



UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE CIENCIAS FORESTALES
INGENIERÍA FORESTAL

**DETECCIÓN ESPECTRAL DE ESPECIES ARBÓREAS MEDIANTE DATOS
IN-SITU E IMÁGENES HIPERESPECTRALES AÉROTRANSPORTADAS:
CASO DE ESTUDIO LAGUNA GRANDE SAN PEDRO DE LA PAZ.**

Tesis presentada a la Facultad de Ciencias Forestales de la Universidad de
Concepción para otorgar al título profesional de Ingeniero Forestal

POR: Nicolás Andrés Córdova Olea

Profesor Guía: Santiago Paul Yépez Figueroa

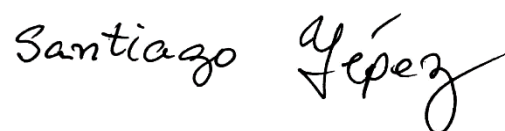
Junio, 2024

Concepción, Chile

© 2024, Nicolás Andrés Córdova Olea

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento

DETECCIÓN ESPECTRAL DE ESPECIES ARBÓREAS MEDIANTE DATOS IN
SITU E IMÁGENES HIPERESPECTRALES AÉROTRASPORTADAS: CASO
DE ESTUDIO LAGUNA GRANDE SAN PEDRO DE LA PAZ.

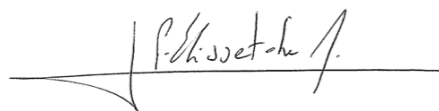


Profesor Guía

Santiago Paúl Yépez Figueroa

Profesor Asociado

Ingeniero Geólogo, Dr.



Profesor Guía

Juan Pedro Elissetche Martínez

Profesor Asociado

Ingeniero Forestal, Dr.

AGRADECIMIENTOS

Quiero expresar mi más profundo agradecimiento a la Universidad de Concepción por brindarme el espacio y los conocimientos necesarios para concretar este proyecto. Agradezco a cada académico y funcionario de la Facultad de Ciencias Forestales por brindarme un segundo hogar y otorgar conocimientos y valores muy importantes para mi futuro profesional.

En particular, deseo agradecer al profesor Santiago Yopez F. y al profesor Juan Elissetche M. por confiar en mí y apoyarme en la elaboración de mi tesis. Sus consejos, material académico y experiencia profesional han hecho de este camino una experiencia más agradable y enriquecedora. Valoro enormemente su tiempo y sus conocimientos, así como la atención brindada ante mis consultas.

No quiero pasar por alto a mis padres, quienes han sido los pilares fundamentales en mi desarrollo profesional y en muchos otros aspectos importantes de mi vida. Su cariño y apoyo incondicional han sido esenciales para llegar hasta aquí. A mis hermanos y hermanas, gracias por su apoyo incondicional y los momentos de alegría que compartimos en familia.

Un agradecimiento especial a Valentina, cuyo amor y apoyo en estos últimos años de universidad han sido fundamentales. Su presencia ha hecho este tramo final más cálido y acompañado, y por ello, le estoy eternamente agradecido.

TABLA DE CONTENIDO

RESUMEN	xi
ABSTRACT	xiii
I. INTRODUCCIÓN	1
II. HIPÓTESIS Y OBJETIVOS	7
2.1 Hipótesis	7
2.2 Objetivo General	7
2.3 Objetivos Específicos	7
III. MARCO TEÓRICO	8
3.1 Importancia de los inventarios forestales en terreno	8
3.2 Tecnologías utilizadas para la identificación espectral de especies arbóreas, ventajas y limitaciones	13
3.3 Espectro electromagnético	16
3.4 Firma espectral.....	18
3.5 Imágenes Hiperespectrales.....	19
3.6 Aplicación de técnicas y modelos de aprendizaje automático para la identificación de especies arbóreas.....	21
IV. METODOLOGÍA.....	25
4.1 Descripción del área de estudio	25
4.2 Muestreo de campo	28
4.3 Adquisición de imágenes hiperespectrales	29
4.5 Procesamiento de imágenes hiperespectrales	30
4.6 Creación de mosaico hiperespectral	32
4.7 Mascara forestal.....	35
4.8 Transformación MNF.....	37
4.9 Generación de conjuntos de datos de entrenamiento y validación mediante la segmentación de las copas arbóreas	38
4.10 Creación de librería espectral de especies arbóreas.....	39
4.11 Clasificación de especies arbóreas	39
4.12 Validación estadística de modelos de clasificación.....	43
V. RESULTADOS	47

5.1	Inventario en terreno	47
5.2	Resultados del mosaico hiperespectral	51
5.3	Firmas espectrales por especie	52
5.4	Clasificación SVM y RF en imagen RGB.....	54
5.5	Clasificación RF y SVM en imagen MNF.....	62
VI.	DISCUSIÓN.....	70
VII.	CONCLUSIONES	73
VIII.	BIBLIOGRAFÍA.....	76
IX.	APÉNDICE	82

ÍNDICE DE TABLAS

Tabla 1. Tabla de muestras por especie.....	42
Tabla 2. Estructura de una matriz de confusión simple proporcionada por Orfeo ToolBox.....	44
Tabla 3. Valorización de Índice Kappa.....	46
Tabla 4. Parámetros de desempeño para la clasificación SVM en imagen RGB.	54
Tabla 5. Parámetros de desempeño para la clasificación RF en imagen RGB.	58
Tabla 6. Parámetros de desempeño para la clasificación RF en imagen MNF.	62
Tabla 7. Parámetros de desempeño para la clasificación SVM en imagen MNF.	66

ÍNDICE DE ILUSTRACIONES

Figura 1. Espectro electromagnético.....	18
Figura 2. Curvas de reflectancia espectral de algunos tipos de vegetación.....	19
Figura 3. Localización y planificación de vuelo de la Laguna Grande de San Pedro de la Paz. Las líneas amarillas corresponden a las imágenes utilizadas en este estudio para hacer el mosaico con las escenas HySpex VNIR-1800.....	26
Figura 4. Flujograma de trabajo para la captura de datos, procesamiento de imágenes, clasificación y validación.....	27
Figura 5. Cámara hiperespectral HySpex VNIR-1800.....	30
Figura 6. Sistema de coordenadas del sensor rotado (x' , y' , z') en el espacio y la orientación de los ángulos de actitud (ω , ϕ , κ), El vector de barrido L1 se obtiene por transformación del sistema de coordenadas.....	31
Figura 7. (a) Ensamble de las cuatro líneas hiperespectrales; (b) Mosaico hiperespectral.....	34
Figura 8. Umbral de áreas no forestales (en rojo).....	36
Figura 9. Regiones de interés sobre copas de árboles para la fase de entrenamiento (verde) y validación (azul).	38
Figura 10. Muestreo de especies arbóreas.....	49
Figura 11. Árboles dominantes de <i>Pinus radiata</i> en el área de estudio.....	50
Figura 12. (a) Boldo (<i>Peumus boldus</i>) y (b) Peumo (<i>Cryptocaria alba</i>).....	51
Figura 13. La primera imagen (a) representa una imagen del área de estudio en color verdadero. La segunda (b) una imagen en MNF.	52
Figura 14. Firmas espectrales por especie.....	53
Figura 15. Matriz de confusión de la clasificación SVM en imagen RGB.....	55
Figura 16. Clasificación SVM en imagen RGB.....	56
Figura 17. Distribución de cobertura de especies a partir de la clasificación SVM en Imágenes RGB.....	57
Figura 18. Matriz de confusión de la clasificación RF en imagen RGB.....	59
Figura 19. Clasificación RF en imagen RGB.....	60
Figura 20. Distribución de cobertura de especies a partir de la clasificación RF en Imágenes RGB.....	61
Figura 21. Matriz de confusión de la clasificación RF en imagen MNF.....	63
Figura 22. Clasificación RF en imagen MNF.....	64
Figura 23. Distribución de cobertura de especies a partir de la clasificación RF en imagen MNF.....	65
Figura 24. Matriz de confusión de la clasificación SVM en imagen MNF.....	67
Figura 25. Clasificación SVM en imagen MNF.....	68
Figura 26. Distribución de cobertura de especies a partir de la clasificación RF en imagen MNF.....	69

RESUMEN

Este estudio evaluó el uso de imágenes hiperespectrales para identificar especies arbóreas alrededor del Santuario de la Naturaleza Laguna Grande - Humedal Los Batros, Chile, destacando la necesidad de técnicas avanzadas en la gestión de ecosistemas. Se usaron imágenes hiperespectrales con métodos de Machine Learning, específicamente Support Vector Machine (SVM) y Random Forest (RF), para clasificar y georreferenciar especies arbóreas y vegetación. Las muestras se identificaron y georreferenciaron in-situ, creando una librería espectral para entrenar y validar los modelos. Los resultados muestran que las imágenes hiperespectrales, especialmente con el preprocesamiento MNF (Minimum Noise Fraction), permitieron alta precisión en la clasificación de especies. SVM logró una precisión del 90% y un índice Kappa de 0,89 en imágenes en color verdadero, mientras que RF alcanzó un 43% de precisión y un índice Kappa de 0,33. En imágenes MNF, SVM obtuvo un 74% de precisión y un índice Kappa de 0,72, mientras que RF logró un 75% de precisión y un índice Kappa de 0,73. Las especies exóticas *Eucalyptus globulus* y *Cupressus macrocarpa* mostraron dominancia, afectando la cobertura forestal, aunque hubo errores de mezcla en la clasificación, especialmente con *Acacia melanoxylon* y *Cupressus macrocarpa*, debido a su baja reflectividad. Los resultados destacan la eficacia de las imágenes hiperespectrales y los modelos de Machine Learning en la identificación de especies arbóreas, aunque también revelan la necesidad

de mejorar las técnicas de clasificación para resolver desafíos específicos. En conclusión, la teledetección hiperespectral es una herramienta valiosa para la gestión y conservación de ecosistemas forestales, proporcionando una base sólida para futuras investigaciones.

