the classification achieved a global accuracy (GA) of 0.95 and a Kappa index of 0.94. In contrast, species-level classification showed a considerably lower performance, with a GA of 0.58 and a Kappa index of 0.50. Species-specific results were heterogeneous: *Eucalyptus benthamii* showed the best performance (F1 = 0.79), followed by *E. grandis* (0.60) and *E. smithii* (0.55), while *E. globulus*, *E. maidenii*, and *E. dunnii* presented F1 values below 0.55. Despite these limitations, the study demonstrates that it is feasible to classify SPS and their associated species using Sentinel-2 imagery. However, the structural complexity of these systems and the spatial resolution of the imagery hinder the discrimination of certain species.

Keywords: silvopastoral systems, Sentinel-2, Google Earth Engine, Random Forest, *Eucalyptus*

1 INTRODUCCIÓN

La forestación en Uruguay ha experimentado un crecimiento sostenido en los últimos años, lo que impulsó la expansión de plantaciones con fines comerciales principalmente de los géneros *Eucalyptus* y *Pinus* (Dirección General Forestal [DGF], 2024; Panario & Gutiérrez, 2007). Esta incorporación en un país históricamente ganadero como lo es Uruguay favoreció el desarrollo de los sistemas silvopastoriles (SSP), en los cuales diferentes componentes interactúan para mejorar la productividad y los servicios ecosistémicos (Carriquiry, 2011; Schinato, 2022). Este tipo de sistema se ha expandido en distintas regiones del país, principalmente bajo especies del género *Eucalyptus* (Sancho et al., 2021).

El desarrollo de la teledetección ha permitido abordar estas dinámicas productivas con mayor facilidad. En especial con los sensores multiespectrales, como los de Sentinel-2 que ofrecen de forma libre, una resolución espectral adecuada para distinguir diferentes coberturas vegetales y separar especies forestales, aprovechando la respuesta específica que presenta la vegetación en las bandas del espectro visible, infrarrojo cercano y borde rojo (DGF, 2021; Fyfe, 2003; Segarra et al., 2020). La disponibilidad de la plataforma de procesamiento en la nube Google Earth Engine (GEE), facilita el manejo de grandes volúmenes de datos y el empleo de algoritmos de clasificación supervisada como Random Forest (RF) y Support Vector Machine (SVM), los cuales han sido ampliamente utilizados en estudios forestales y de uso del suelo (Chen & Ishwaran, 2012; Torres, 2024).

En este contexto, la detección y caracterización de superficies bajo SSP mediante imágenes Sentinel-2 representa una herramienta gratuita relevante para mejorar el conocimiento sobre su distribución y composición forestal, así como para apoyar la planificación productiva y ambiental a escala nacional. Este estudio aborda estos puntos mediante la aplicación de métodos de clasificación supervisada y el análisis de la precisión de los resultados obtenidos.

2 OBJETIVOS

2.1 Objetivos generales

Identificar y caracterizar plantaciones forestales bajo régimen silvopastoril en Uruguay mediante la clasificación de imágenes satelitales Sentinel-2 utilizando técnicas de teledetección.

2.2 Objetivos específicos

- I. Detectar y delimitar áreas con sistemas silvopastoriles en Uruguay a partir del análisis de imágenes Sentinel-2 mediante algoritmos de clasificación supervisada.
- II. Diferenciar y clasificar las especies forestales presentes en estos sistemas utilizando técnicas de clasificación supervisada.
- III. Evaluar la precisión de los resultados obtenidos mediante la comparación con cartografía existente de bosques bajo sistemas silvopastoriles en Uruguay.

3 REVISIÓN BIBLIOGRÁFICA

3.1 Producción forestal en Uruguay

El impulso estatal al rubro forestal comenzó con la Ley Forestal de 1968 y se consolidó con la Ley N°15.939 de 1987, que estableció el marco legal para el desarrollo de la actividad (Panario & Gutiérrez, 2007). Esta última tuvo y mantiene el objetivo principal de promover la forestación mediante incentivos fiscales, subsidios y exoneraciones de impuestos para quienes inviertan en dicha actividad, así como declarar ciertas áreas del país según características del suelo como prioridad forestal. A su vez, la ley también regula la conservación de suelos y el manejo sostenible de los bosques para un uso sostenible en el tiempo (Ley N°15.939, 1987). Desde ese entonces el sector forestal ha tenido un crecimiento exponencial al punto de transformarse en uno de los principales rubros de exportación del país (Centro de Estudio de la Realidad Económica y Social [CERES], 2023).

Cerca del 75% de las hectáreas forestadas en Uruguay se ubica en suelos declarados de prioridad forestal. Estos suelos, considerados de baja productividad agrícola, cuentan con beneficios fiscales significativos destinados a incentivar la actividad forestal (CERES, 2023). Entre estos beneficios se encuentran exoneraciones en impuestos sobre la renta y al patrimonio, así como en el IVA para la compra de insumos específicos (CERES, 2023). Además, la normativa incluye incentivos como subsidios y facilidades para la importación de maquinaria especializada, lo que reduce los costos operativos y promueve la inversión en el sector forestal (CERES, 2023). Estos estímulos han sido clave para el crecimiento de la superficie forestada y han impulsado el desarrollo en áreas rurales menos rentables para la agricultura (CERES, 2023).

3.2 Crecimiento y aportes del sector

Comparando el sector en los últimos 15 años con Países como Suecia y Argentina, se puede ver que ha tenido una evolución muy significativa (CERES, 2023), al punto que Carlos Faroppa en 2023 dijo que el sector forestal es un porcentaje importante del PBI nacional, que llegará a ser más o menos entre 5 y 6% del PBI sobre fines del 2024 (Cardozo, 2023). Analizando los valores de mercado brindados por el Informe Anual Comercio exterior de Uruguay XXI de 2023 y 2024 se puede ver que como la celulosa pasó a ser el principal producto de exportación pasando de 2019 millones de dólares en 2023 a 2545 millones de dólares en 2024 mostrando un aumento

del 35%, mientras que el sector cárnico (El más grande históricamente) pasó de 2081 millones a 2026 millones mostrando una disminución del 2%. La exportación de celulosa representó el 20% del total y la de madera un 3% (Uruguay XXI, 2024).

Este gran desarrollo ha estado acompañado por inversiones en infraestructura, logística y generación de empleo, con una expansión en industrias asociadas como el aserrado, el debobinado y la producción de CLT impactando positivamente en la economía nacional (Fermi, 2023, 2024). Tal es así la generación de empleo que en 2022 las plantas de celulosa emplearon un aproximado de 25 mil personas, cifra que incrementarían en 10 mil puestos más con la operación de UPM 2 (Fermi, 2023). Además, el sector industrial impulsa el sector de transporte y logística, y brinda oportunidades laborales de calidad, ya que, ante deficiencias en las habilidades de los trabajadores, las empresas han asumido un rol activo en su capacitación de los trabajadores (Ackermann & Cortelezzi, 2017). Los productos forestales se buscan que sean renovables y sostenibles operando bajo altos estándares de sostenibilidad. Actualmente el 90% de sus plantaciones están certificadas por las normas FSC y PEFC (Boscana & Faroppa, 2023; Fermi, 2024).

3.3 Superficie plantada por especie y destinos de producción

Según lo reportado por la cartografía forestal nacional 2024 se identificaron más de 1.161.851 hectáreas efectivas dedicadas a la forestación, lo que representa aproximadamente el 6,6% del área del territorio nacional, sin incluir las más de 800 mil hectáreas de bosque nativo (CERES, 2023; DGF, 2024). Estas 1.161.851 hectáreas están conformadas por una pequeña variedad de especies dentro de los géneros *Eucalyptus*, *Pinus* y *Salix*. Siendo las principales de estos en *Eucalyptus*; *E. grandis* con 283.012 hectáreas, *E. dunnii* con 250.457, *E. globulus* con 94.682 hectáreas. En *Pinus*; *P. elliottii* y *P. taeda* con 128.497 hectáreas (DGF, 2024). Y en *Salix* teniendo una muy baja superficie comparando con otras especies de *Eucalyptus* no mencionadas, *Salix spp.* y *Populus spp.* con 3.096 hectáreas (DGF, 2024).

Este conjunto reducido de especies forestales responde a una lógica productiva orientada a distintos fines industriales. La producción de *Eucalyptus* se destina principalmente a la transformación industrial, tanto para la elaboración de celulosa como para procesos de aserrado y debobinado, con destino mayoritariamente a la exportación y, en menor medida, al mercado interno (Oficina de Programación y

Política Agropecuaria [OPYPA], 2019; Uruguay XXI, 2021). Además, la madera de *Eucalyptus* también se utiliza para la generación de energía, ya sea mediante la quema de biomasa sólida (como chips y aserrín) o a través de la combustión de licor negro en las plantas de celulosa (Uruguay XXI, 2021). Por su parte, la producción de madera de *Pinus* se orienta principalmente al aserrado y debobinado, con fines comerciales similares a los del *Eucalyptus* (OPYPA, 2019; Uruguay XXI, 2021).

3.4 Sistemas agroforestales

La interacción entre la forestación y la ganadería tiene tantos años como la implantación de la forestación en el país. La reducción en la disponibilidad del pastoreo y el aumento del costo de la tierra ha reforzado la interacción donde el ganado aprovecha las zonas no utilizadas por la forestación (Carriquiry, 2011). Los predios forestales normalmente presentan entre un 30 y 40% de zonas sin cobertura forestal por restricciones del suelo, como pueden ser bajos, drenajes naturales, callejones, cortafuegos, alambrados o líneas eléctricas (Carriquiry, 2011; Cubbage et al., 2012). Esto da la oportunidad al crecimiento de pasturas y malezas que de no ser consumidas aumentan el riesgo de incendios, además de que también se ejerce cierto control sobre especies invasoras (Carriquiry, 2011; Cubbage et al., 2012). Este aprovechamiento del total del área no solo aumenta los ingresos por la energía de la pastura, sino que también se ha visto una interacción positiva de la forestación hacia el ganado, donde el bosque protege al ganado reduciendo su gasto metabólico mejorando el uso de la energía brindada por la pastura (Carriquiry, 2011).

Los Sistemas Agroforestales (SAF) como tal, son un sistema sustentable de manejo de cultivos y de tierra que procura aumentar los rendimientos en forma continua, combinando la producción de cultivos forestales arbolados (que abarcan frutales y otros cultivos arbóreos) con cultivos de campo o arables y/o animales de manera simultánea o secuencial sobre la misma unidad de tierra, aplicando además prácticas de manejo que son compatibles con las prácticas culturales de la población local (Consejo Internacional para la Investigación en la Agroforestería, 1982, como se cita en Farrell & Altieri, 1999). Esto permite afrontar problemas de erosión de suelos, como también bajo rendimientos y escasez de productos forestales. La característica principal de los SAF es la capacidad de optimizar la producción de un ecosistema a través de una explotación diversificada (Benedetti & Espinoza, 1992).

3.5 Sistema silvopastoril

Dentro de los sistemas agroforestales se encuentran los sistemas silvopastoriles (SSP), estos se caracterizan por integrar los componentes animal, forrajero y forestal en unidades productivas con el objetivo de promover interacciones positivas entre estos componentes, diversificar los ingresos y preservar los ecosistemas (Carvalho & Xavier, 2005; Dogliotti, 2024; Schinato, 2022). Las posibilidades de combinación entre las especies, arreglos y manejos permiten la adecuación de estos sistemas a las variaciones ambientales de los sitios y a las condiciones socioculturales del medio social agrario. La multifuncionalidad de los SSP se relaciona con la búsqueda por la diversificación productiva, el uso de los recursos vegetales locales y la promoción de servicios ambientales (Schinato, 2022; Viñoles et al., 2022).

Las interacciones positivas se deben al cambio en el microclima, como puede ser la intercepción de la radiación mejorando el confort térmico en animales al igual que la disminución de la velocidad del viento atenuando la acción del frío en los animales en el viento (Munka, 2017; Sotomayor et al., 2009). También se ha demostrado que la presencia de coberturas vegetales reduce la amplitud térmica entre invierno y verano, aumentando las temperaturas en invierno y reduciendo las de verano (Munka, 2017). Cuanto más denso sea el monte, mayor influencia tendría sobre los cambios de temperatura del aire (Munka, 2017). Esta cobertura afecta la humedad del aire y del suelo, temperatura y también se ha visto una reducción en la pérdida de humedad en el suelo durante el verano que favorece el crecimiento vegetal (Sotomayor et al., 2009). Este cambio a nivel microclimático repercute en un menor gasto energético por parte del animal para regular su temperatura, lo que se traduce en un mayor aprovechamiento de la energía consumida para aumentar el peso vivo (Fedrigo et al., 2019), mejores niveles de fertilidad e impactos sobre la sanidad animal (Chen et al., 2015; Daramola et al., 2012).

3.5.1 Distribución geográfica y características estructurales de los SSP

Las plantaciones forestales bajo régimen silvopastoril de Uruguay se centran en tres grandes zonas. La zona de mayor superficie es la zona sur-este (5.066,25 ha) seguido de la zona centro-sur (976,34 ha) y como último la zona norte (349,98 ha), teniendo un total de 6.393,57 ha (Sancho et al., 2021). Las especies utilizadas son del género *Eucalyptus*, predominando en 2012 el *E. globulus* representando un 57% y

siendo la más frecuentes en la zona sur-sureste, en la zona norte el *E. grandis* es el que más predomina (Ministerio de Ambiente [MA], 2021; Sancho et al., 2021). El *E. globulus* spp. *globulus* es una de las especies de mayor rendimiento pulpable, ofreciendo condiciones inmejorables para su uso en SSP, puesto que posee una copa de escaso diámetro y follaje en relación con otras especies como lo es el *E. grandis*. Una de las desventajas que presenta el *E. globulus* es su alta susceptibilidad a enfermedades como lo ha sido el ataque de *Teratosphaeria nubilosa*, reduciendo fuertemente el desarrollo de nuevas plantaciones (Soares de Lima et al., 2020).

En cuanto a la implantación de los árboles, la densidad de plantación y el arreglo espacial como la distancia entre callejones y la disposición en líneas simples, dobles o triples pueden variar según la finalidad productiva de la madera (Almeida, 2017; Fedrigo et al., 2018). En zonas con relieve plano u ondulado suave se debe dar preferencia a la orientación de las líneas de los árboles en sentido Este-Oeste para maximizar la incidencia de la luz, mientras que en zonas de relieve ondulado las líneas de árboles deber ser dispuestas a nivel priorizando la conservación del suelo (Almeida, 2017).

En los SSP se observa un claro predominio de plantaciones en filas dobles o triples (87%) separadas por callejones, siendo los más frecuentes aquellos de entre 6 y 8 metros (80%). No obstante, en los sistemas más jóvenes, asociados a productores que conciben la forestación como un complemento al rubro ganadero, se registran callejones más amplios de 12 a 20m y densidades de plantación más bajas, con menos de 750 árboles ha⁻¹. En general, la mayoría de las plantaciones supera los 900 árboles ha⁻¹ (83%) (MA, 2021).

En cuanto al componente animal, la base forrajera utilizada es principalmente campo natural y en algunos casos se incorporan mejoramientos con leguminosas y otras gramíneas (MA, 2021; Silveira et al., 2017). Se observan cargas ganaderas de entre 0,6 y 0,9 UG ha⁻¹, ajustadas a la disponibilidad forrajera. La selección del tipo de ganado varía entre categorías adultas, jóvenes y ovinos, y predomina el pastoreo continuo, aunque algunos productores han comenzado a aplicar sistemas de pastoreo rotativo (Sancho et al., 2021).

A la hora de comparar los sistemas silvopastoriles con los forestales, podemos ver los resultados del estudio de Boscana et al. (2023) “Wood production and financial

return in two silvopastoral systems”, donde se compara un sistema forestal en un marco de plantación de 3.5×2.7 m con un SSP en un marco de 2×2 m y callejón de 8 m. En este concluyó que los sistemas silvopastoriles presentan la ventaja de combinar una producción de madera aceptable con ingresos adicionales ganaderos. Lo que concluye en un Ingreso Anual Equivalente similar, pero con la ventaja de que requiere una menor inversión de plantación y tener una mayor liquidez durante la rotación, mejorando la rentabilidad global del sistema frente a las plantaciones forestales (Boscana et al., 2023).

3.6 Sensores remotos

Teledetección es el conjunto de técnicas que permiten obtener información sobre objetos o fenómenos en la superficie terrestre sin necesidad de tener contacto físico directo con ellos. Esto se logra mediante la captación y análisis de la radiación electromagnética reflejada o emitida por dichos objetos, utilizando sensores montados en plataformas como satélites, aviones o drones (Sobrino, 2001). Estos sensores se clasifican en pasivos y activos, donde los pasivos captan la energía emitida por la superficie terrestre y los activos emiten energía hacia la superficie (Betti & Giraldez, 2020; Chuvieco-Salineró, 1996, como se cita en Hirigoyen, 2022; Jacobo et al., 2024).

Entre los sensores activos se encuentran principalmente el LiDAR (Light Detection and Ranging) y los sensores de radar. Estos dispositivos emiten su propia energía y registran la señal reflejada por los objetos para generar información de la superficie terrestre (García, 2010; Sobrino, 2001; Veneros et al., 2020). En el ámbito forestal, uno de los principales usos de estos sensores es la estimación de la altura relativa de la cubierta vegetal respecto a la superficie del suelo. Esta aplicación, al combinarse con modelos estadísticos como los lineales o RF, ha demostrado ofrecer buenos niveles de ajuste para la estimación de altura media dominante, índice de sitio, volumen total y biomasa aérea (Hirigoyen et al., 2020; Rizzo-Martín et al., 2023; Sobrino, 2001).

Dentro de los sensores pasivos se encuentran los multispectrales e hiperspectrales que registran la radiación electromagnética emitida en un rango del espectro de longitud de onda resultado de la interacción de la energía solar con la superficie en estudio (Chuvieco-Salineró, 1996, como se cita en Hirigoyen et al., 2022; Veneros et al., 2020). Estos sensores en el medio vegetal se pueden utilizar para la

determinación de producción de biomasa, detección estrés abiótico y biótico, detección de usos de suelo, cálculo de índices espectrales, entre otros (Becerra, 2021; Bloemberger et al., 2007, como se cita en Martínez-Barbáchano & Solís-Miranda, 2018; Segarra et al., 2020). Una de las principales limitaciones de los sensores pasivos satelitales es su dependencia de la radiación solar, lo que implica que su funcionamiento se ve afectado por condiciones climáticas adversas como la nubosidad, dificultando así la obtención de imágenes con calidad adecuada (Jacobo et al., 2024).

En el trabajo de Ruiz y Cardoso (2023) se puede ver la utilización de sensores pasivos junto a algoritmos de machine learning para la clasificación de las variables vegetales dentro de sistemas silvopastoriles. El estudio se enfocó en la clasificación de árboles mediante diferentes algoritmos, utilizando imágenes satelitales Planet Scope. Estas representan un promedio mensual, contando con una alta resolución espacial que abarcan bandas RGB e infrarrojo cercano (NIR). Estas imágenes permitieron detectar, contar y segmentar árboles individuales mediante el entrenamiento y evaluación de modelos de aprendizaje automático como lo son Detectree, MIPAR y Mask RCNN.

A la hora de utilizar la información de un satélite es fundamental comprender la resolución y las escalas de observación, esta nos determina la capacidad de monitoreo que tendremos a la hora realizar determinados muestreos. Las imágenes satelitales presentan distintas resoluciones como lo son la resolución espectral, la resolución espacial y la resolución temporal (Segarra et al., 2020).

3.7 Resolución espectral

La resolución espectral hace referencia a la capacidad de un sensor para diferenciar la radiación en diversas longitudes de onda dentro del espectro electromagnético (Paruelo, 2008; Tristán et al., 2008). Esta resolución depende de cuántas bandas puede registrar el sensor, del ancho de esas bandas y de su posición dentro del espectro (Camacho-Velasco et al., 2015; Liang & Wang, 2019; Tristán et al., 2008). Un sensor presenta mayor resolución espectral mientras presenta una mayor cantidad de bandas espectrales (Camacho-Velasco et al., 2015). Existen sensores hiperespectrales que capturan una mayor cantidad de información del espectro electromagnético en comparación con los sensores multispectrales. Por ello, las imágenes hiperespectrales se caracterizan por tener una resolución espectral más alta (Camacho-Velasco et al., 2015; Tristán et al., 2008).

3.8 Resolución espacial

Se llama resolución espacial al nivel de detalle que una imagen puede representar en el espacio (Liang & Wang, 2019; Sobrino, 2001; Tristán et al., 2008). Específicamente, indica el tamaño del área del terreno que corresponde a cada píxel de la imagen (Liang & Wang, 2019), el cual es la unidad mínima de las imágenes digitales (Torres, 2024). Debido a esto, cuanto menor sea el tamaño del píxel (por ejemplo, 2,5 metros por píxel), mayor será la resolución espacial, ya que se pueden distinguir objetos más pequeños en la superficie terrestre, permitiendo una mejor visualización y conocimiento de la zona de interés (Chuvienco, 2002, como se cita en Poveda-Sotelo et al., 2022; Segarra et al., 2020). Por el contrario, una resolución espacial baja (por ejemplo, 10 metros por píxel) implica menor nivel de detalle, ya que cada píxel representa una porción más grande del terreno.

La resolución espectral presenta igual importancia que la resolución espacial. Por ejemplo, el satélite SPOT posee una resolución espacial de 10 m en modo pancromático y de 20 m cuando opera con bandas multiespectrales. El satélite Landsat ofrece una resolución de 30m, pero en muchas aplicaciones resulta más adecuado que el SPOT, ya que cuenta con 7 bandas espectrales con respecto a 3 de este último, abarcando un rango espectral más amplio y con bandas más estrechas (Sobrino, 2001). Dentro de los satélites de libre acceso el Sentinel-2 se presenta como el más adecuado para nuestra tarea, ya que ofrece resoluciones espaciales de 10, 20 y 60 metros, junto con 13 bandas espectrales, lo que permite una mayor amplitud espectral (Tabla 1).

3.9 Resolución temporal

Se denomina resolución temporal a la frecuencia con la que el sensor capta una nueva imagen en la misma zona de la superficie terrestre (Gonzaga, 2014; Liang & Wang, 2019; Roman-Gonzalez & Vargas-Cuentas, 2013). En diferentes satélites la periodicidad depende generalmente de dos factores: Características orbitales como lo son la altura de la órbita, velocidad y ángulo del satélite, como diseño del sensor con características como ángulo y abertura de la observación (Sobrino, 2001; Tristán et al., 2008).

A continuación, se presenta la Tabla 1 donde se comparan los satélites más utilizados a nivel mundial en término de su resolución espectral, espacial y temporal.

Tabla 1*Comparación del satélite Sentinel-2 con otros de capacidades parecidas*

Resolución	Descripción/Satélite	Sentinel-2	Landsat 1-7	Spot
Resolución Temporal	Repetición de Ciclos (días)	5*	16	26
	Ancho de Franja (km)	290	185	2x60
Resolución espectral	Bandas Espectrales	13	7	4
Resolución espacial	Resolución espacial (m)	10, 20, 60	30, 60	2,5, 10, 20
	Acceso	Libre	Libre	No libre

Nota. Elaborado con base en European Space Agency (ESA, 2015) y Segarra et al. (2020).

3.10 Sentinel-2

Los satélites Sentinel fueron lanzados en 2014 como parte del programa Copernicus, una iniciativa de la ESA. Su resolución espacial varía según la banda espectral, con valores de 10, 20 o 60 metros (ESA, 2015). En cuanto a la resolución espectral, el sensor cuenta con cuatro bandas en el rango visible y nueve en el infrarrojo cercano y de onda corta (Tabla 2, Picone, 2017). Además, la alta resolución espacial (hasta 10 m) y temporal (revisita de hasta 5 días) permite aprovechar al máximo el detalle espacial y la frecuencia de adquisición de estas imágenes. Es por ello que estos datos han sido ampliamente utilizados en agricultura (Morell-Monzó & Garófano-Gómez, 2022) y a nivel forestal (DGF, 2024; Tovar et al., 2020).

La constelación Sentinel-2 está formada por dos satélites de las mismas características (Sentinel-2A y Sentinel-2B). El satélite Sentinel-2A se lanzó el 23 de junio de 2015 y el Sentinel-2B se lanzó el 7 de marzo de 2017. Ambos heliosíncronos, operan a una altura de 786 km sobre la superficie terrestre (Segarra et al., 2020). El sensor Multi-Spectral Instrument, que equipan ambos satélites, permite capturar imágenes con un tiempo de revisión de 10 días (5 días con ambos satélites) en 12 bandas espectrales desde B1 Coastal Aerosol de 0,443 μm hasta B12 SWIR 2 de 2,190 μm (ESA, 2021; Segarra et al., 2020). En estas resoluciones nos encontramos con 4 bandas de resolución 10 m teniendo 3 en la zona RGB que corresponde al espectro visible, estas son: azul visible de banda ancha clásico (490 μm), verde (560 μm) y rojo

(665 μm), además una en zona del infrarrojo con (842 μm). Luego tenemos 6 bandas de 20m dentro de las cuales tenemos 4 bandas estrechas en la zona borde rojo (red edge) de la vegetación (705, 740, 775 y 865 μm) la cual es una zona muy útil para detectar o inferir características biofísicas de las plantas. Y además en esta resolución de 20m tenemos dos en SWIR (1610 y 2190 μm) (Gatti & Bertolini, 2015; Segarra et al., 2020). Y a 60 m3 bandas dedicadas a la corrección atmosférica (443 μm para aerosoles y 940 para vapor de agua), para detección de cirros (1375 μm) (Gatti & Bertolini, 2015; Segarra et al., 2020).