ABSTRACT

This study evaluated the use of hyperspectral imagery to identify tree species around the Laguna Grande Nature Sanctuary - Los Batros Wetland, Chile, highlighting the need for advanced techniques in ecosystem management. Hyperspectral images were employed with Machine Learning methods, specifically Support Vector Machine (SVM) and Random Forest (RF), to classify and georeference tree species and vegetation. Samples were identified and georeferenced in situ, creating a spectral library to train and validate the models. The results indicate that hyperspectral images, particularly with Minimum Noise Fraction (MNF) preprocessing, enabled high precision in species classification. SVM achieved 90% accuracy and a Kappa index of 0.89 in true color images, while RF achieved 43% accuracy and a Kappa index of 0.33. In MNF images, SVM achieved 74% accuracy with a Kappa index of 0.72, while RF achieved 75% accuracy with a Kappa index of 0.73. Exotic species such as *Eucalyptus globulus* and *Cupressus macrocarpa* exhibited dominance, impacting forest cover, though classification errors occurred, particularly with *Acacia melanoxylon* and *Cupressus macrocarpa* due to their low reflectivity. The results underscore the effectiveness of hyperspectral imagery and Machine Learning models in identifying tree species, while also highlighting the need to enhance classification techniques to address specific challenges. In conclusion, hyperspectral remote

sensing proves to be a valuable tool for the management and conservation of forest ecosystems, laying a solid foundation for future research.

I. INTRODUCCIÓN

En los bosques, los árboles son los principales actores naturales, cumpliendo diferentes funciones ecológicas. En Chile, a escala nacional los bosques nativos se caracterizan por presentar un particular patrón de diversidad, cubriendo una superficie de 14.758.614 hectáreas (Poblete et al., 2023, p. 44).

En cuanto, a los bosques nativos de la comuna de Concepción, región del Biobío, es ampliamente conocido que estos fueron explotados intensivamente por el cambio de uso de suelo, principalmente para el establecimiento de la agricultura, así como la extracción de recursos madereros. Espinosa et al. (2017) destaca los efectos de degradación que surgieron debido a la alta demanda de trigo, durante la fiebre del oro en California y Australia, lo que condujo a un uso insostenible de la tierra (p. 75) y, cuando finalmente el suelo evidenció problemas erosivos, la especie *Pinus radiata* (D.Don), se estableció como una manera de mitigar dichos efectos. La sustitución de la cobertura forestal nativa en la región del Biobío ha ocasionado la pérdida significativa de biodiversidad.

Es esencial entender la composición de los bosques remanentes, lo que implica identificar y clasificar las especies arbóreas presentes en la zona, a través de un proceso de caracterización. Esta actividad, es fundamental para conocer la diversidad arbórea y para emplear buenas prácticas de conservación. Vílchez

(2002), indica que el proceso mencionado es insustituible para la conservación de la biodiversidad y la valoración de los servicios ecosistémicos ambientales que brindan los bosques, tales como, la mitigación de gases por efecto invernadero, recreación, la regulación de caudales, la calidad del agua y la prevención o atenuación de desastres naturales (p. 15). Por otra parte, llevar a cabo un registro o inventario de las especies forestales nativas, dentro de una determinada área natural, se hace imprescindible para monitorear y evaluar la distribución, abundancia, así como el estado de las especies forestales (Liu et al., 2017, p. 3).

A partir de la relevancia mencionada sobre la identificación de especies y sus beneficios culturales y ambientales, es importante implementar herramientas que nos permitan reconocer la ubicación espacial de las especies arbóreas en una zona específica. Dicho lo anterior, la teledetección hiperespectral aérea, se posiciona como una tecnología de punta para estudiar su distribución espacial y para monitorear su condición fitosanitaria, a través de la respuesta espectral usando la radiación electromagnética reflejada por las hojas y canopia (Acuña et al., 2016, p.3; Gonzalez y Vargas, 2013, p.5).

En esta investigación, un tema de especial interés, son las imágenes hiperespectrales que poseen una alta resolución espectral y espacial. Paoletti et al. (2019) destaca que este tipo de imágenes, capturadas por sensores ópticos, revelan información del espectro electromagnético, proporcionando una visión

detallada y simultánea de la superficie terrestre (p. 2), muchas veces invisibles al ojo humano.

En el trabajo de Trier et al. (2018), se menciona que los datos hiperespectrales pueden proporcionar información sobre parámetros biofísicos y bioquímicos, así como también la composición de las especies vegetales (p. 3), En cuanto a las imágenes hiperespectrales, estas se han empleado con éxito en el mapeo de especies arbóreas (Medina et al., 2018, p. 2). En este contexto, el uso de imágenes hiperespectrales para la detección de especies forestales ha resultado de gran utilidad para su identificación y distribución precisa de dichas especies a nivel de individuo, que son esenciales para la gestión forestal y la evaluación del estrés medioambiental (Verma et al., 2023, p. 1).

En Chile, los Santuarios de la Naturaleza son áreas resguardadas por el Ministerio de Medio Ambiente. Tanto los sitios terrestres como los marinos brindan oportunidades particulares para estudios e investigaciones en diversas disciplinas, siendo su conservación de interés tanto científico como estatal, según lo establece el Artículo 31° de la Ley 17.288 de Monumentos Nacionales y Normas Relacionadas (p. 30). Este tipo de área protegida está clasificada como categoría tipo IV según la Unión Internacional para la Conservación de la Naturaleza (UICN), donde su principal objetivo es mantener, conservar y restaurar especies y hábitats (Sierralta et al., 2011, p. 23). A pesar de las

regulaciones gubernamentales que respaldan los Santuarios de la Naturaleza en Chile, Sierralta et al. (2011) define que estas áreas protegidas se enfrentan a desafíos clave que incluyen mejorar la representación de ecosistemas nacionales bajo presión, optimizar la financiación y lograr una gestión eficiente y estandarizada de las áreas protegidas en Chile (p. 34).

La variedad de desafíos que enfrentan los Santuarios de la Naturaleza ya sea debido al cambio climático o al escaso interés de las comunidades en comprender y, a su vez, preservar, constituye una problemática compleja. Es así como resalta la importancia de fortalecer las medidas de preservación y gestión integral en estos santuarios, asegurando así la sostenibilidad de estos preciados espacios naturales (Cárdenas et al., 2023, p. 13). Aunque en Chile están trabajando en estrategias para proteger la biodiversidad en tierra y mar, estas no son suficientes para resolver todos los problemas. Esto destaca la necesidad de un enfoque más completo y fuerte para asegurar la salud de estos importantes entornos naturales (Jorquera et al., 2012, p. 10).

Dado este contexto, existe una realidad donde se presentan algunas de las problemáticas previamente señaladas. En el caso del Santuario de la Naturaleza “Laguna Grande - Humedal Los Batros”, se encuentra emplazada en la Región del Biobío, provincia de Concepción, específicamente en la comuna de San Pedro de la Paz, Según el Decreto N°42 de 2021 del Ministerio del Medio

Ambiente, este ecosistema acuático forma parte del Plan Nacional de Protección de Humedales del 2018 al 2022. Posee una superficie de 312 hectáreas aproximadamente; una gran riqueza de especies y un alto valor ecológico, además de flora nativa y endémica, así mismo, sirve como refugio para la fauna y especies de aves migratorias.

A pesar de ser designado como Santuario de la Naturaleza y reconocido por su valioso patrimonio ambiental, así como por su diversidad de especies nativas y endémicas, el sitio carece de un registro que documente la distribución espacial de sus especies arbóreas. La comprensión de los patrones espaciales y las interacciones entre estas especies en los bosques es esencial para llevar a cabo una gestión forestal efectiva y abordar la restauración de ecosistemas degradados (Zhang et al., 2010, p. 1).

Esta investigación aborda lagunas cruciales en la conservación de la biodiversidad arbórea al emplear imágenes hiperespectrales y datos in-situ para generar un mapa detallado de la distribución individual de especies. Este enfoque identifica especies clave para la conservación, reforestación y protección en futuros planes de manejo. Proponemos también un sistema de monitoreo basado en la cartografía detallada, que permitirá localizar “hotspot” de biodiversidad y focalizar eficazmente sitios óptimos para reforestación, destacando nuestra

contribución significativa hacia la gestión y protección efectiva de estos entornos naturales.