Tabla 2

Características de las 13 bandas espectrales captadas por Sentinel-2

Región del espectro	Banda	Nombre	Longitud de onda central (μm)	Ancho de banda (μm)	Resolución espacial (m)
Visible	B1	Aerosol costero	443	20	60
	B2	Azul	490	65	10
	B3	Verde	560	35	10
	B4	Rojo	66	30	10
Borde rojo	B5	Borde rojo 1	705	15	20
	B6	Borde rojo 2	740	15	20
	B7	Borde rojo 3	783	20	20
Infrarrojo cercano	B8	Infrarrojo cercano (NIR)	842	115	10
	B8A	Vegetación RE (NIR)	865	20	20
Infrarrojo de onda corta	B9	Vapor de agua	945	20	60
	B10	SWIR Cirros	1375	30	60
	B11	SWIR 1	1610	90	20
	B12	SWIR 2	2190	180	20

Nota. Adaptado de ESA (2021) y Segarra et al. (2020).

Estas bandas pueden ser utilizadas tanto para la clasificación de superficies dado por la característica reflectancia de la vegetación, presentando una gran absorción en el espectro rojo y alta reflectancia en la región NIR (Fyfe, 2003; Xie et al., 2018). Por otra parte, también pueden ser usadas para la diferenciación de especies debido a características ópticas y morfológicas como puede ser la densidad de área foliar, ramas, forma de la hoja, rugosidad de la superficie de la hoja y estructura de la canopia (Stone, 2001; Youngentob et al., 2012).

3.11 Índices de vegetación

Los índices de vegetación son herramientas derivadas de la combinación de diversas bandas espectrales, estas permiten inferir propiedades biofísicas específicas de las plantas a partir de su reflectancia reflejada en las bandas (Segarra et al., 2020).

Las bandas que presenta el satélite Sentinel-2 posibilita el cálculo de índices de vegetación como, el NDVI (Normalized Difference Vegetation Index) propuesto por Tucker en 1979, que se obtiene mediante la siguiente combinación $(B8 - B4) / (B8 + B4)$. En este caso, la banda B8 corresponde al infrarrojo cercano (NIR) y la banda B4 a la del espectro rojo (red) (Hasanlou & Mostofi, 2015; Segarra et al., 2020). Este índice nos permite estimar de forma remota la biomasa verde y el vigor del cultivo, que a su vez se puede llegar a correlacionar con el contenido de nitrógeno en el cultivo (Hunt et al., 2005, como se cita en Segarra et al., 2020).

3.12 Clasificación de imágenes satelitales

La clasificación de imágenes satelitales es una técnica que permite extraer información de un gran número de imágenes satelitales, siendo un proceso de agrupación de píxeles en clases de uso de suelo (Fajardo, 2023; Karlsson, 2003). La clasificación permite diferenciar tipos de vegetación como bosques nativos, plantaciones agrícolas, plantaciones forestales e incluso diferenciar entre especies forestales. Existen varios métodos y técnicas de clasificación de imágenes satelitales, estas se pueden clasificar en tres categorías: automatizado, manual e híbrido (Abburu & Golla, 2015). A nivel forestal, esta técnica es una opción fundamental para diferenciar áreas, integración de datos para el seguimiento de la evolución de parámetros y generar mapas de cobertura forestal pudiendo mostrar su cambio a lo largo del tiempo (Torres, 2024).

3.12.1 Clasificación supervisada y no supervisada


Dentro de la clasificación de imágenes satelitales automatizadas nos encontramos con dos tipos, supervisada y no supervisada. La clasificación no supervisada consiste en agrupar los píxeles de una imagen en función de su semejanza espectral, sin requerir información previa sobre las clases temáticas presentes. En cambio, la clasificación supervisada se considera que requiere conocimiento del terreno y de las coberturas. En base en esta información se crean las zonas de entrenamiento para el algoritmo de clasificación (Posada et al., 2012; Rodríguez et al., 2015). Dicho

algoritmo calcula los parámetros estadísticos de cada banda para cada zona, para luego evaluar cada nivel digital de la imagen, compararlo y asignarlo a una respectiva clase (Posada et al., 2012; Rodríguez et al., 2015). Los algoritmos de clasificación supervisada más utilizados a nivel forestal son RF y SVM (Torres, 2024).

3.13 Random Forest

RF es un algoritmo de aprendizaje automático desarrollado para manejar problemas de alta dimensión, basado en la construcción de múltiples árboles de clasificación y regresión. Este combinado con imágenes de Sentinel-2 ha demostrado una precisión de clasificación óptima (Chen & Ishwaran, 2012; Gómez et al., 2019; Šumanovac, 2024). Los árboles se generan normalmente mediante la metodología CART (Classification and Regression Trees). Cada árbol se construye sobre una muestra aleatoria del conjunto de datos original (bootstrap) y a diferencia de CART tradicional, RF introduce aleatoriedad adicional en dos niveles (Chen & Ishwaran, 2012). Al seleccionar la muestra para cada árbol (bootstrap) y al elegir un subconjunto aleatorio de variables en cada nodo para determinar la mejor división para el nodo. La doble aleatorización aplicada en RF busca disminuir la dependencia entre los árboles individuales, lo que permite que el conjunto completo del modelo presente efecto bagging disminuyendo la varianza (Chen & Ishwaran, 2012).

Figura1
Estructura del algoritmo RF



Nota. Adaptado de Son y Yang (2022).

En un trabajo realizado en España (Torres, 2024), el análisis de diversos estudios dio que RF tiene ciertas ventajas ante otros métodos, pudiendo alcanzar buenas precisiones, determinar la importancia de las variables incluidas y mejorar la interpretación del modelo de otros métodos. Además, el estudio de Tovar et al. (2020), estimó la biomasa aérea en plantaciones forestales de *Eucalyptus grandis* y *Pinus spp* ubicadas en el departamento de Cauca (Colombia) mediante el uso de algoritmo RF combinando datos de radar de apertura sintética (SAR) de Sentinel-1A, datos ópticos de Sentinel-2A y datos de inventarios forestales. Como conclusión, se determinó que el RF combinado con imágenes Sentinel-2, tiene un buen potencial para estimar la biomasa aérea en plantaciones forestales. Sin embargo, los modelos presentan una precisión limitada (R^2 bajos) por lo que se va a requerir aumentar el tamaño muestral y desagregar especies del género *Pinus* para mejorar exactitud.

3.14 Support Vector Machine

SVM es un algoritmo de aprendizaje supervisado ampliamente utilizado. Su funcionamiento se basa en el procesamiento de un conjunto de datos etiquetados, donde el

algoritmo de entrenamiento busca encontrar un hiperplano el cual separe el conjunto de datos en clases (Mountrakis et al., 2011). Para este se han encontrado numerosas aplicaciones en la teledetección (Mountrakis et al., 2011). En otro trabajo realizado en España (Guzmán Yera, 2019) se empleó el algoritmo SVM junto con otros algoritmos como RF y Distancia de Mahalanobis, con el objetivo de modelar la distribución potencial de 23 especies arbóreas nativas en las Sierras Béticas en España. El modelo utilizó 17 variables ambientales con las que se puede caracterizar el clima, el suelo y la topografía. Según los valores AUC, RF y Mahalanobis mostraron una leve superioridad en la mayoría de los casos, aun así, SVM presentó resultados destacados, con un valor AUC promedio de $0,8 \pm 0,09$ y superando un valor de 0,9 para algunas especies. Adicionalmente, en el trabajo ya mencionado (Torres, 2024), se utilizó el algoritmo SVM para clasificar el estado de salud de las masas forestales. En este caso se logró mediante indicadores extraídos de imágenes Landsat. Como resultado, el modelo utilizado para discriminar entre zonas dañadas y no dañadas, en algún caso logró niveles de precisión de hasta 0.91.

3.15 Google Earth Engine

El análisis de la gran superficie terrestre mediante teledetección presenta grandes desafíos como lo son el procesamiento de la gran base de datos que utilizan y la disponibilidad de imágenes con una máxima cobertura de nubes aceptable, para la cual es necesario buscar, filtrar, descargar, enmascarar y hacer la corrección atmosférica. Tarea la cual lleva mucho trabajo y se requiere una gran capacidad de procesamiento y almacenamiento. Es aquí donde una herramienta como lo es GEE cobra tanta relevancia (Šumanovac, 2024).

GEE es una herramienta de análisis geoespacial a escala planetaria lanzada en 2010 que permite manejar grandes cantidades de información directamente desde la nube, reduciendo las limitaciones computacionales, tiempos de procesamiento y facilitando el trabajo con este tipo de imágenes (Gorelick et al., 2017; Perilla & Mas, 2020; Phan et al., 2020).

Esto es posible gracias que cuenta con 4 elementos como los son la infraestructura de Google mediante servidores para un alto procesamiento, su dataset con un gran catálogo de datos geoespaciales, el API (Application Program Interface) que permite generar algoritmos mediante comandos y funciones preestablecidas. Y por último la herramienta

Code editor, la cual es una plataforma en líneas basado en JavaScript donde se integran los elementos anteriores mediante un código de trabajo con el cual podemos seleccionar la información, procesar y visualizar para obtener el resultado buscado.

Tras el procesamiento de la información los resultados son extraíbles a partir de Google Drive (Perilla & Mas, 2020).


4 METODOLOGÍA

4.1 Caracterización del área de estudio

El estudio se realizó sobre la región centro sureste de Uruguay, siendo la zona de mayor influencia de SSP en Uruguay (MA, 2021; Sancho et al., 2021). Esta zona está comprendida por nueve imágenes satelitales Sentinel-2 (Figura 2) que contienen los departamentos de Lavalleja, Florida, Maldonado, Canelones, Rocha, Treinta y Tres, Flores, San José, Durazno y Cerro Largo. La temperatura media del área total que abarcan los SSP es de un promedio anual de $16,75 \pm 0,75^{\circ}\text{C}$ y las precipitaciones medias son $1150 \pm 150\text{mm}$ (Instituto Uruguayo de Meteorología [INUMET], s.f.). Las principales unidades de suelo de las zonas de estudio son Santa Clara, Sierras de Polanco, José Pedro Varela, San Gabriel de Guayancure, Tacuarembó, etc. y los principales suelos CONEAT son 2.12, 2.11a, 2.11b, 5.02b, 2.21, etc. Las especies plantadas en régimen silvopastoril son *E. globulus*, *E. smithii*, *E. dunnii*, *E. maidenii*, *E. grandis* y *E. benthamii* (Sancho et al., 2021).

Figura2

Mapa de la zona de estudio con cuadrícula Sentinel-2y especies presentes en los SPP



Nota. Mapa generado en Qgis de la zona de estudio con presencia de SSP realizado mediante la cartografía de Sancho et al. (2021).

4.2 Adquisición de imágenes satelitales

Se descargaron imágenes satelitales multiespectrales del satélite Sentinel-2 a través de la plataforma GEE por medio de la función Image Collection para el periodo de 1 de enero de 2021 al 31 de marzo de 2021. La selección de imágenes satelitales en GEE se orientó hacia la estación de verano, considerando que el estudio de Phan et al. (2020) empleó imágenes multiespectrales y demostró que estas ofrecen un desempeño superior, lo que contribuye a mejorar la precisión en la clasificación de las coberturas terrestres. Las imágenes seleccionadas corresponden a las cuadrículas 21HWD, 21HXD, 21HYD, 21HWC, 21HXC, 21HYC, 21HWP, 21HXB Y 21HYB (figura 2), de acuerdo con el sistema de tiling del sensor. Se utilizaron productos Sentinel-2 Nivel 2A (L2A), que proporcionan valores de reflectancia a nivel de superficie al estar corregidos atmosféricamente, lo cual los hace apropiados para análisis biofísicos y de cobertura del suelo. Además, se le adiciono un filtro de nubosidad reduciéndola a menos del 20%.

4.3 Clasificación supervisada

Para identificar las plantaciones bajo régimen silvopastoril y para diferenciar entre especies plantadas se llevó a cabo una clasificación supervisada utilizando la función Classifier de GEE entrenando un modelo RF (Phan et al., 2020; Šumanovac, 2024) de 10 árboles de regresión, con el 70% de las muestras y 30% de validación. Este, se realizó mediante las bandas 2, 3 4 y 8, ya que estas son las de mayor resolución espacial (Tabla 2) (DGF, 2018), la cual es una de las principales limitantes de Sentinel-2. El escalado de otras bandas como lo son la 5 y la 6 podría llevar a un aumento del error que no es deseado ya que tienen una menor resolución espacial (20m) (DGF, 2021).