El objetivo principal de este estudio se centra en utilizar datos in-situ e imágenes hiperespectrales aéreas HySpex VNIR-1800 (de la empresa NEO), para realizar una detección espectral precisa de especies arbóreas en la cobertura forestal ubicada en los alrededores de la Laguna Grande ubicada dentro del área urbana de San Pedro de La Paz.

II. HIPÓTESIS Y OBJETIVOS

2.1 Hipótesis

¿Es posible evaluar el potencial del uso de imágenes hiperespectrales para identificar con precisión especies arbóreas alrededor del Santuario de la Naturaleza Laguna Grande - Humedal Los Batros, mediante técnicas de espectrometría de imágenes y clasificaciones empleando técnicas Machine Learning?.

2.2 Objetivo General

Reconocer e identificar especies arbóreas ubicadas alrededor del Santuario de la Naturaleza Laguna Grande - Humedal Los Batros, mediante el uso combinado de imágenes hiperespectrales y validación in-situ.

2.3 Objetivos Específicos

- Identificar y georreferenciar in-situ especies arbóreas y otras especies vegetales para entrenar y validar los modelos clasificación espectral.
- Generar librería espectral de las especies arbóreas y arbustivas.
- Clasificación espectral de especies usando métodos no paramétricos Machine Learning, incluyendo su validación estadística.

III. MARCO TEÓRICO

En este apartado, se llevará a cabo una revisión bibliográfica enfocada en la identificación de especies arbóreas mediante imágenes hiperespectrales. La investigación se sustentará con literatura científica actual y relevante, abordando temas como la identificación de especies arbóreas, características de las imágenes hiperespectrales, modelos de aprendizaje automático (Machine Learning), métodos de validación estadística para evaluación de modelos. Esta revisión bibliográfica busca proporcionar una comprensión integral, contextualizando mediante fundamentos teóricos sobre el uso de técnicas hiperespectrales, destacando tendencias emergentes en la identificación de especies arbóreas mediante esta tecnología.

3.1 Importancia de los inventarios forestales en terreno

La Ley 20.283 de Recuperación de Bosque Nativo y Fomento Forestal, establece definiciones fundamentales como árbol y bosque, los cuales de acuerdo con el documento legal en el artículo N°2, se entienden como:

Árbol: planta de fuste generalmente leñoso, que en su estado adulto y en condiciones normales de hábitat puede alcanzar, a lo menos, cinco metros de altura, o una menor, en condiciones ambientales que limiten su desarrollo (p.1).

Bosque: sitio poblado con formaciones vegetales en las que predominan árboles y que ocupa una superficie de por lo menos 5.000 metros cuadrados, con un ancho mínimo de 40 metros, con cobertura de copa arbórea que supere el 10% de dicha superficie total, en condiciones áridas y semiáridas y el 25% en circunstancias más favorables (p.1).

En línea con las definiciones previamente mencionadas, se destaca el esfuerzo de autores como Rodríguez et al. (2005) llevaron a cabo la creación de un libro que presenta los árboles más relevantes del país. Este trabajo detallado proporciona información sobre: botánica, origen y distribución geográfica, usos conocidos, así como una ilustración para la identificación de cada especie. Esto contribuye a la comprensión y a definir la identidad de los bosques chilenos.

En este contexto, existe una profunda preocupación por conocer los tipos de especies dominantes en los bosques. Se destaca la colaboración de García y Ormazabal (2008), entre ENERSIS y la Fundación Huinay, que resultó en la elaboración de un libro sobre especies arbóreas nativas en Chile. Este proyecto llevó a cabo un minucioso catastro de las especies presentes en el territorio

nacional. Además de proporcionar valiosa información para la identificación y reconocimiento de especies, la visión de este trabajo refleja la importancia de aplicar este procedimiento. Valorando el bosque por sus servicios ecosistémicos, esta iniciativa también representa un compromiso con la exhibición del patrimonio biogeográfico, la contribución al equilibrio ecológico y la preservación del medio ambiente.

El caso de Chile, la identificación de árboles va más allá de la conservación del patrimonio forestal. Además de contribuir a la identificación de especies y sus familias, es necesario reunir información para apoyar su reconocimiento mediante la creación de material bibliográfico. Este esfuerzo también tiene un enfoque productivo. El Instituto Nacional Forestal (INFOR), durante las últimas dos décadas, ha llevado a cabo un inventario forestal centrado en el bosque nativo, así como plantaciones forestales. Este compromiso tiene como objetivo respaldar los procesos de toma de decisiones, procesos de exportación internacional con diversas áreas de interés tanto actuales como futuras. En este contexto, se destaca que la identificación de especies arbóreas no solo se vincula estrechamente con los servicios ecosistémicos del bosque, sino también con su valor cultural para el entorno y el medio ambiente (Tapella, 2012, p. 84.)

Los autores Rodas y Godínez (2012) definen las funciones ecosistémicas como:

Las interacciones entre las especies de flora y fauna en los ecosistemas, resultado de su dinámica propia, junto con el espacio o ambiente físico (abiótico) y la energía solar, generan una serie de funciones ecosistémicas, también conocidas como funciones ecológicas o ambientales. Ejemplos de estas funciones, incluyen el ciclo hidrológico, los ciclos de nutrientes, así como la retención de sedimentos. A través de esta interacción, se derivan diversos bienes y servicios ambientales (p. 11).

Las funciones ecológicas que proporciona un bosque se vuelven cruciales al evaluar la calidad y funcionalidad de estos tipos de ecosistemas. El reconocimiento y estudio de especies arbóreas no solo caracterizan el entorno, sino también preservan servicios ecosistémicos valiosos. Toro et al. (2017) destaca la importancia ecológica, económica y cultural de los bosques nativos, subrayando su capacidad para almacenar carbono, prevenir inundaciones, purificar agua y proporcionar madera, mientras su diversidad de especies promueve la resiliencia frente a cambios naturales a lo largo del tiempo (p. 5).

La importancia de identificar especies arbóreas se resalta a nivel internacional, demostrando su utilidad en diversas regiones y actividades productivas. En países como México, autores como Rodríguez et al. (2018), indican que la identificación de especies arbóreas es crucial para conocer las principales

especies consumidas por el ganado, permitiendo un inventario preciso y la implementación de medidas de protección y monitoreo, según sea necesario (p.7). En la sabana sudafricana, Cho et al. (2012), subrayan el papel esencial de identificar árboles como la Marula (*Sclerocarya birrea* (A. Rich.) Hochst.) en el suministro de productos forestales no madereros, para las empresas de las comunidades locales en los pastizales (p. 19).

Estos estudios destacan la importancia en la identificación de especies como un procedimiento fundamental para la gestión sostenible de recursos forestales no madereros, enfocándose en satisfacer las necesidades económicas y de subsistencia de las comunidades locales.

Adicionalmente, Cho et al. (2012), resaltan que la precisión en la cartografía y control de especies de árboles de copas grandes tiene un valor inmenso para la biodiversidad y la gestión de recursos en áreas como la sabana. Estos árboles de gran tamaño cumplen funciones clave, como ser lugares de cría para las aves, productores de frutos utilizados por comunidades locales, actuando como bombas de nutrientes, creando islas de fertilidad en el paisaje (p.18). Este enfoque preciso en la identificación de especies arbóreas contribuye significativamente a la comprensión y preservación de los ecosistemas en estas regiones.

Dada la vital relevancia de los árboles, en los últimos años se han implementado técnicas avanzadas de identificación arbórea, marcando un significativo avance en su aplicación. Este progreso tecnológico desempeña un papel crucial en la comprensión y gestión eficiente de los recursos forestales, promoviendo así el mantenimiento de la salud y equilibrio de los ecosistemas forestales, entre otros objetivos ecosistémicos.

3.2 Tecnologías utilizadas para la identificación espectral de especies arbóreas, ventajas y limitaciones

En el ámbito forestal, la tecnología se refiere al conjunto de herramientas, técnicas y métodos que se utilizan para recopilar, analizar y gestionar información relacionada con los recursos forestales.

Una de las tecnologías más reconocidas para la identificación de árboles son los inventarios forestales en terreno. Estos inventarios permiten la identificación individual de árboles, a través de características morfológicas específicas, tales como: corteza, flores, semillas, forma de la copa y hojas. Adicionalmente, Scott y Gove (2002), explican que los inventarios forestales buscan enumerar la población de árboles en un bosque y obtener información adicional, como volumen, valor, crecimiento y composición por especies (p. 2).

Otra definición relevante proviene de SERFOR (2019), que define el inventario forestal como el conteo y la medición del diámetro a la altura del pecho (DAP) y la altura comercial (Hc) de los árboles, en toda el área del bosque utilizando técnicas de muestreo tradicional. La información recopilada a través de este proceso permite estimar la cantidad de madera disponible para su aprovechamiento en toda el área del permiso (p.15).

No obstante, los inventarios forestales también presentan desventajas significativas. Los Inventarios Forestales son la fuente de datos de campo más crucial para los países y, dada su relevancia, requieren un compromiso sustancial de recursos para lograr un muestreo suficiente. Esta necesidad se vuelve especialmente evidente en paisajes extensos, heterogéneos y con una alta diversidad, donde el desafío de obtener datos precisos se incrementa (Brandeis et al., 2021, p. 4).

Por otra parte, importantes avances se han desarrollado dentro del campo de la identificación de árboles, donde destaca la implementación de tecnologías de Sistema de Información Geográfica (en adelante, SIG), de acuerdo con la literatura, y según el autor Bravo (2000) “son un método o técnica de tratamiento de la información geográfica que permite combinar eficazmente información básica para obtener información derivada” (p.6). Procesos como la fotointerpretación mediante imágenes remotas, permite determinar manualmente

áreas boscosas en entornos naturales o urbanos, facilitando la gestión de dichos recursos. De acuerdo con lo que plantea Mena et al. (2011) la combinación y aplicación de la fotointerpretación, los SIG y la planificación urbana pueden constituir una herramienta valiosa para promover el desarrollo sostenible en los ámbitos económico, social y ambiental (p. 3).

Adicionalmente, cabe destacar la presencia de la tecnología de teledetección, cuyos fundamentos se originan en la década de los años 60', impulsados principalmente por misiones espaciales y aplicaciones militares (Echeverri, 2013, p. 7). Esta tecnología, según la definición proporcionada por Gonzalez y Vargas (2013) comprende métodos para identificar propiedades de objetos, ya sean naturales o artificiales, a distancia. En otras palabras, implica obtener información sobre la superficie terrestre sin contacto físico, capturando y registrando la energía reflejada para su posterior procesamiento y aplicación en diversas áreas (p. 2). Esta poderosa herramienta en la actualidad tiene múltiples usos, como la obtención de información de satélites civiles para la movilización de manera más efectiva, hasta tener acceso a internet o televisión satelital.

Para poder comprender con mayor facilidad cómo funciona este tipo de tecnologías, autores como Perez y Muñoz (2006) indican que un sistema de

teledetección utiliza la radiación solar reflejada en la Tierra, captada por sensores óptico-electrónicos en vehículos espaciales tras atravesar la atmósfera (p. 20).

Este nuevo tipo de tecnología ha revolucionado significativamente el campo de la identificación de especies arbóreas y la capacidad de obtener información detallada sobre la superficie terrestre sin la necesidad de contacto físico, lo cual también, ha permitido avances notables en la comprensión de los cambios medioambientales, la gestión de recursos naturales y la toma de decisiones basada en datos de teledetección.

3.3 Espectro electromagnético

De acuerdo con Martin (2013), el espectro electromagnético (Figura 1), se define como el “conjunto de radiaciones electromagnéticas de todas las longitudes de onda ordenadas por sus frecuencias y, por ende, de energía” (p. 2). Dentro de este espectro, se encuentran diversas longitudes de onda, como señalan Santos y Renovato (2019) destacando que la luz visible abarca desde los 400 hasta los 700 nanómetros (p. 42).

Existen ondas electromagnéticas que escapan a la percepción del ojo humano. Según lo señalado por Roman y Vargas (2013), una de las áreas más notables en este contexto es el espectro infrarrojo (IR), que se extiende en un intervalo de longitudes de onda aproximado de 700 a 1000 nanómetros (p.4).

En la naturaleza, las diferentes superficies terrestres, incluyendo bosques, suelos cultivados y cuerpos de agua, se distinguen por su capacidad para absorber y reflejar la energía electromagnética en varias longitudes de onda del espectro electromagnético (Alonso et al., 1999, p.1).

Las plantas destacan por su afinidad a las longitudes de onda del espectro visible, comprendidas entre 400 y 700 nanómetros, conocidas como Radiación Fotosintéticamente Activa (por sus siglas en inglés, PAR). Este rango es esencial para los procesos fotosintéticos, donde la clorofila, pigmento vital en las plantas, absorbe en las bandas azul y roja, dando lugar a un pico máximo de reflectancia alrededor de los 550 nm en el espectro electromagnético (Alonso et al., 1999, p.3; Valladares et al., 2004, p.3).




Figura 1. Espectro electromagnético.
Fuente: Horst, J. (2007).

3.4 Firma espectral

Una vez que la energía electromagnética llega a la superficie terrestre, interactúa con distintos materiales a través de procesos de reflexión, absorción o transmisión, cada uno exhibiendo un patrón de respuesta espectral específico (Hernández y Montaner, 2009, p. 3). En base a este patrón de respuesta, Daniel et al, (2015) destaca que cada componente exhibe un espectro de reflexión exclusivo, considerado su identificación distintiva, frecuentemente conocido como firma espectral (Figura 2) (p. 167).

En síntesis, la variabilidad en las respuestas espectrales de los materiales es clave para identificar y caracterizar componentes en el entorno terrestre.

Comprender estas firmas espectrales resulta esencial en aplicaciones como teledetección y ciencia de datos geospaciales, donde se utiliza la información única de los patrones espectrales para análisis y clasificación.




Figura 2. Curvas de reflectancia espectral de algunos tipos de vegetación. Fuente: Biblioteca espectral del USGS.

3.5 Imágenes Hiperespectrales

Las imágenes hiperespectrales están compuestas por cientos de bandas espectrales de información a través de todo el espectro electromagnético (Roman y Vargas, 2013, p. 3). La captura de este tipo de datos se lleva a cabo mediante un espectrómetro, siendo un dispositivo sensorial (sensor óptico), que posibilita el análisis de la radiación luminosa emanada por un objeto en particular.

La mayoría de los estudios que utilizan este tipo de imágenes, se llevan a cabo con sensores que operan en el rango visible e infrarrojo cercano (VNIR) (de aproximadamente 400 nm a 900 nm) (Dalponte et al., 2013, p. 3).

En el caso de la vegetación, las imágenes hiperespectrales pueden almacenar información importante sobre la reflexión de la luz sobre sus hojas, que pueden determinar áreas afectadas por enfermedades o estrés hídrico, y ofrecer información detallada sobre la cantidad de clorofila presente en las hojas. Los autores Perez y Muñoz (2006) sugieren que la caracterización de la vegetación y la medición de sus atributos pueden lograrse de dos maneras: mediante observaciones directas en el terreno o, de forma indirecta, utilizando análisis de imágenes remotas y fotografías aéreas hiperespectrales, que emplean técnicas basadas en la respuesta espectral de la vegetación (p. 191).

Algunos autores como Daniel et al. (2015) sostienen que las cubiertas vegetales exhiben la respuesta espectral de sus partes predominantes: las hojas. Estas hojas contienen células con clorofila y otros pigmentos que absorben luz, especialmente en el espectro visible. En el infrarrojo cercano (NIR), no absorben luz, sino que la reflejan más intensamente cuanto más superficies internas tenga la hoja, separando el tejido del aire exterior y su contenido (p 356).

3.6 Aplicación de técnicas y modelos de aprendizaje automático para la identificación de especies arbóreas

En la era digital actual, las técnicas avanzadas y los modelos de aprendizaje automático están desencadenando una revolución significativa en el campo de la teledetección. La tarea esencial de clasificar imágenes de teledetección para identificar diversos objetos o tipos de coberturas en el terreno real se vuelve imperativa. En este contexto, la aplicación de métodos de clasificación automática se torna crucial.

Específicamente, los modelos de aprendizaje automático y las técnicas de Machine Learning, emergen como herramientas indispensables para identificación remota. La clasificación de imágenes, definida por Calvario (2019) se expresa “como el proceso de categorizar todos los píxeles de una imagen o región de datos con el objetivo de obtener un conjunto de etiquetas o características de cobertura terrestre, constituye un componente integral de este proceso innovador” (p.73). Estos sistemas emergen como recursos indispensables en la identificación remota, demostrando su eficacia en la interpretación y categorización precisa de datos visuales a distancia.

Como señala Sandoval (2018), esta disciplina dentro de la Inteligencia Artificial se centra en el desarrollo de algoritmos capaces de aprender sin necesidad de

programación directa (p.2). Lo que impulsa significativamente la eficiencia y precisión en la interpretación de datos recopilados por sensores remotos. Estos enfoques no solo aceleran el proceso de clasificación, sino que también mejoran la capacidad para discernir patrones complejos en grandes conjuntos de datos, proporcionando así una comprensión más profunda de la realidad geoespacial.

En el contexto de la clasificación en teledetección, se suelen emplear dos reconocidos métodos, la clasificación supervisada y la no supervisada.

La clasificación supervisada implica que el usuario tenga conocimiento previo acerca de la categorización de una imagen. Conforme detalla la investigación de Calvario (2019) en este método, el usuario especifica un conjunto de datos particular para la región de interés y asigna cada elemento a sus respectivas clases correspondientes (p. 75). La precisión de este tipo de clasificación se encuentra estrechamente ligada a la calidad de la información o muestras recopiladas en el terreno. Esta metodología de clasificación consta de dos fases, la de entrenamiento y validación o prueba.

Durante la fase de entrenamiento, se lleva a cabo una cuidadosa selección de muestras para alimentar el algoritmo, con la recolección y ubicación de datos en el terreno para garantizar una comprensión auténtica de los elementos a clasificar. Calvario (2019) destaca que, durante la etapa de entrenamiento, el

algoritmo adquiere la capacidad de identificar patrones similares dentro de la imagen, lo cual sienta las bases sólidas para su aprendizaje (p. 75). Posteriormente, en la fase de validación, las muestras restantes son empleadas para evaluar la eficacia del algoritmo. Siguiendo la metodología de Trier et al. (2018), se busca confirmar que el modelo genera resultados precisos y coherentes (p. 18). Este proceso valida la capacidad del algoritmo para aplicar y generalizar el conocimiento adquirido durante la fase de entrenamiento.