Las muestras se generaron por medio de la digitalización en la sección de mapa de GEE, identificando las diferentes clases utilizadas basándose en la cartografía de SSP (Sancho et al., 2021). Para la detección de SSP las clases se denominaron SSP, Forestación, Pasturas, Suelo desnudo, Agua y Bosque Nativo. Para la clasificación de diferentes especies dentro de los SSP se utilizaron las clases definidas por los epítetos específicos de las especies presentes en la Figura 2, siendo benthamii, dunnii, globulus, grandis, maidenii y smithii.

4.4 Validación de la clasificación

Con el fin de evaluar el desempeño de la clasificación, utilizando GEE se realizó una validación independiente utilizando el 30% de las muestras que no fueron empleadas en el proceso de entrenamiento. Para ello se construyó una matriz de confusión que compara los valores de referencia de cada muestra con la clase asignada por el clasificador (He et al., 2023; Praticò et al., 2021; Šumanovac, 2024). A partir de esta matriz se calcularon distintos indicadores de exactitud. En primer lugar, la exactitud global (EG) del inglés Overall Accuracy, expresa la proporción de muestras clasificadas correctamente sobre el total, constituyendo un indicador general del desempeño de la clasificación (Nasiri et al., 2022; Šumanovac, 2024).

Asimismo, se calcularon las métricas de exactitud específicas por clase. La precisión del consumidor (PC) del inglés User's Accuracy, indica la probabilidad de que un píxel asignado a una clase determinada corresponda efectivamente a esa clase en el terreno, mientras que la precisión del productor (PP) del inglés Producer's Accuracy representa la proporción de muestras de referencia que fueron correctamente identificadas en la clasificación (Nasiri et al., 2022; Šumanovac, 2024).

De manera complementaria, se estimó el F1-score (F1), métrica que combina de forma armónica la PC y PP, proporcionando un balance entre errores de omisión y de comisión. Finalmente, se calculó el índice Kappa de Cohen, que cuantifica el grado de concordancia entre la clasificación y los datos de referencia corrigiendo el acuerdo que podría darse por azar. El índice es similar al coeficiente de correlación y puede variar entre -1 y +1. Un valor de 0 refleja una coincidencia que podría darse por azar, mientras que un valor de 1 representa una concordancia perfecta (Nasiri et al., 2022).

A continuación, se presentan las fórmulas de los indicadores utilizados para validar el resultado de la clasificación supervisada (Nasiri et al., 2022):

$$(1) \text{Exactitud global} = \frac{\text{Número de muestras clasificadas correctamente}}{\text{Número total de muestras}}$$

$$(2) \text{Índice Kappa} = \frac{\text{Exactitud global} - \text{Acuerdo esperado por azar}}{1 - \text{Acuerdo esperado al azar}}$$

$$(3) \text{Precisión del consumidor} = \frac{\text{Numero de muestras clasificadas correctamente en cada clase}}{\text{Número de muestras clasificado en esa clase}}$$

$$(4) \text{Precisión del productor} = \frac{\text{Numero de muestras clasificadas correctamente en cada clase}}{\text{Número de muestras de referencia en cada clase}}$$


$$(5) F1 - score = \frac{2 * \text{Precisión del consumidor} * \text{Precision del productor}}{\text{Precisión del consumidor} + \text{Precision del productor}}$$

En conjunto, estos indicadores permiten una evaluación integral de la confiabilidad de la clasificación, tanto de forma global como por clase, aportando robustez al análisis y garantizando que los resultados obtenidos puedan ser interpretados con un nivel adecuado de confianza.

A continuación, en figura 3 se presenta el diagrama de flujo para la realización de las clasificaciones supervisadas tanto a nivel de superficie para detección de SSP como para la clasificación de las especies dentro de los rodales.

Figura3

Diagrama de flujo de trabajo para la clasificación supervisada



Nota. **EG:** Exactitud Global, **PC:** Precisión del consumidor, **PP:** Precisión del Productor, **F1:**F1-Score.


5 RESULTADOS

5.1 Clasificación de SSP

A continuación, se presenta el mapa resultante de la clasificación supervisada (Figura 5) donde se destaca la superficie ocupada por las clases utilizadas para la detección de SSP.

Figura4

Mapa con clasificación supervisada para detección SSP.




Nota. Mapa resultado de la clasificación supervisada por superficie para la detección de SSP destacando SSP cartografiados por Sancho et al. (2021).

A continuación, se presentan zonas de ejemplo (Figura 5 y 6) del mapa resultante de la clasificación de superficies, con el objetivo de analizar en mayor detalle algunos sectores representativos, esto permite observar con mayor claridad el desempeño del modelo en la detección de áreas silvopastoriles y las diferencias en la asignación de clases dentro de la imagen satelital.

Figura5


Mapas de con clasificación de SSP en predio individual



Nota. Mapa con presencia del SSP plantado en 2016 con diferentes especies del género *Eucalyptus*. Presenta filas dobles con 2m entre plantas, 2m de entre fila y callejones de 7m (Sancho et al., 2021). Mapa superior con capa de clasificación de superficie y mapa inferior con imagen obtenidas en GEP para el año 2021 (Google, 2025b).

Figura6

Mapa tomado de Qgis con presencia del predio forestal cercano al pueblo de Reboledo



Nota. Mapa superior presenta capa de clasificación por superficie, el mapa inferior presenta imagen tomada de GEP para el año 2021 (Google, 2025a).

La tabla 3 corresponde a la matriz de validación de la clasificación supervisada que utilizó las clases SSP, Forestación, Pasturas, Suelo desnudo, Agua y Bosque Nativo.

Tabla 3

Matriz de validación de la clasificación supervisada de superficie para detectar SSP

Matriz de validación							
	SSP	Forestación	Pastura	Suelo desnudo	Agua	Bosque Nativo	Total real
SSP	150582	2040	15455	0	0	5206	173283
Forestación	7953	95406	0	0	0	6598	109957
Pastura	13671	0	1876948	1183	0	0	1891802
Suelo desnudo	0	0	0	357888	0	0	357888
Agua	0	0	0	0	2987987	0	2987987
Bosque Nativo	0	345	0	0	0	282786	283131
Total predicho	172206	97791	1892403	359071	2987987	294590	5804048

La matriz de validación compara los valores reales con los predichos por clase. Los valores de la diagonal indican clasificaciones correctas, por ejemplo, 150.582 píxeles reales de SSP fueron clasificados correctamente como SSP. En cambio, los valores fuera de la diagonal representan errores de clasificación o confusiones, como píxeles de SSP clasificados como pastura. Estas confusiones se dan principalmente entre clases, como SSP-Pastura y Forestación-Bosque Nativo. El total real corresponde a la cantidad de píxeles que pertenecen efectivamente a cada clase, por ejemplo, Pastura tiene 1.891.802, mientras que el total predicho indica la cantidad de píxeles que el modelo asignó a esa clase, como los 1.892.403 que fueron clasificados como Pastura.

El algoritmo generado obtuvo buenos resultados a la hora de clasificar cada clase en la fase de prueba. Los mejores resultados se obtuvieron para las clasificaciones Agua y Suelo Desnudo, sin mostrar ningún error dentro de la matriz. Por otra parte, los mayores errores fueron en la clase Silvopastoreo, mostrando confusión con Forestación, Pastura y Bosque Nativo aparentemente.

En la Tabla 4 se observan los valores de PC, PP y F1. Las métricas de PC y PP permiten evaluar el desempeño por clase. La PP mide cuán confiables son las clasificaciones del modelo, como cuando un 86 % de los píxeles clasificados como SSP realmente lo son. Por su parte, la PC mide cuántos píxeles reales de una clase fueron correctamente identificados, evitando la subclasificación; por ejemplo, un 97 % de los píxeles reales de Forestación fueron clasificados correctamente. El F1 combina ambas métricas en un solo valor y resume el desempeño por clase. En este sentido, Pastura y Suelo Desnudo presentan valores muy altos (0,99), mientras que Agua alcanza un valor de 1, lo que indica una clasificación prácticamente perfecta.

Tabla 4

Resultados de indicadores de PC, PP y F1 para la clasificación supervisada de SSP

Clase	Precisión del consumidor	Precisión del Productor	F1-Score
SSP	0,87	0,86	0,87
Forestación	0,97	0,86	0,92
Pastura	0,99	0,99	0,99
Suelo desnudo	0,99	0,99	0,99
Agua	1	1	1
Bosque Nativo	0,96	0,99	0,97


Se observó el valor más alto para la clase Agua con un valor de 1 para los tres índices. En contrapartida se observaron los valores más bajos para la clase SPP, mostrando valores de 0,87 en PC, 0,86 en PP y 0,87 en F1. La EG de la clasificación supervisada fue de 0.95 y el Índice Kappa presentó un valor de 0.94.

En términos generales, la clasificación presentó valores elevados de los diferentes indicadores de validación ya que casi todas las clases presentan valores superiores a 0,8. Las clases con mejor desempeño fueron Agua, con resultados perfectos, seguidas por Pastura, Suelo Desnudo y Bosque Nativo. Las clases que presentó mayor cantidad de píxeles clasificados como otras clases fue la clase de SSP. Los píxeles correspondientes a la clase SSP que fueron clasificados de manera errónea se asignaron predominantemente a la clase Pastura. Además, los píxeles de la clase SSP fueron clasificados erróneamente, aunque en menor medida, como Bosque Nativo y Forestación.

A continuación, se presenta el gráfico de la firma espectral de cada clase en distintas bandas del espectro (B2, B3, B4 y B8 del satélite Sentinel-2).

Figura7

Gráfico de firma espectral por clase para las 4 bandas de Sentinel-2 utilizadas



En la tabla 5 se presenta la firma espectral por clase para las bandas y el desvío estándar. El desvío estándar refleja la variabilidad interna de los valores espectrales

dentro de cada clase. Los valores bajos son clases más homogéneas con reflectancias similares entre sus píxeles y valores más altos son clases heterogéneas con gran variabilidad dentro de la clase. Suelo desnudo presenta valores de desvío más alto (732-997), esto puede variar mucho en color, textura y humedad. El agua presenta los valores más bajos ya que los cuerpos de agua son muy homogéneos espectralmente ya que el agua absorbe de forma uniforme la radiación, sobre todo el infrarrojo cercano (B8).

Tabla 5

Matriz de validación de la clasificación supervisada de superficie para detectar SSP

Banda/Clasificación	SSP	σ	Forestación	σ	Pastura	σ	Suelo desnudo	σ	Bosque Nativo	σ	Agua	σ
B2 (μm)	324	137	164	23	553	86	985	732	430	105	208	27
B3 (μm)	503	195	295	46	905	85	1276	895	455	49	538	118
B4 (μm)	508	236	244	39	804	166	1657	997	236	31	469	205
B8 (μm)	2652	318	2658	433	3218	307	2634	866	2926	233	329	237

Nota. σ : Desvío Estándar.

5.2 SSP Clasificación de especies dentro de rodales de SSP

A continuación, se presentan los resultados de la clasificación supervisada para las diferentes especies, donde se destaca la superficie ocupada por las clases (*E. benthamii*, *E. dunnii*, *E. globulus*, *E. grandis*, *E. maidenii* y *E. smithii*) utilizadas para la identificación de especies dentro de los rodales bajo régimen silvopastoril (Sancho et al., 2021).

En la Tabla 6 se presenta una matriz de validación para la clasificación supervisada realizada para la detección de especies con imágenes satelitales Sentinel-2.

Tabla 6

Matriz de validación de la clasificación supervisada por especie dentro de los SSP

Matriz de validación							
Clases	<i>E. dunnii</i>	<i>E. benthamii</i>	<i>E. globulus</i>	<i>E. grandis</i>	<i>E. maidenii</i>	<i>E. smithii</i>	Total real
<i>E. dunnii</i>	44714	537	10150	16234	13769	3276	88680
<i>E. benthamii</i>	285	75244	7265	12295	1381	944	97414
<i>E. globulus</i>	4907	4430	36257	4936	4922	7842	63294
<i>E. grandis</i>	7541	7787	14559	63596	4522	1847	99852
<i>E. maidenii</i>	8049	2158	10819	12031	37732	10583	81372
<i>E. smithii</i>	10701	2409	18734	3228	2301	38032	75405
Total predicho	76197	92565	97784	112320	64627	62524	506017

Como se observa, la clasificación supervisada presentó errores de clasificación de píxeles entre clases. Los valores ubicados en la diagonal representan las clasificaciones correctas; por ejemplo, 63.596 píxeles reales de *E. grandis* fueron correctamente clasificados como *E. grandis*. En cambio, los valores fuera de la diagonal indican errores de clasificación o confusiones, como píxeles de *E. globulus* clasificados como *E. maidenii* o *E. smithii*.