Por otro lado, la clasificación no supervisada opera de manera autónoma, prescindiendo de la intervención del usuario para especificar la caracterización de los objetos. En este enfoque, la clasificación identifica automáticamente patrones de similitud entre objetos, agrupándolos de manera inherente. El usuario, no obstante, tiene la capacidad de definir el número de agrupamientos o clústeres según sus necesidades y objetivos específicos.

Dentro de los modelos de aprendizaje automático supervisado para clasificación de imágenes, destaca el algoritmo Random Forest (RF). Pal (2005) explica que este clasificador funciona seleccionando aleatoriamente un conjunto de características y construyendo un clasificador usando una muestra bootstrapped de los datos de entrenamiento. Esto genera múltiples árboles clasificadores y, en la etapa final, se asigna una clase a un píxel de clasificación desconocida mediante un método de voto no ponderado (p. 3). RF logra una alta precisión,

manejando eficientemente valores atípicos y ruido en los datos. Además, se destaca por su relativa simplicidad de implementación (Ahmad et al., 2018; Dalponte et al., 2013). Otro clasificador destacado corresponde al Support Vector Machine (SVM), el cual destaca por su excepcional capacidad de generalización a partir de los datos de entrenamiento, Incluso en situaciones donde los datos no son separables sin errores, la SVM emplea propiedades especiales en el espacio de características para lograr una separación eficaz (Cortes y Vapnik, 1995, p. 1). En un estudio de Dalponte et al. (2013) sobre la clasificación de especies en un bosque boreal, se empleó un sensor hiperespectral VNIR junto con un clasificador SVM, el cual proporciono las mayores precisiones globales y kappa en comparación con otros dos clasificadores.

IV. METODOLOGÍA

4.1 Descripción del área de estudio

El área de estudio corresponde a Laguna Grande del Santuario de la Naturaleza denominado “Laguna Grande - Humedal Los Batros” (Figura 3) ubicado en la Región del Biobío, provincia de Concepción, comuna de San Pedro de la Paz (36°50'51"S, 73°06'36"O). Este lugar posee una superficie aproximada de 312 hectáreas, que comprende una laguna cubierta por áreas adyacentes con bosques, humedales y edificaciones.

Según el Decreto 42 del año 2021 establecido bajo la Ley N°19.300 de Medio Ambiente, esta zona cumple diferentes funciones ecológicas, por una parte, se destaca su rol y valor como lugar de concentración para aves migratorias como *Numenius phaeopus* (Zarapito) y *Charadrius modestus* (Chorlo chileno), permite la reproducción de la población de *Cygnus melanocoryphus* (Cisne de cuello negro), y, también comprende diferentes redes ecológicas dentro del humedal, entre otros beneficios ecosistémicos.

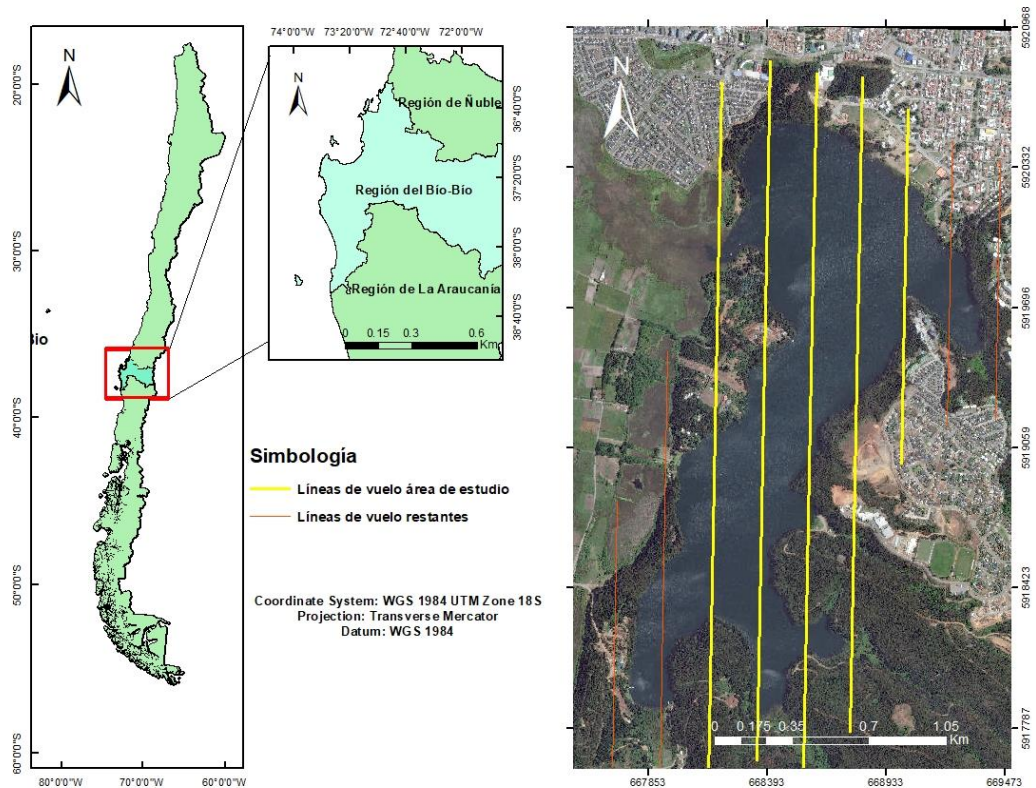


Figura 3. Localización y planificación de vuelo de la Laguna Grande de San Pedro de la Paz. Las líneas amarillas corresponden a las imágenes utilizadas en este estudio para hacer el mosaico con las escenas HySpex VNIR-1800.

La metodología de esta investigación seguirá un enfoque estructurado mediante la elaboración de un flujograma de trabajo (Figura 4). Este diseño guiará los procesos necesarios para llevar a cabo la clasificación de especies arbóreas en el área de estudio.

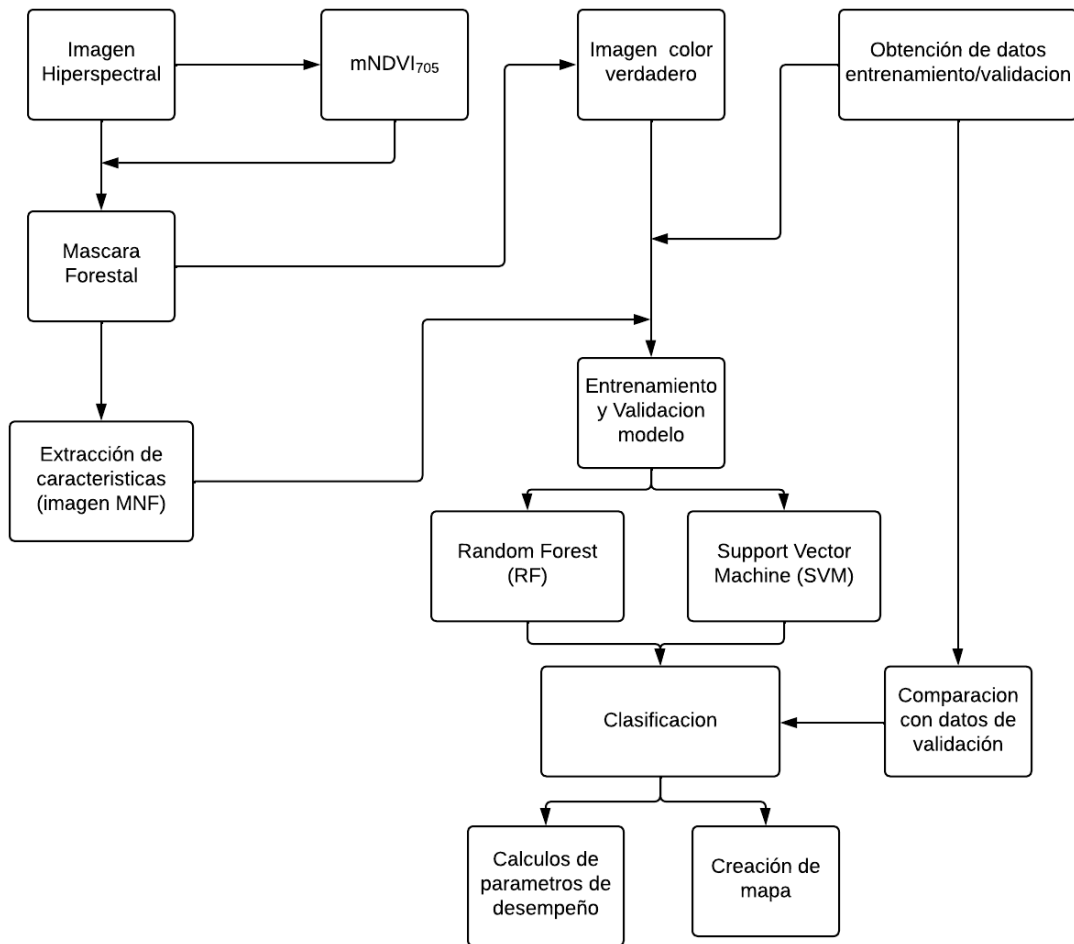


Figura 4. Flujograma de trabajo para la captura de datos, procesamiento de imágenes, clasificación y validación.