En relación con los píxeles totales, *E. grandis* cuenta con 99.852 píxeles reales, mientras que el total predicho indica la cantidad de píxeles que el modelo clasificó como pertenecientes a esa especie; por ejemplo, *E. grandis* obtuvo 112.320 píxeles predichos.

A continuación, en la tabla 7 se presentan los resultados para los índices PC, PP y F1.

Tabla 7

Resultados de indicadores de PC, PP y F1 para la clasificación de especies

Especie/Indicador	Precisión del		
	Precisión del consumidor	Productor	F1-Score
<i>E. dunnii</i>	0,59	0,5	0,54
<i>E. benthamii</i>	0,81	0,77	0,79
<i>E. globulus</i>	0,37	0,57	0,45
<i>E. grandis</i>	0,57	0,64	0,6
<i>E. maidenii</i>	0,58	0,47	0,52
<i>E. smithii</i>	0,61	0,5	0,55

La EG de la clasificación supervisada fue de 0.58 y el Índice Kappa presentó un valor de 0.5.


Respecto a la precisión, las especies con mejor desempeño son *E. benthamii* (F1 = 0.79) y *E. grandis* (F1 = 0.60), seguidas por *E. smithii* (F1 = 0.55). Las especies *E. globulus*, *E. maidenii* y *E. dunnii* presentan valores más bajos ($F1 \leq 0.55$), lo que evidencia una mayor confusión entre las clases.

La clasificación muestra un desempeño moderado, por presentar valores de los indicadores inferiores a 0,8 con diferencias marcadas entre especies. *E. benthamii* presenta la mejor discriminación, mientras que *E. globulus* y *E. maidenii* son las más difíciles de distinguir. Los principales errores de clasificación de píxeles ocurren confusiones entre *E. globulus*, *E. maidenii* y *E. smithii*, mientras que *E. grandis* tiende a mezclarse en menor medida con *E. dunnii*. En general, los resultados sugieren que el modelo logra una clasificación razonable, aunque sería conveniente incorporar más variables espectrales o temporales para mejorar la separación entre especies similares.

En las siguientes figuras (Figura 8, 9, 10 y 11) se muestran diversos resultados para alguna de las especies clasificadas.

Figura8


*Mapa clasificación supervisada para especies en los rodales de SSP plantados con *E. benthamii**



Nota. Mapa de clasificación por especies en predios silvopastoriles ubicados en la unidad de suelo Montecoral, unidad geológica Complejo basal del CRP, plantados con *E. benthamii* en 2018 con filas triples con 2,2 m de entre plantas, 2 m de entrefila y 20 m de callejón (Sancho et al., 2021).

Figura9

Mapa clasificación supervisada para especies en los rodales de SSP plantados con E. globulus



Nota. Mapa de clasificación por especies en predios silvopastoriles ubicados en la unidad de suelo Montecoral, unidad geológica Formación Libertad, plantados con *E. globulus* en 2008 y pasado a talar en 2018 con filas dobles con 2 m de entre plantas, 3 m de entrefila y 6 m de callejón (Sancho et al., 2021).

Figura10


Mapa clasificación supervisada para especies en los rodales de SSP plantados con E. globulus



Nota. Mapa de clasificación por especies en predios silvopastoriles ubicados en la unidad de suelo Santa Clara, unidad geológica Grupo Lavalleya, plantados con *E. globulus* en 2006 y pasado a talar en 2017 con filas dobles con 2 m de entre plantas, 3 m de entrefila y 6 m de callejón (Sancho et al., 2021).

Figura 11

Mapa clasificación supervisada para especies en los rodales de SSP plantados E. grandis




Nota. Mapa de clasificación por especies en predios silvopastoriles ubicados en la unidad de suelo Santa Clara y en la unidad geológica Formación Tacuarembó, plantados con *E. grandis* en 2015. Presentan arreglos en filas dobles con dos configuraciones espaciales dominantes: 4 m entre plantas, 4 m entre filas y 16 m de callejón, y 5 m entre plantas, 5 m entre filas y 20 m de callejón (Sancho et al., 2021).

Finalmente, la clasificación supervisada alcanzó una EG de 0,58 y un índice Kappa de 0,50, lo que indica que el modelo logra identificar correctamente una proporción considerable de píxeles, pero aún existen confusiones relevantes entre especies con características espectrales cercanas.

En la figura 12 se presenta el gráfico de la respuesta espectral de las seis clases en las cuatro bandas utilizadas para la clasificación supervisada.

Figura12

Gráfico de firma espectral por especie de Eucalyptus para las 4 bandas de Sentinel-2 utilizadas



La tabla 8 presenta la firma espectral por especie para las bandas y su respectivo desvío estándar.

Tabla 8*Valores de firma espectral y desvío estándar por especie para las bandas utilizadas*

Ban/ Esp	<i>E. dunnii</i>	σ	<i>E. benthamii</i>	σ	<i>E. globulus</i>	σ	<i>E. grandis</i>	σ	<i>E. maidenii</i>	σ	<i>E. smithii</i>	σ
B2 (μm)	229	118	470	59	432	146	365	95	330	128	433	158
B3 (μm)	375	170	771	74	650	179	606	138	512	162	632	203
B4 (μm)	365	207	691	96	680	268	624	159	534	175	639	290
B8 (μm)	2852	320	3041	224	2610	271	2859	321	2656	226	2714	263

El *E.benthamii* muestra los valores más altos en todas las bandas. El *E. grandis*, *globulus* y *smithii* presentan curvas similares con diferencias leves entre sí. El *E.dunnii* refleja valores más bajos en todas las bandas, especialmente en la B8.

Las especies con menor desviación estándar son el *E. benthamii* y el *E. grandis*. Por lo contrario, el *E. dunnii* y *E. smithii* muestran mayores valores de desvío especialmente en la B8, generando mayor heterogeneidad interna asociada a diferencias estructurales, densidad foliar o presencia de mezclas con otras coberturas.

6 DISCUSIÓN

En este estudio, mediante la plataforma GEE se realizó una clasificación supervisada utilizando el algoritmo RF en base a imágenes satelitales del satélite Sentinel-2, con el fin de detectar zonas con SSP y diferenciar entre especies dentro de estos. El resultado de la clasificación para detección de SSP presentó valores considerables de los diferentes índices utilizados para la validación. No obstante, al observar la cartografía resultante se pudo detectar zonas de mayor o menor error a la hora de clasificar píxeles como clases no objetivo. Por otro lado, la clasificación con fines de diferenciar zonas entre especies dentro de SSP presentó valores bajos de los diferentes indicadores mencionados para la validación de la cartografía.

En la clasificación de SSP y otras coberturas dentro del área de estudio, se obtuvieron valores PC de 95% y valores de índice Kappa de 0,94, demostrando buenos resultados y similares a los del estudio de Nasiri et al. (2022), quienes reportaron una PC de 95,48% y un índice Kappa de 0,94 en un estudio basado en imágenes multiespectrales. Estos valores fueron menores a los que obtuvo el estudio de Šumanovac (2024), el cual comparando diferentes algoritmos en la clasificación de superficies con todas las bandas de Sentinel-2, obtuvo una EG y un índice Kappa de 0,99.

Si bien los resultados de la clasificación de SSP presentaron valores elevados de los indicadores, se evidenciaron confusiones entre distintas clases. Por ejemplo, como se puede ver en la tabla 3, la clase SSP muestra errores de clasificación causados por confusiones con Forestación, Pastura y Monte Nativo, viéndose reflejado en F1 0,87. Esto se puede deber a la presencia de callejones de ancho variable con presencia de pasturas en los SSP (Majaura et al., 2024).

En el estudio de DGF (2021), se utilizaron las mismas técnicas de clasificación que en este trabajo, pero sin la complejidad que significa la clasificación de SSP. Se observó cómo el algoritmo confundió monte nativo con forestación y bosque nativo con pastura. No obstante, el estudio mostró un EG de 0.92 para la clase Forestación. Las confusiones entre clases en la clasificación mediante imágenes multiespectrales, puede deber a la similitud de las firmas espectrales entre las clases (figura 7), lo cual ha sido señalado por Fyfe (2003) como un factor que puede dificultar la discriminación espectral. Además, este estudio presenta la novedad de incluir los SSP, que presentan la combinación de montes plantados con fines comerciales con pasturas, mostrando

diferencias a nivel de arreglos espaciales (ancho de las filas, ancho de los callejones y número de filas) y diferencias de especies forestales. También, es de destacar que se trabajó con un tamaño de píxel relativamente grande (10 m), siendo la menor resolución disponible para el satélite Sentinel-2, lo que limita la capacidad de distinguir objetos individuales o conjuntos de objetos (Immitzer et al., 2016). Esta resolución tiende a contemplar distintas coberturas terrestres dentro de un mismo píxel, dificultando la separación precisa entre las clases. De acuerdo con Wu y Zhang (2019), las metodologías basadas en objetos resultan más eficaces para la clasificación que las basadas únicamente en píxeles, ya que consideran características espaciales y contextuales. Por lo tanto, esta limitación podría explicar la presencia de errores en la clasificación de la clase SSP, especialmente en la identificación precisa de las especies o tipos de cobertura.

En la Figura 7, se presenta la firma espectral para cada una de las clases utilizadas, mostrándose una gran diferencia de firma entre el Agua y el resto de las clases explicando la buena clasificación de esta. Por otra parte, los SSP presentaron una firma espectral intermedia entre la Forestación y la Pastura, lo que coincide con lo mencionado previamente sobre la baja resolución espacial de las imágenes satelitales utilizadas. Esto puede observarse en la Figura 5, donde se aprecia que los bordes de los rodales forestales fueron clasificados como SSP debido a la combinación de superficie pastura con superficie con árboles. En este mapa se muestra una porción de la clasificación en la que aparece un predio identificado por Sancho et al. (2021) como SSP. Si bien dicho predio es efectivamente clasificado como SSP, puede observarse que hacia el oeste la clasificación se extiende. En la imagen de GEP en el año 2021 se aprecia que, para el año correspondiente a los registros de Sancho et al. (2021), existía una baja densidad de árboles, lo que se asemeja a un SSP y genera el error de clasificación. Para comprender este comportamiento, se analizaron imágenes más antiguas mediante GEP, lo que permitió determinar que se trataba de un monte previamente talado, cuyos tocones rebrotaron con el tiempo.

Además, en la Figura 7 se observa la clasificación correspondiente a un monte forestal. En esta imagen puede apreciarse que los rodales forestales fueron correctamente identificados; sin embargo, tal como se mencionó previamente, el algoritmo detecta una menor densidad de árboles y clasifica esos sectores como SSP. En este mismo ejemplo se incluye un SSP de *Eucalyptus* spp. densamente plantado, con un

espaciamiento entre plantas de 2 m y callejones de 7 m. Allí se observa que algunos pocos píxeles ubicados en el centro del SSP fueron clasificados como monte forestal, probablemente debido a la alta densidad presente.

En la Figura 5 se identifica el arroyo del Alférez, asociado a un perímetro de bosque ribereño. Parte de este borde aparece clasificado como bosque nativo, mientras que otro sector es clasificado como SSP, lo cual podría deberse a la proximidad entre los rodales forestales y el cauce del arroyo. También se distinguen claramente áreas de pastura y zonas de suelo desnudo, consistentes con lo observado en la imagen de GEP para el año 2021.

Estos mismos patrones se evidencian en el mapa de la Figura 6. En la imagen superior se puede ver que la vegetación próxima al arroyo Chamamé es clasificada mayoritariamente como bosque nativo, aunque un pequeño sector aparece identificado como forestación. Esto se podría explicar por la alta densidad arbórea en los bordes del arroyo y por el desconocimiento de la composición específica de ese bosque, que podría incluir especies cuya reflectancia se asemeja a la de un monte de *Eucalyptus*. Esto sumado a que el tamaño del píxel (10 m) dificulta capturar adecuadamente la heterogeneidad del área, pudiendo inducir a su clasificación como forestación (Immitzer et al., 2016).

Como resultado de la clasificación por especies se obtuvo una EG del 0.58 y un índice Kappa de 0,5. Este valor, relativamente bajo, puede atribuir a la dificultad de distinguir entre especies que presentan reflectancias espectrales similares (Immitzer et al., 2016; Kumar et al., 2007), fenómeno ampliamente documentado para distintas especies del género de *Eucalyptus* (Kumar et al., 2007). Esta situación se evidencia en la Figura 12, donde las firmas espectrales de las especies analizadas exhiben patrones muy semejantes, con diferencias mínimas entre ellas. Esto también se refleja en la Tabla 6 (matriz de validación), donde se observa que las especies con una firma espectral similar presentan mayores confusiones por parte del algoritmo de clasificación. No obstante, dentro de la heterogeneidad observada en los indicadores por especie, se destaca una buena clasificación para *E. benthamii*, que presenta un F1 de 0,79. Este desempeño se ve reflejado en la Figura 8, donde se observa que prácticamente la totalidad de los rodales fueron identificados como *E. benthamii*. Estos rodales ya habían sido reportados como SSP de *E. benthamii* plantados en 2018 por Sancho et al. (2021). No obstante, la clasificación también muestra algunas confusiones puntuales, donde

ciertos píxeles fueron asignados a otras especies. Entre estas confusiones, *E. dunnii* aparece en menor proporción, lo cual es consistente con su mayor distancia espectral respecto a *E. benthamii*, según se aprecia en la Figura 12. En contraste, los valores de los indicadores para *E. globulus* fueron significativamente más bajos, obteniendo el peor desempeño con un valor F1 de 0,45. Parte de los resultados de esta clasificación se ilustran en las figuras 9 y 10, donde se aprecia que, aunque la mayoría del predio fue clasificado como *E. globulus*, se observa también una presencia notable de otras especies como *E. grandis* y *E. smithii*. Además, se observa una diferencia evidente entre ambas figuras, evidenciando un error mayor en la figura 10. Por otro lado, los resultados correspondientes a *E. grandis* arrojaron un valor de F1 de 0,60, convirtiéndola en la segunda especie con mejor desempeño. Sin embargo, en la figura 11 se observa que el área predominante del predio está clasificada como *E. maidenii*, seguida por *E. globulus*, y recién en tercer lugar aparecería el *E. grandis* como especie dominante.

En la figura 13 podemos ver como las bandas B2, B3 y B4 presentan valores bajos y similares, lo cual es esperable ya que, como se puede ver en los resultados de DGF(2021), la vegetación absorbe gran parte de la radiación dentro del espectro visible, teniendo una reflectancia un poco mayor en la región Green (B3). En cuanto a la B8 se observa un aumento abrupto en la reflectancia en todas las especies, lo cual es típico ya que las hojas reflejan fuertemente la radiación NIR por su estructura interna (Zeng et al., 2021). Según Verma et al. (2019) la clasificación de las especies de *Eucalyptus* mediante datos de teledetección presentan un desafío particular ya que presentan características biofísicas similares. Una de las diferencias se puede deber a las propiedades ópticas de las hojas ya que generalmente cuelgan verticalmente lo que hace que las copas sean semi transparentes cuando se observan desde arriba, a su vez influye la reflectancia de las hojas maduras que se ve influenciada por cambios fisiológicos-morfológicos asociados al envejecimiento.

Las bandas de las imágenes satelitales Sentinel-2 utilizadas en este trabajo fueron seleccionadas en función de los requerimientos de la clasificación (Ginindza, 2025), priorizando aquellas con la mayor resolución espacial disponible. Esta elección responde a la complejidad que implica identificar correctamente un SSP frente a resoluciones espaciales pequeñas. No obstante, las bandas empleadas no solo ofrecen la mejor resolución posible para el satélite, sino que además se encuentran entre las más significativas para este tipo de tareas de clasificación. En un estudio realizado por DGF

(2021) se llevó a cabo una clasificación de superficie similar a la del presente trabajo. Para ello se emplearon imágenes de muy alta resolución (WorldView-02, Pleiades y ortomosaicosIDEuy) con un tamaño de píxel de 1,85 a 2 m, lo que permitió obtener mejores resultados, alcanzando una EG del 93,4%. Por su parte, Alonso et al. (2022) también utilizaron imágenes multiespectrales de alta resolución (WorldView-3) junto al algoritmo RF para clasificar *E. globulus* y *E. nitens*, obteniendo una PC del 69% para ambas especies. En este estudio, *E. globulus* presentó el menor desempeño, con una PP del 65% y una PA del 45%, mientras que *E. nitens* mostró mejores resultados, con valores de PP y PA superiores al 70%. Estas diferencias se ven reflejadas en el índice Kappa, que fue de 0,31. A pesar de la limitante de la resolución espacial de este trabajo, la clasificación de SSP mediante Sentinel-2 quizás podría mejorar incorporando más información a los modelos. Según el resultado de Alonso et al. (2022) en concordancia con Peerbhay et al. (2014), las bandas dentro del rango espectral 393 a 723 μm son las más importantes, encontrándose B2, B3 y B4 en estas zonas, pero se menciona en Nasiri et al. (2022) que las bandas del borde rojo (B5, B6 y B7) fueron importantes para mejorar la clasificación RF. Además, en el estudio de Praticò et al. (2021), mediante GEE con imágenes Sentinel-2, se realizó la comparativa de múltiples clasificaciones supervisadas utilizando los algoritmos RF, SVM y CART para diferentes conjuntos de bandas y de Índices de Vegetación. Dentro de sus resultados podemos ver como utilizando las bandas RGB más NIR obtuvo un PC de 0,79, resultado menor al que obtuvo sumando B5, B6, B7 y B8A con un valor de 0,81. Además, el mejor resultado lo obtuvo para el algoritmo RF añadiendo tres índices de vegetación (NDVI, EVI y NBR) a todas las bandas de Sentinel-2 con una PC de 0,88.

En síntesis, aunque el algoritmo RF mostró buen desempeño en la clasificación general y en la detección de SSP, la resolución espacial de Sentinel-2 limita la capacidad de distinguir los arreglos propios de los SSP y, especialmente, de diferenciar entre especies de *Eucalyptus* con firmas espectrales similares. Para mejorar la precisión, será necesario trabajar con imágenes de mayor resolución e integrar información de otros sensores (índices de vegetación, datos hiperespectrales, radar o LiDAR) que permita caracterizar con mayor detalle la estructura y las propiedades de cada especie.

7 CONCLUSIÓN

El presente estudio demostró que es posible detectar SSP y clasificar coberturas terrestres utilizando imágenes Sentinel-2 y el algoritmo RF dentro de la plataforma GEE. La clasificación general presentó un desempeño robusto, con valores elevados de EG e índice Kappa, comparables a los reportados en la literatura para estudios basados en imágenes multiespectrales. Esto confirma que Sentinel-2 constituye una herramienta adecuada para distinguir coberturas amplias y categorías de uso del suelo a escala regional.

Sin embargo, el análisis detallado reveló que la resolución espacial de 10 m impone limitaciones importantes, especialmente en sistemas heterogéneos como los SSP. La presencia de callejones, variaciones en la densidad de plantación y condiciones de borde entre forestación, pastura y monte nativo generaron confusiones frecuentes en la clasificación. Estas limitaciones se acentúan al intentar discriminar especies de *Eucalyptus*, cuyas similitudes espectrales redujeron significativamente la precisión, reflejándose en valores bajos de EG e índice Kappa para esta etapa del análisis.

Los resultados indican que la integración de imágenes de mayor resolución espacial, el uso de bandas adicionales (como las del borde rojo), índices de vegetación, o incluso la incorporación de sensores complementarios (datos hiperespectrales o LiDAR) podrían mejorar de forma sustancial la detección de SSP y la diferenciación entre especies forestales.

En conjunto, este trabajo evidencia el potencial del uso de Sentinel-2 y RF para detectar SSP, pero también destaca la necesidad de incorporar mayor detalle espectral y espacial para abordar con éxito la complejidad estructural y composicional de estos sistemas. De esta manera, estudios futuros podrán avanzar hacia una clasificación más precisa, útil tanto para la gestión forestal como para la planificación productiva y ambiental.

8. BIBLIOGRAFÍA

- Abburu, S., & Golla, S. B. (2015). Satellite image classification methods and techniques: A review. *International Journal of Computer Applications*, 119(8), 20-25.
<https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=69613390ca76bf103791ef251e1568deb5fe91dd>
- Ackermann, M., & Cortelezzi, Á. (2017). Mercado de trabajo agropecuario: Situación y prospectiva hacia el Uruguay Agrointeligente de 2030. En *Anuario OPYPA*. MGAP. https://www.gub.uy/ministerio-ganaderia-agricultura-pesca/sites/ministerio-ganaderia-agricultura-pesca/files/documentos/publicaciones/e_-_ackermann_cortelezzi_mercado_de_trabajo_agropecuario_situacion_y_prospectiva_hacia_el_uruguay_agrointeligente_2030.pdf
- Almeida, R. (2017, 6-7 de noviembre). *Integración agrícola-ganadera-forestal con enfoque al ganado de carne* [Contribución]. 25° Congreso CEA: Praderas y Forrajes, Asunción, Paraguay. https://www.researchgate.net/profile/Roberto-Almeida4/publication/320958975_INTEGRACION_AGRICOLA-GANADERA-FORESTAL_CON_ENFOQUE_AL_GANADO_DE_CARNE/links/5a0487e1aca2726b4c7001f2/INTEGRACION-AGRICOLA-GANADERA-FORESTAL-CON-ENFOQUE-AL-GANADO-DE-CARNE.pdf
- Alonso, L., Picos, J., & Armesto, J. (2022). Mapping *Eucalyptus* species using WorldView-3 and random forest. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information*, XLIII-B3-2022, 819-825.
<https://doi.org/10.5194/isprs-archives-XLIII-B3-2022-819-2022>
- Becerra, D. (2021). *Clasificación supervisada de una imagen satelital suministrada por la Policía Nacional para la identificación de posibles cultivos de amapola en el municipio de La Cruz-Nariño* [Trabajo final de grado, Universidad Militar Nueva Granada]. Repositorio Institucional UMNG.
<https://repository.umng.edu.co/server/api/core/bitstreams/fa8dc5eb-7740-434c-b29c-94d1bc8b2798/content>
- Benedetti, S., & Espinoza, R. (1992). Sistemas agroforestales. *Ciencia e Investigación Forestal*, 6, 281-283.
<https://bibliotecadigital.infor.cl/bitstream/handle/20.500.12220/10832/18530.pdf>
- Betti, A., & Giraldez, R. N. (2020). *Aplicación de técnicas basadas en aprendizaje profundo para la clasificación de imágenes satelitales* [Trabajo final de grado, Universidad Nacional de Mar del Plata]. RINFI.
<https://rinfi.fi.mdp.edu.ar/handle/123456789/464>

- Boscana, M., Bussoni, A., & Bentancur, O. (2023). Wood production and financial return in two silvopastoral systems. *Agrociencia Uruguay*, 27, Artículo e793. <https://doi.org/10.31285/agro.27.793>
- Boscana, M., & Faroppa, C. (2023). *Estadísticas forestales 2023: Extracción - Producción - Consumo - Mano de Obra - Comercio Exterior*. MGAP.
- Camacho-Velasco, A., Vargas-García, C. A., Rojas-Morales, F. A., Castillo-Castelblanco, S. F., & Arguello-Fuentes, H. (2015). Aplicaciones y retos del sensado remoto hiperspectral en la geología colombiana. *Revista Facultad de Ingeniería*, 24(40), 17-29. http://www.scielo.org.co/scielo.php?pid=S0121-11292015000300003&script=sci_arttext
- Cardozo, F. (2023, 22 de junio). La industria forestal representará entre el 5 y 6% del PBI a fines de 2024. *Ámbito*. <https://www.ambito.com/uruguay/la-industria-forestal-representara-el-5-y-6-del-pbi-fines-2024-n5751716>
- Carriquiry, R. (2011). La heterogeneidad de ganaderos a la sombra de plantaciones forestales y los sistemas silvopastoriles. *Revista del Plan Agropecuario*, (140), 20-24. https://www.planagropecuario.org.uy/publicaciones/revista/R140/R_140_20.pdf
- Carvalho, M. M., & Xavier, D. F. (2005). Sistemas silvipastoris para recuperação e desenvolvimento de pastagens. En A. A. de Aquino & A. M. Assis (Eds.), *Agroecologia: Princípios e técnicas para uma agricultura orgânica sustentável* (pp. 497-517). Embrapa. <https://www.fcav.unesp.br/Home/departamentos/zootecnia/anaclaudiaruggieri/6.-sistemas-silvipastoris.pdf>
- Centro de Estudio de la Realidad Económica y Social. (2023). *La producción forestal en Uruguay: Un sector líder y sostenible*. <https://www.gub.uy/ministerio-ganaderia-agricultura-pesca/sites/ministerio-ganaderia-agricultura-pesca/files/documentos/noticias/Sector%20Forestal%202023%20%281%29.pdf>
- Chen, X., & Ishwaran, H. (2012). Random forests for genomic data analysis. *Genomics*, 99(6), 323-329. <https://www.sciencedirect.com/science/article/pii/S0888754312000626>
- Chen, Y., Arsenault, R., Napper, S., & Griebel, P. (2015). Models and methods to investigate acute stress responses in cattle. *Animals*, 5(4), 1268-1295. <https://doi.org/10.3390/ani5040411>