4.2 Muestreo de campo

Mediante un muestreo en terreno, se recopiló información detallada sobre la ubicación espacial de las especies arbóreas más destacadas en la zona norte que rodea la Laguna Grande de San Pedro de la Paz. Se registraron las coordenadas geográficas de longitud (X) y latitud (Y) con el objetivo principal de centrarse en los árboles. Este proceso se llevó a cabo aprovechando los senderos de acceso público, que no solo ofrecen una travesía segura, sino también la oportunidad de apreciar las diferentes especies presentes en el entorno.

La identificación de los árboles se llevó a cabo mediante la observación visual de sus características morfológicas, que incluyeron hojas, corteza y cuando aplicaba, flores y frutos, todo basado en el criterio de un experto. Posteriormente, se registró la ubicación precisa de cada especie utilizando un dispositivo GPS de alta precisión (Garmin GPSMAP® 66s) con un margen de error de la ubicación exacta de +/- 3,65 m.

Se recolectaron muestras adicionales de pasto y Retamilla (*Teline monspessulana* (L.) K.Koch.) debido a abundante presencia en el área de estudio. Esta recopilación complementaria fortalece el proceso de clasificación, ya que proporciona datos adicionales que ayudan a mejorar la precisión del modelo. De esta manera, se reduce la probabilidad de clasificar incorrectamente las especies arbóreas al contar con muestras representativas de otras coberturas vegetales importantes en el ecosistema.

4.3 Adquisición de imágenes hiperespectrales

Se capturaron cuatro imágenes hiperespectrales sobre el área de estudio el día 26 de febrero de 2023 utilizando el sensor hiperespectral aerotransportado HySPEX VNIR-1800 (Figura 5), entre las 17:00 y 18:00 horas (Hora de la laptop en Noruega).

La cámara HySpex VNIR-1800, fabricada por la empresa NEO en Noruega, se destaca por su capacidad para capturar imágenes con una amplia gama de bandas espectrales, que abarcan desde los 400 hasta los 1000 nanómetros, distribuidas en 186 bandas. El vuelo se realizó a una altura de 745 m sobre el nivel del suelo, adquiriendo imágenes con una resolución espacial de 1 metro, lo

que posibilita una discriminación y análisis más precisos de objetos y materiales en base a sus firmas espectrales distintivas.



Figura 5. Cámara hiperespectral HySpex VNIR-1800.

4.5 Procesamiento de imágenes hiperespectrales

4.5.1 Corrección geométrica

Las escenas capturadas desde el aire suelen experimentar diversas distorsiones. Schlöpfer y Richter (2002) menciona que estas distorsiones son causadas por parámetros auxiliares que incluyen la posición del sensor ($x/y/z$) y la actitud de la aeronave (balanceo ω , inclinación ϕ , rumbo o cabeceo k) (p. 7) (Figura 6).




Figura 6. Sistema de coordenadas del sensor rotado (x' , y' , z') en el espacio y la orientación de los ángulos de actitud (ω , ϕ , κ), El vector de barrido L_1 se obtiene por transformación del sistema de coordenadas.

Fuente: Schläpfer y Richter (2002).

La corrección geométrica de las imágenes hiperespectrales se llevará a cabo utilizando el software PARGE®. Este proceso se basará en el modelo DTM (Digital Terrain Model) SRTM, remuestreado a una resolución de 1 metro, del área de estudio, así como en los datos de navegación de las líneas de vuelo (GPS/IMU). Además, se determinará el sistema de proyección geográfica, que corresponde a WGS 84 / UTM zona 18 S. De este modo, se logrará georreferenciar y ortorrectificar con precisión las imágenes hiperespectrales, permitiendo su análisis en un contexto geoespacial. Es importante este proceso debido a las distorsiones ocasionadas por el movimiento del sensor durante la adquisición de los datos (Schläpfer y Richter, 2002) (p. 5).

4.5.2 Corrección atmosférica

Aplicar una corrección atmosférica, es fundamental en el procesamiento de imágenes hiperespectrales, la cual, busca mitigar los efectos de la atmósfera en las mediciones, permitiendo una interpretación más precisa de la reflectancia, que el caso de este estudio, proviene de la copa de los árboles. Daniel et al. (2015) menciona que este proceso se utiliza para evaluar la influencia de la atmósfera en la radiación emitida o reflejada por un objeto y corregirla (p. 223).

Para llevar a cabo las correcciones atmosféricas y topográficas de las líneas hiperespectrales, se utilizará el modelo ATCOR 4, esto permitirá reducir el efecto de las distorsiones atmosféricas que presentan las escenas al momento de su adquisición (Richter y Schlöpfer, 2019).

4.6 Creación de mosaico hiperespectral

Una vez que se han aplicado las correcciones geométricas y atmosféricas a las líneas hiperespectrales, es necesario abordar las distorsiones que se produjeron durante la captura. Para ello, se llevará a cabo una corrección geométrica automática antes de crear el mosaico final. En una primera etapa, se realizará un

registro automático de las líneas hiperespectrales utilizando la herramienta de Image Registration Workflow del software ENVI 5.6. Esta herramienta generará varios puntos de enlace georreferenciados entre dos imágenes: una imagen maestra y una imagen esclava que se desea coregistrarse, con el objetivo de alinearlas de manera más precisa.

Una vez que las cuatro imágenes están registradas, se facilita la construcción de un mosaico compuesto por ellas. Este proceso se realizó utilizando la herramienta Seameless Mosaic de ENVI 5.6., cuya función es acoplar las imágenes, seleccionando una imagen base y ajustando las demás en consecuencia. El resultado es un mosaico que combina las cuatro imágenes en una sola (Figura 7), lo que permite realizar la clasificación en toda el área de estudio de manera más eficiente.




Figura 7. (a) Ensamble de las cuatro líneas hiperespectrales; (b) Mosaico hiperespectral.

4.7 Mascara forestal

Clasificar especies arbóreas en áreas urbanas puede ser un proceso complicado debido a la presencia de infraestructuras urbanas. Para abordar este desafío, la investigación de Liu et al. (2017) sugiere excluir, antes de la clasificación, una máscara de áreas no arboladas derivada de las imágenes hiperespectrales (p.7). Esta estrategia ayuda a mejorar la precisión al enfocarse específicamente en las zonas arboladas y reducir la interferencia de elementos no relacionados con la vegetación.

Para generar la máscara forestal, se empleó el software ENVI 5.6. En una primera etapa, se calculó el índice de vegetación $mNDVI_{705}$ (1), propuesto por Sims y Gamon (2002). La fórmula correspondiente se expresó mediante la herramienta Band Math aplicada al mosaico normalizado.

$$mNDVI_{705} = \frac{(R_{750} - R_{705})}{(R_{750} + R_{705} - 2 * R_{445})} \quad (1)$$

Donde:

R_{750} corresponde a la banda 109 del sensor HySPEX VNIR-1800.

R_{705} corresponde a la banda 95 del sensor HySPEX VNIR-1800.

R_{445} corresponde a la banda 13 del sensor HySPEX VNIR-1800.

Del índice de vegetación se obtuvo una imagen de una sola banda, que contenía el valor del índice por cada píxel. Posteriormente se determinó el umbral de datos, excluyendo así todos los píxeles inferiores a 0,44, rango efectivo en la exclusión de cubierta no forestal propuesto por Modzelewska et al. (2020). Este paso se considera crucial para determinar el rango de datos que contiene información relevante para la extracción de cobertura arbórea (Figura 8).




Figura 8. Umbral de áreas no forestales (en rojo).

Una vez que se han identificado las zonas que no corresponden a áreas no forestales, se procede a la creación de una máscara utilizando la herramienta Build Raster Mask de ENVI 5.6. Esta herramienta tiene la capacidad de ocultar, o en este contexto, eliminar las áreas no forestales de las escenas

hiperespectrales y así obtener una clasificación más representativa de especies forestales.

4.8 Transformación MNF

Las imágenes hiperespectrales, compuestas por cientos de bandas espectrales, contienen una gran cantidad de información. Para manejar esta complejidad, se recurre a técnicas de reducción de dimensionalidad como la Transformación de la Fracción de Ruido Mínimo (MNF), que permiten conservar la información relevante mientras se reduce el ruido presente en las bandas espectrales. En esencia, la MNF emplea transformaciones de Análisis de Componentes Principales (PCA) en cascada para separar la señal útil del ruido (Modzelewska et al., 2020).

Para reducir el ruido presente en las bandas de la imagen hiperespectral, se llevará a cabo una transformación MNF utilizando el software ENVI 5.6. El propósito principal de esta transformación es separar el ruido y la señal importante, así como distribuirlo uniformemente a lo largo de las nuevas bandas, lo que simplifica la identificación de características espectrales relevantes y la mejora de la calidad de la imagen al reducir el ruido.

4.9 Generación de conjuntos de datos de entrenamiento y validación mediante la segmentación de las copas arbóreas

La segmentación manual de las copas de los árboles se llevó a cabo utilizando el software ENVI 5.6. Se delimitaron las copas de los árboles muestreados mediante Regiones de Interés (ROI), polígonos de copa en formato vectorial (shapefile). El objetivo principal fue definir con precisión las copas de los árboles, coincidiendo con los puntos de muestreo previamente georreferenciados. El resultado de este proceso es la generación de ROI, que posteriormente se utilizarán como datos de vectores de entrenamiento (verde) y validación (azul) en el proceso de clasificación supervisada de especies arbóreas.




Figura 9. Regiones de interés sobre copas de árboles para la fase de entrenamiento (verde) y validación (azul).

4.10 Creación de librería espectral de especies arbóreas

Una vez que delineados los polígonos correspondientes a las copas de los árboles, será posible extraer los espectros de reflectancia promedio de cada píxel que componen la muestra ROI. A través de la reflectancia promedio de estos espectros en la imagen hiperespectral, se podrán clasificar como firmas espectrales únicas las especies arbóreas, generando así una librería espectral para cada uno de los árboles presentes en el área de estudio, que posteriormente se utilizarán como vectores de entrenamiento y para la validación de la clasificación espectral. En resumen, el objetivo principal consiste en desarrollar una librería espectral que pueda aplicarse para clasificar e identificar diversas especies de árboles en futuras imágenes hiperespectrales, validando así los resultados del proceso de clasificación espectral.

4.11 Clasificación de especies arbóreas

La clasificación la imagen hiperespectral se llevará a cabo mediante una clasificación supervisada. La cual se trata de un procedimiento donde se emplean píxeles cuya identidad se conoce previamente y están situados dentro de las zonas de estudio designadas. Estos píxeles son utilizados como referencia para clasificar aquellos cuya identidad no se conoce (Linares y Tisnes, 2011).

Para la clasificación se utilizarán dos modelos de Machine Learning. El primero se denomina Random Forest (RF), el cual es un algoritmo de aprendizaje automático ampliamente utilizado, que combina la salida de múltiples árboles de decisión para obtener un único resultado. Su facilidad de uso y flexibilidad han impulsado su adopción, ya que es capaz de manejar tanto problemas de clasificación como de regresión (Breiman, 2001).

El segundo corresponde al Support Vector Machine (SVM), técnica de aprendizaje automático utilizado ampliamente en tareas de clasificación de imágenes (Ahmad et al., 2018). El SVM es un algoritmo que construye hiperplanos en el espacio de características para separar clases de datos. Su objetivo es encontrar el hiperplano óptimo que logre la máxima separación entre las clases. Cuando se trata de clasificar múltiples clases, el SVM utiliza la estrategia "uno contra todos" (o "one vs all"), donde se entrena un clasificador binario para cada clase frente a todas las demás clases. De esta manera, el modelo es capaz de determinar el hiperplano que mejor divide cada par de clases, asegurando una separación óptima y maximizando la distancia entre las clases en el espacio de características.

La clasificación se llevó a cabo utilizando el paquete de herramientas Orfeo ToolBox (OTB) dentro de QGIS 3.28. Los procesos para llevar a cabo la clasificación consistieron en una primera parte, definir dos grupos de muestras de entrenamiento y validación para alimentar los algoritmos de aprendizaje automático RF y SVM. Se seleccionaron un total de 124 muestras para desarrollar y validar el modelo de clasificación, divididas en 87 muestras para el entrenamiento y 37 muestras para la validación. Esta división representó el 70% para el conjunto de entrenamiento y el 30% para el conjunto de validación, respectivamente.

Primero se procedió a obtener las estadísticas de la imagen del área de estudio a clasificar (Compute Images Statistics). Esta herramienta calcula la media global y la desviación estándar de cada banda que compone la imagen hiperespectral, mejorando el proceso y resultado de la clasificación.

La fase de entrenamiento se llevó a cabo con la herramienta Train Image Classifier. Para entrenar el modelo, se debe proporcionar una imagen y una lista de polígonos o vectores para entrenar y validar el modelo. Estas deben contener un identificador (Class ID) entero positivo para separar las clases, que en este caso corresponden a diferentes especies arbóreas (Tabla 1). El resultado de esta fase se compone de un modelo entrenado y una matriz de confusión.

Tabla 1. Tabla de muestras por especie.

Class_ID	Especie	N° total de muestras
1	<i>Acacia melanoxylon</i>	20
2	<i>Cryptocarya alba</i>	10
3	<i>Cupressus macrocarpa</i>	5
4	<i>Eucalyptus globulus</i>	24
5	<i>Maytenus boaria</i>	3
6	<i>Nothofagus dombeyi</i>	2
7	<i>Nothofagus obliqua</i>	3
8	<i>Peumus boldus</i>	14
9	<i>Pinus radiata</i>	30
10	<i>Populus deltoides</i>	3
11	<i>Salix babylonica</i>	4
12	<i>Teline monspessulana</i>	2
13	Pasto	4

Después de entrenar el modelo del clasificador, procedimos a clasificar la imagen hiperespectral utilizando Image Classifier. Para realizar esta clasificación, se empleó la imagen a clasificar como entrada, junto con el modelo del clasificador previamente entrenado y las estadísticas de la imagen utilizadas durante el

proceso de entrenamiento del modelo. El resultado será la clasificación de los píxeles de la imagen de salida por el clasificador para las clases de interés.

4.12 Validación estadística de modelos de clasificación

Para evaluar la exactitud de la clasificación de los modelos entrenados, se empleará una matriz de confusión específica para cada modelo entrenado. Esta herramienta consiste en una tabla donde las columnas representan los datos de referencia y las filas corresponde a las asignaciones del clasificador.

La matriz de confusión simple se compone de Verdaderos Positivos (VP), Falsos Positivos (FP), Verdaderos Negativos (VN) y Falsos Negativos (FN) para cada clase. En específico se considera la matriz de confusión que entrega OTB (Tabla 2). La diagonal principal de esta matriz cuadrada expresa el número de puntos de verificación en donde se produce acuerdo entre las dos fuentes (mapa y realidad), mientras los marginales suponen errores de asignación (Linares y Tisnes, 2011).

Tabla 2. Estructura de una matriz de confusión simple proporcionada por Orfeo ToolBox.

		Etiquetas Producidas	
		Positivo	Negativo
Etiquetas de Referencia	Positivo	Verdaderos Positivos (VP)	Falsos Negativos (FN)
	Negativo	Falsos Positivos (FP)	Verdaderos negativos (VN)

A través de las matriz de confusión se calcularon algunos parámetros de desempeño:

Precisión (Precision): Proporción de verdaderos positivos (VP) sobre la suma de verdaderos positivos y falsos positivos (FP).

$$Precisión\ de\ la\ clase = \frac{VP}{VP + FP}$$

Sensibilidad (Recall): Proporción de verdaderos positivos (VP) sobre la suma de verdaderos positivos y falsos negativos (FN).

$$Recall\ de\ la\ clase = \frac{VP}{VP + FN}$$

Puntuación F (F-score): Media ponderada de precisión y recuerdo, donde la puntuación F alcanza su mejor valor en 1 y el peor en 0.

$$F - score = \frac{2 * Precision * Recall}{Precision + Recall}$$

Precisión global (Overall Accuracy):

$$\frac{VP + VN}{(VP + FP + VN + FN)}$$

Índice kappa (k): el índice Kappa es una medida de concordancia que mide la coincidencia entre las clasificaciones observadas y las esperadas por el azar, corrigiendo así la posibilidad de acuerdos aleatorios.

$$k = \frac{P_o - P_e}{1 - P_e}$$

Donde:

P_o es la proporción de acuerdo observado entre las clasificaciones

P_e es la proporción de acuerdo esperado al azar

Landis y Koch (1977) fueron los primeros en proponer la escala de valoración del índice k (Tabla 3), la cual ha sido adoptada extensamente desde su publicación inicial.

Tabla 3. Valorización de Índice Kappa.

Kappa (κ)	Grado de acuerdo
< 0,00	Sin acuerdo
0,21-0,40	Mediano
0,41-0,60	Moderado
0,61-0,80	Sustancial
0,81-1,00	Casi perfecto

V. RESULTADOS

5.1 Inventario en terreno

En terreno se recopiló un total de 124 muestras, de las cuales 118 corresponden a árboles, dos de un arbusto introducido y cuatro en zonas donde predominaba pasto (Figura 10). En cuanto a las especies arbóreas se lograron identificar 11 especies diferentes que abundaban dentro del área de estudio.

Los árboles identificados presentaron una variedad de especies exóticas, entre las cuales se encuentran árboles como Acacia negra (*Acacia melanoxylon* R.Br.), Ciprés de monterrey (*Cupressus macrocarpa* Hartw. ex Gord.), Eucalipto (*Eucalyptus globulus* Labill.), Pinus insigne (*Pinus radiata* D.Don.), Álamo negro de Norteamérica (*Populus deltoides* W. Bartram ex Marshall), Sauce llorón (*Salix babylonica* L.) y un arbusto leñoso denominado Retamilla (*Teline monspessulana* (L.) K.Koch.).