- Cubbage, F., Balmelli, G., Bussoni, A., Noellemeyer, E., Pachas, A. N., Fassola, H., Colcombet, L., Rossner, B., Frey, G., Dube, F., de Silva, M. L., Stevenson, H., Hamilton, J., & Hubbard, W. (2012). Comparing silvopastoral systems and prospects in eight regions of the world. *Agroforestry Systems*, 86(3), 303-314. <https://doi.org/10.1007/s10457-012-9482-z>
- Daramola, J. O., Abioja, M. O., & Onagbesan, O. M. (2012). Heat stress impact on livestock production. En V. Sejian, S. M. K. Naqvi, T. Ezeji, J. Lakritz & R. Lal (Eds.), *Environmental stress and amelioration in livestock production* (pp. 53-67). Springer. https://doi.org/10.1007/978-3-642-29205-7_3
- Dirección General Forestal. (2018). *Cartografía forestal nacional 2018*. MGAP. https://www.gub.uy/ministerio-ganaderia-agricultura-pesca/sites/ministerio-ganaderia-agricultura-pesca/files/documentos/publicaciones/metodologia_1.pdf
- Dirección General Forestal. (2021). *Elaboración de la cartografía forestal nacional 2021*. MGAP. <https://descargas.mgap.gub.uy/Documentos%20compartidos/CARTOGRAFIA%202021/INFORME%20METODOLOGIA%20Y%20RESULTADOS%20ICA%202021.pdf>
- Dirección General Forestal. (2024). *Resultados de la cartografía forestal nacional 2024*. MGAP. <https://descargas.mgap.gub.uy/Documentos%20compartidos/CARTOGRAFIA%202024/Informe%20de%20resultados%202025.pdf>
- Dogliotti, G. (2024). *Análisis de sistemas silvopastoriles con Eucalyptus grandis: Segmentación de copas, microambiente y productividad del campo natural* [Tesis de maestría]. Universidad de la República.
- European Space Agency. (2015). *Sentinel-2 userhandbook*. https://sentinels.copernicus.eu/documents/247904/685211/Sentinel-2_User_Handbook
- European Space Agency. (2021). *Sentinel-2 Level-2A algorithm theoretical basis document*. <https://sentinels.copernicus.eu/documents/247904/446933/Sentinel-2-Level-2A-Algorithm-Theoretical-Basis-Document-ATBD.pdf>
- Fajardo, R. (2023). *Análisis de la deforestación de los años 2016 y 2022 en el distrito Castillo Grande, Huánuco, Perú* [Trabajo final de grado, Universidad Nacional Agraria de la Selva]. Repositorio Institucional UNAS. <https://repositorio.unas.edu.pe/items/58b7f432-1d07-483c-9eae-544ec52c1a00>
- Farrell, J., & Altieri, M. (1999). Sistemas agroforestales. En M. Altieri (Ed.), *Agroecología: Bases científicas para una agricultura sustentable* (pp. 229-242). CLADES. https://www.academia.edu/8955227/AGROECOLOGIA_Bases_cient%C3%ADficas_para_una_agricultura_sustentable

- Fedriago, J. K., Benítez, V., Santa Cruz, R., Posse, J., Santiago Barro, R., Hernández, J., Mantero, C., Morales Olmos, V., David Silveira, E., & Viñoles, C. (2018). Oportunidades y desafíos para los sistemas silvopastoriles en Uruguay. *Veterinaria (Montevideo)*, 54(209), 20-30.
<https://www.revistasmvu.com.uy/index.php/smvu/article/view/83/33>
- Fedriago, J. K., Santa Cruz, R., Benítez, V., Courdin, V., Ferreira, G., Posse, J. P., & Viñoles, C. (2019). Dynamics of forage mass, air temperature and animal performance in a silvopastoral system of Uruguay. *Agroforestry Systems*, 93, 715-728. <https://ainfo.inia.uy/digital/bitstream/item/13342/1/Fedriago-2018.pdf>
- Fermi, M. J. (2023). Envión forestal: Una mirada al desarrollo y los números del sector. *Revista Forestal*. <https://www.revistaforestal.uy/en-contexto/envion-forestal-una-mirada-al-desarrollo-y-los-numeros-del-sector>
- Fermi, M. J. (2024). Tiempos de cambio. *Revista Forestal*. <https://www.revistaforestal.uy/en-contexto/tiempos-de-cambio>
- Fyfe, S. K. (2003). Spatial and temporal variation in spectral reflectance: Are seagrass species spectrally distinct? *Limnology and Oceanography*, 48(1, Part 2), 464-479. https://doi.org/10.4319/lo.2003.48.1_part_2.0464
- García, D. (2010). *Estimación de variables de interés forestal basada en datos LiDAR en el monte número 117 del CUP término municipal de Cuenca* [Trabajo final de grado, Universidad Politécnica de Madrid]. Archivo Digital UPM. <https://oa.upm.es/id/eprint/6171>
- Gatti, A., & Bertolini, A. (2015). *Sentinel-2 products specification document*. Thales Alenia Space. https://sentinels.copernicus.eu/documents/247904/349490/S2_MS_I_Product_Specification.pdf
- Ginindza, T. M. (2025). Identification of commercial forest tree species using sentinel 2 and planet scope imageries in the Usutu forest, Eswatini. *Journal of Geographic Information System*, 17(1), 1-22.
https://ui.adsabs.harvard.edu/link_gateway/2025JGIS...17....1G/doi:10.4236/jgis.2025.171001
- Gómez, D., Salvador, P., Sanz, J., & Casanova, J. (2019). Potato yield prediction using machine learning techniques and Sentinel-2 data. *Remote Sensing*, 11(15), Artículo e1745. <https://www.mdpi.com/2072-4292/11/15/1745>
- Gonzaga, C. (2014). *Aplicación de índices de vegetación derivados de imágenes satelitales Landsat 7 ETM+ y ASTER para la caracterización de la cobertura vegetal en la zona centro de la provincia de Loja, Ecuador* [Tesis de maestría, Universidad Nacional de La Plata]. SEDICI. <https://sedici.unlp.edu.ar/handle/10915/34487>

- Google. (2025a). [Reboledo, Florida, Uruguay. Mapa]. Recuperado el 28 de octubre de 2025, de https://earth.google.com/web/search/Reboledo+Departamento+de+Florida/@-33.96988613,-55.4985762,170.0624258a,8415.13661307d,35y,0h,0t,0r/data=CiwiJgokCSnh6U9lJTNAESfh6U9lJTPAGT595KsyfkhAIA5dZ06hUnAQgIIAToDCgEwQgIIAEoNCP_____wEQAA
- Google. (2025b). [Rocha, Uruguay. Mapa]. Recuperado el 28 de octubre de 2025, de https://earth.google.com/web/search/Reboledo+Departamento+de+Florida/@-34.34372677,-54.50014906,140.29186976a,6383.76502824d,35y,0h,0t,0r/data=CiwiJgokCSnh6U9lJTNAESfh6U9lJTPAGT595KsyfkhAIA5dZ06hUnAQgIIAToDCgEwQgIIAEoNCP_____wEQAA?authuser=0
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Guzmán Yera, M. (2019). *Modelos de distribución potencial de especies forestales en las Sierras de Jaén: Aplicaciones de alta resolución* [Tesis de maestría, Universidad de Jaén]. CREA. <https://crea.ujaen.es/server/api/core/bitstreams/f05fdda9-07a5-4497-a921-8126dc557391/content>
- Hasanlou, M., & Mostofi, N. (2015, 22 de junio-5 de julio). *Investigating urban heat island estimation and relation between various land cover indices in Tehran City using Landsat 8 imagery* [Contribución]. 1st International Electronic Conference on Remote Sensing, Tehran. <https://www.sciforum.net/paper/download/2903/manuscript>
- He, T., Zhou, H., Xu, C., Hu, J., Xue, X., Xu, L., Lou, X., Zeng, K., & Wang, Q. (2023). Deep learning in forest tree species classification using Sentinel-2 on Google Earth Engine: A case study of Qingyuan County. *Sustainability*, 15(3), Artículo e2741. <https://doi.org/10.3390/su15032741>
- Hirigoyen, A. (2022). Teledetección para el manejo forestal: Aportes a una tecnología de uso creciente en Uruguay. *Revista INIA*, (69), 97-100. <https://ainfo.inia.uy/digital/bitstream/item/16545/1/Revista-INIA-69-Junio-2022-19.pdf>
- Hirigoyen, A., Varo-Martínez, M. A., Rachid-Casnati, C., Franco, J., & Navarro-Cerrillo, R. M. (2020). Stand characterization of Eucalyptus spp. plantations in Uruguay using airborne LiDAR scanner technology. *Remote Sensing*, 12(23), Artículo e3947. <https://www.mdpi.com/2072-4292/12/23/3947>
- Immitzer, M., Vuolo, F., & Atzberger, C. (2016). First experience with Sentinel-2 data for crop and tree species classifications in central Europe. *Remote Sensing*, 8(3), Artículo e166. <https://www.mdpi.com/2072-4292/8/3/166>

- Instituto Uruguayo de Meteorología. (s.f.). *Características climáticas*.
<https://www.inumet.gub.uy/clima/estadisticas-climatologicas/caracteristicas-climaticas>
- Jacobo, J., Guevara, H., & Cruz, Ó. (2024). Teledetección y automatización en la agricultura del futuro. *Elementos*, 133, 79-84.
https://www.researchgate.net/profile/Oscar-Cruz-Alvarez/publication/372502596_Teledeteccion_y_automatizacion_en_la_agricultura_del_futuro/links/6594a3a30bb2c7472b2c503f/Teledeteccion-y-automatizacion-en-la-agricultura-del-futuro.pdf
- Karlsson, A. (2003). *Classification of high resolution satellite images* [Tesis de maestría, École Polytechnique Fédérale de Lausanne]. Infoscience.
<https://infoscience.epfl.ch/bitstreams/f582f824-9557-4223-8402-a675c63e8b8f/download>
- Kumar, L., Schmidt, K. S., Dury, S., & Skidmore, A. K. (2007). Imaging spectrometry and vegetation science. En L. Kumar, K. S. Schmidt, S. Dury & A. K. Skidmore (Eds.), *Imaging spectrometry and vegetation science* (pp. 1-20). CRC.
<https://rune.une.edu.au/entities/publication/a2a46960-4a37-48d5-9d26-e29e4d0c3ab9>
- Ley n.º 15.939: *Ley Forestal: Fondo Forestal: Recursos Naturales*. (1987). IMPO.
<https://www.impco.com.uy/bases/leyes/15939-1987>
- Liang, S., & Wang, J. (Eds.). (2019). *Advanced remote sensing: Terrestrial information extraction and applications* (2nd ed.). Academic Press.
https://books.google.com.uy/books?id=1-y_DwAAQBAJ
- Majaura, M., Böhm, C., & Freese, D. (2024). The influence of trees on crop yields in temperate zone alley cropping systems: A review. *Sustainability*, 16(8), Artículo e3301. <https://www.mdpi.com/2071-1050/16/8/3301>
- Martínez-Barbáchano, R., & Solís-Miranda, G. A. (2018). Caracterización espectral y detección de flecha seca en palma africana en Puntarenas, Costa Rica. *Revista Geográfica de América Central*, 2(61), 349-367.
<https://www.redalyc.org/articulo.oa?id=451755941013>
- Ministerio de Ambiente. (2021, 29 de julio). *Definición, caracterización y cuantificación del área bajo sistemas silvopastoriles en Uruguay*.
<https://www.gub.uy/ministerio-ambiente/comunicacion/noticias/definicion-caracterizacion-cuantificacion-del-area-bajo-sistemas>

- Morell-Monzó, M., & Garófano-Gómez, V. (2022). *Investigación del abandono de tierras en la comarca de La Safor (Comunitat Valenciana) utilizando datos Sentinel-2*. CDR La Safor; COCEDER; Gobierno de España.
<https://www.coceder.org/wp-content/uploads/2023/01/Abandonament-terres-Safor-Marc-MorellMonzo-Virginia-Garofano-Gomez.pdf>
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247-259.
<https://www.sciencedirect.com/science/article/abs/pii/S0924271610001140>
- Munka, C. (2017). Microclima en sistemas silvopastoriles. En Polo Agroforestal (Ed.), *I Seminario en sistemas silvopastoriles: Producción integrada para maximizar la rentabilidad* (pp. 63-68). Universidad de la República; INIA.
<https://www.poloagroforestal.edu.uy/wp-content/uploads/2020/02/Revista-I-Integraci%C3%B3n-Ganader%C3%ADa-Forestal-Integraci%C3%B3n.pdf>
- Nasiri, V., Deljouei, A., Moradi, F., Mohammad, S., & Borz, S. A. (2022). Land use and land cover mapping using Sentinel-2, Landsat-8 satellite images, and Google Earth Engine: A comparison of two composition methods. *Remote Sensing*, 14(9), Artículo e1977. <https://doi.org/10.3390/rs14091977>
- Oficina de Programación y Política Agropecuaria. (2019). *Anuario OPYPA 2019*. MGAP.
<https://descargas.mgap.gub.uy/OPYPA/Anuarios/Anuario%202019/ORIGINAL%202019%20OPYPA%20INTERACTIVO%20agregado%2018-12-2019.pdf>
- Panario, D., & Gutiérrez, O. (2007, 16 de noviembre). *La política forestal industrial del Estado uruguayo* [Contribución]. Seminario Política y pasteras en el Río Uruguay: Medio ambiente, modelos productivos y movimiento social, Argentina.
https://www.researchgate.net/publication/264840541_La_politica_forestal_industrial_del_Estado_uruguayo
- Paruelo, J. M. (2008). La caracterización funcional de ecosistemas mediante sensores remotos. *Ecosistemas*, 17(3), 4-22.
<http://revistaecosistemas.net/index.php/ecosistemas/article/view/83>
- Peerbhay, K. Y., Mutanga, O., & Ismail, R. (2014). Investigating the capability of few strategically placed WorldView-2 multispectral bands to discriminate forest species in KwaZulu-Natal, South Africa. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(1), 307-316.
<https://www.semanticscholar.org/paper/Investigating-the-Capability-of-Few-Strategically-Peerbhay-Mutanga/2d82eae54b83b9ec120eed940d752e2b60cfe0d9>

- Perilla, G., & Mas, J. F. (2020). Google Earth Engine (GEE): Una poderosa herramienta que vincula el potencial de los datos masivos y la eficacia del procesamiento en la nube. *Investigaciones Geográficas*, (101), Artículo e00111. https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0188-46112020000100111
- Phan, T. N., Kuch, V., & Lehnert, L. W. (2020). Land cover classification using Google Earth Engine and random forest classifier: The role of image composition. *Remote Sensing*, 12(15), Artículo e2411. <https://www.mdpi.com/2072-4292/12/15/2411>
- Picone, N. (2017). *Comparación de imágenes satelitales Sentinel-2 y Landsat 8 en el estudio de áreas urbanas* [Contribución]. Congreso Nacional de Geografía de Universidades Nacionales, Argentina. https://www.researchgate.net/profile/Natasha-Picone/publication/320705706_COMPARACION_DE_IMAGENES_SATELITALES_SENTINEL_2_Y_LANDSAT_8_EN_EL_ESTUDIO_DE_AREAS_URBANAS/links/59f658e80f7e9b553ebd29c1/COMPARACION-DE-IMAGENES-SATELITALES-SENTINEL-2-Y-LANDSAT-8-EN-EL-ESTUDIO-DE-AREAS-URBANAS.pdf
- Posada, E., Ramirez, H., & Espejo, N. (2012). *Manual de prácticas de percepción remota con el programa ERDAS IMAGINE 2011*. UN; IGAC. <https://es.slideshare.net/slideshow/manual-erdas-web-56559578/56559578>
- Poveda-Sotelo, Y., Bermúdez-Cella, M. A., & Gil-Leguizamón, P. (2022). Evaluación de métodos de clasificación supervisada para la estimación de cambios espacio-temporales de cobertura en los páramos de Merchán y Telecom, Cordillera Oriental de Colombia. *Boletín de Geología*, 44(2), 51-72. http://www.scielo.org.co/scielo.php?pid=S0120-02832022000200051&script=sci_arttext
- Praticò, S., Solano, F., Di Fazio, S., & Modica, G. (2021). Machine learning classification of Mediterranean forest habitats in Google Earth Engine based on seasonal Sentinel-2 time-series and input image composition optimisation. *Remote Sensing*, 13(4), Artículo e586. <https://doi.org/10.3390/rs13040586>
- Rizzo-Martín, I., Hirigoyen-Domínguez, A., Arthus-Bacovich, R., Varo-Martínez, M. Á., & Navarro-Cerrillo, R. (2023). Site index estimation using airborne laser scanner data in Eucalyptus dunnii Maiden stands in Uruguay. *Forests*, 14(5), Artículo e933. <https://www.mdpi.com/1999-4907/14/5/933>
- Rodríguez, D., Sánchez, N., Domínguez, J., & Santa, C. (2015). *Cuestiones de teledetección*. Universidad Nacional de Educación a Distancia. <https://books.google.com/books?hl=es&lr=&id=tXxxCgAAQBAJ>

- Roman-Gonzalez, A., & Vargas-Cuentas, N. I. (2013). Análisis de imágenes hiperespectrales. *Revista Ingeniería & Desarrollo*, 9(35), 14-17.
<https://hal.science/hal-00935014/>
- Ruiz, A., & Cardoso, A. (2023). *AI-driven tree monitoring for silvopastoral systems using remote sensing imagery*. International Center for Tropical Agriculture.
<https://cgspace.cgiar.org/server/api/core/bitstreams/33946028-2cb7-4813-b0c7-56810d67c3f6/content>
- Sancho, L., Arocena, I., & Ordeig, L. (2021). *Definición, caracterización y cuantificación del área bajo sistemas silvopastoriles, para el seguimiento de las contribuciones establecidas en la Contribución determinada a nivel nacional de Uruguay (Proyecto URU/18/G31): Informe final*. MA; MGAP; GEF; PNUD.
https://www.gub.uy/ministerio-ambiente/sites/ministerio-ambiente/files/documentos/noticias/informe_final.pdf
- Schinato, F. (2022). *Evaluación de servicios ambientales en un sistema silvopastoril* [Tesis de maestría, Universidad de la República]. Colibri.
<https://www.colibri.udelar.edu.uy/jspui/bitstream/20.500.12008/35851/1/SchinatoFranco.pdf>
- Segarra, J., Buchailot, M. L., Araus, J. L., & Kefauver, S. C. (2020). Remote sensing for precision agriculture: Sentinel-2 improved features and applications. *Agronomy*, 10(5), Artículo e641. <https://doi.org/10.3390/agronomy10050641>
- Silveira, E. D., Da Rosa, E., Bonino, L., Zanoniani, R., & Boggiano, P. (2017). Productividad de mezclas forrajeras a cielo abierto y bajo un sistema silvopastoril. En W. Ayala, P. Boggiano & O. Alvarez (Eds.), *XXIV Reunión del grupo técnico en forrajeras del Cono Sur: Bioma Campos: Retomando un camino de oportunidades para una producción ganadera sustentable: Memorias* (p. 160). INIA; Universidad de la República.
<https://ainfo.inia.uy/digital/bitstream/item/7112/1/Grupo-Campo-2017.pdf>
- Soares de Lima, J., Scoz, R., & Lanfranco, B. (2020). Sistemas de producción silvopastoriles: Cuando 1 + 1 es igual a 3. *Revista INIA*, (60), 61-65.
<https://ageconsearch.umn.edu/record/310240/?v=pdf>
- Sobrino, J. A. (2001). *Teledetección*. Universidad de Valencia.
<https://www.google.com.uy/books/edition/Teledetecci%C3%B3n/Yb6xIldfoT0C>
- Son, J., & Yang, S. (2022). A new approach to machine learning model development for prediction of concrete fatigue life under uniaxial compression. *Applied Sciences*, 12(19), Artículo e9766. <https://doi.org/10.3390/app12199766>

- Sotomayor, Á., Teuber, O., & Moya, I. (2009). Resultados y experiencias sobre manejo de sistemas silvopastorales en la región de Aysén. En O. Teuber (Ed.), *Sistemas agroforestales para la región de Aysén: Cortinas cortaviento y silvopastoreo* (pp. 165-199). Instituto Forestal.
<https://bibliotecadigital.infor.cl/handle/20.500.12220/17545>
- Stone, C. (2001). Reducing the impact of insect herbivory in eucalypt plantations through management of extrinsic influences on tree vigour. *Austral Ecology*, 26(5), 482-488.
- Šumanovac, L. (2024). *Classification of land cover and agricultural land using Google Earth Engine* [Trabajo final de grado, Sveučilište Josipa Jurja Strossmayera u Osijeku]. Repozitorij Fakulteta agrobiotehničkih znanosti Osijek.
<https://repozitorij.fazos.hr/object/pfos:4150>
- Torres, P. (2024). *Evaluación del estado de salud de las masas forestales de la Comunidad de Madrid mediante técnicas de teledetección* [Disertación doctoral, Universidad de Alcalá]. Repositorio eBUAH.
<https://ebuah.uah.es/dspace/bitstream/handle/10017/61820/Tesis%20Pablo%20Jesus%20Torres%20Hernandez.pdf?sequence=1&isAllowed=y>
- Tovar, A. L., Lizarazo, I. A., & Rodríguez, N. (2020). Estimación de biomasa aérea de *Eucalyptus grandis* y *Pinus* spp. usando imágenes Sentinel-1A y Sentinel-2A en Colombia. *Colombia Forestal*, 23(1), 79-93.
<https://revistas.udistrital.edu.co/index.php/colfor/article/view/14854/15442>
- Tristán, P., Wainschenker, R., & Doorn, J. H. (2008, 7-8 de mayo). *Normalización de imágenes satelitales en el análisis multitemporal* [Contribución]. X Workshop de Investigadores en Ciencias de la Computación, La Plata.
<http://sedici.unlp.edu.ar/handle/10915/20582>
- Uruguay XXI. (2021). *Sector forestal en Uruguay*.
<https://www.uruguayxxi.gub.uy/uploads/informacion/a29771e03cc49e42fe516c01b0d271dc0fcf4cbe.pdf>
- Uruguay XXI. (2023). *Informe anual de comercio exterior de Uruguay 2023*.
<https://www.uruguayxxi.gub.uy/es/centro-informacion/articulo/informe-anual-de-comercio-exterior-de-uruguay-2023/>
- Uruguay XXI. (2024). *Informe anual de comercio exterior de Uruguay 2024*.
<https://www.uruguayxxi.gub.uy/es/centro-informacion/articulo/informe-anual-de-comercio-exterior-de-uruguay-2024/>

- Veneros, J., García, L., Morales, E., Gómez, V., Torres, M., & López-Morales, F. (2020). Aplicación de sensores remotos para el análisis de cobertura vegetal y cuerpos de agua. *Idesia (Arica)*, 38(4), 99-107. <https://doi.org/10.4067/S0718-34292020000400099>
- Verma, N. K., Lamb, D. W., & Sinha, P. (2019). Airborne LiDAR and high resolution multispectral data integration in *Eucalyptus* tree species mapping in an Australian farmscape. *Geocarto International*, 37(3), 70-90. <https://doi.org/10.1080/10106049.2019.1700555>
- Viñoles, C., Fedrigo, J. K., Benítez González, V., García, L., & Báez, F. (2022). Avances en el conocimiento sobre sistemas silvopastoriles en Uruguay. Archivos. *Latinoamericanos de Producción Animal*, 30(Supl. 1), 43-53. <https://doi.org/10.53588/alpa.300505>
- Wu, Y., & Zhang, X. (2019). Object-based tree species classification using airborne hyperspectral images and LiDAR data. *Forests*, 11(1), Artículoe32. <https://doi.org/10.3390/f11010032>
- Xie, Q., Dash, J., Huang, W., Peng, D., Qin, Q., Mortimer, H., Casa, R., Pignatti, S., Laneve, G., Pascucci, S., Dong, Y., & Ye, H. (2018). Vegetation indices combining the red and red-edge spectral information for leaf area index retrieval. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(5), 1482-1492. https://eprints.soton.ac.uk/418574/1/Final_Manuscript.pdf
- Youngentob, K. N., Renzullo, L. J., Held, A., Jia, X., Lindenmayer, D. B., & Foley, W. J. (2012). Using imaging spectroscopy to estimate integrated measures of foliage nutritional quality. *Methods in Ecology and Evolution*, 3(2), 416-426. <https://besjournals.onlinelibrary.wiley.com/doi/full/10.1111/j.2041-210X.2011.00149.x>
- Zeng, Y., Hao, D., Badgley, G., Damm, A., Rascher, U., Ryu, Y., Johnson, J., Krieger, V., Wu, S., Qiu, H., Liu, Y., Berry, J. A., & Chen, M. (2021). Estimating near-infrared reflectance of vegetation from hyperspectral data. *Remote Sensing of Environment*, 267, Artículoe112723. <https://doi.org/10.1016/j.rse.2021.112723>