En cuanto a especies arbóreas nativas, se lograron identificar especies características de la zona, tales como el Peumo (*Cryptocarya alba* (Molina) Looser), Boldo (*Peumus boldus* Molina), Maitén (*Maytenus boaria* Molina) y árboles de Coihue (*Nothofagus dombeyi* (Mirb.) Oerst.) y Roble (*Nothofagus*

obliqua (Mirb.) Oerst.), sin embargo, estas dos últimas especies estaban forestadas con fines estéticos. Es importante destacar que, a pesar de que el coihue y el roble son árboles plantados en la zona del parque, se incluyeron en el estudio con el objetivo de explorar la capacidad de los modelos Machine Learning para su correcta clasificación en imágenes hiperespectrales. Esta decisión amplía el alcance del análisis y permite evaluar la capacidad las imágenes hiperespectrales para discriminar entre especies del género *Nothofagus*, incluso en entornos modificados.

Las especies muestreadas fueron registradas en una tabla (Tabla A.1) que proporciona información sobre el número de árbol, nombre científico de cada especie arbórea y sus coordenadas, característica relevante recopilada durante el proceso de muestreo en terreno. Esta presentación tabular se utilizó como un recurso valioso para la evaluación de la diversidad y distribución de las especies arbóreas en el área de estudio (Figura 10) y su posterior clasificación, contribuyendo significativamente a la comprensión integral de la ecología forestal abordada en esta investigación.

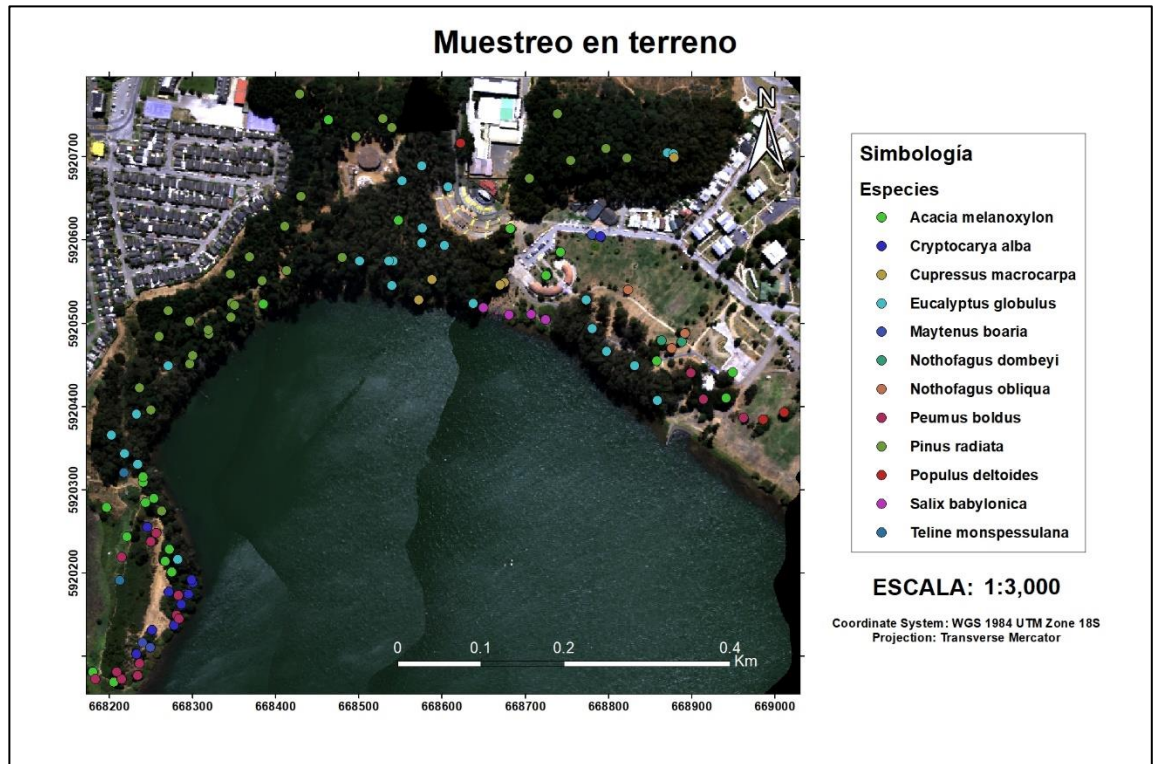


Figura 10. Muestreo de especies arbóreas.

El análisis de las muestras de especies revela una clara prevalencia de especies exóticas en comparación con las nativas, siendo notable la presencia abundante y edad de los árboles de *E. globulus*, *P. radiata* y *A. melanoxylon*. Estas especies se caracterizan, a nivel visual, por ejercer una dominancia significativa del dosel del bosque (Figura 11). Esta situación se fundamenta en la observación de eventos pasados, específicamente alrededor del año 1850, cuando se establecieron diversos géneros de árboles con fines forestales en la cuenca, tales como *Acacia*, *Cupressus*, *Eucalyptus* y *Pinus*. Es crucial destacar que, de todos

ellos, *Pinus radiata* es la especie que proporciona la información histórica más detallada (Vargas et al., 2017, p. 16). Por lo tanto, estos árboles se han vuelto dominantes debido al extenso tiempo que han tenido para crecer y establecerse en el área, superando en número y tamaño a otras especies arbóreas.



Figura 11. Árboles dominantes de *Pinus radiata* en el área de estudio.

En el caso de los árboles nativos, una de las especies más representativa del muestreo correspondió al boldo y el peumo la cual se encontraba como especie dominante, incluso en zonas con constante exposición al sol (Figura 12). El peumo según menciona Rodríguez et al., (1983) se desarrolla principalmente en

quebradas y valles sombríos, pero ocasionalmente se encuentra en áreas soleadas con humedad (p. 107).




Figura 12. (a) Boldo (*Peumus boldus*) y (b) Peumo (*Cryptocaria alba*).

5.2 Resultados del mosaico hiperespectral

La imagen hiperespectral en color verdadero (R: banda76, G: banda 54, B: banda 19) del mosaico hiperespectral, entrego buenos resultados, donde proporciono una imagen de buena calidad y resolución. Al aplicar la máscara de áreas no forestadas, se logró eliminar todo elemento que pudiera afectar la clasificación de árboles. Por otro lado, la imagen MNF, permite observar las características

distintivas y que sea más evidente la diferencia espectral en los árboles (Figura 13).

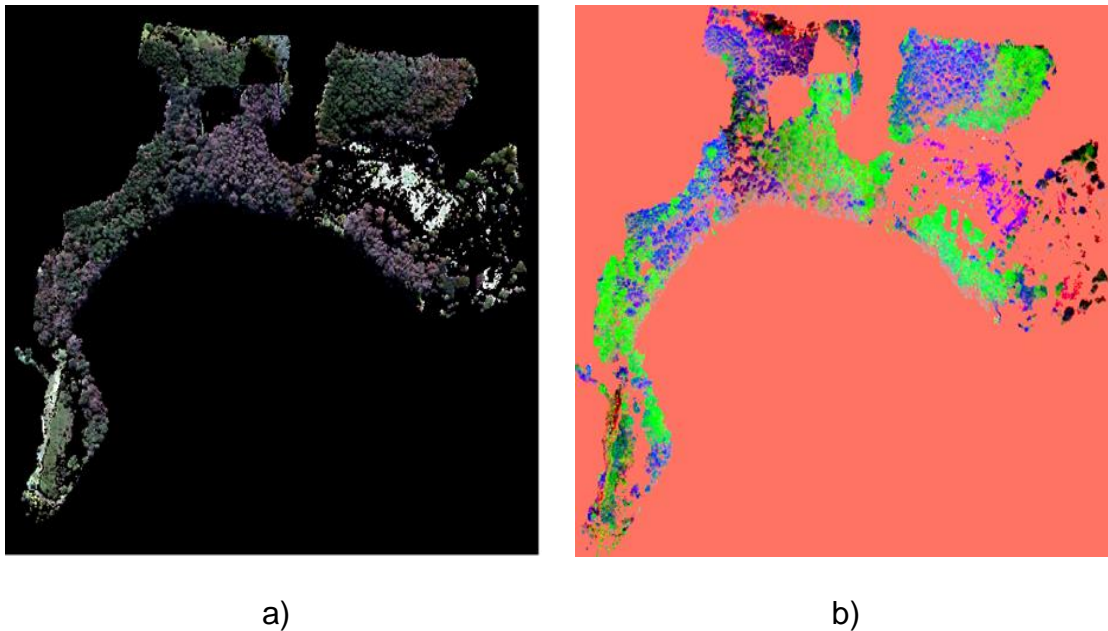


Figura 13. La primera imagen (a) representa una imagen del área de estudio en color verdadero. La segunda (b) una imagen en MNF.

5.3 Firmas espectrales por especie

Las muestras dispuestas sobre el mosaico hiperespectral permitieron la obtención de diversas firmas espectrales promedio por especie (Figura 14). Estas firmas exhiben niveles significativos de separabilidad, lo que resalta la capacidad inherente de las imágenes hiperespectrales para distinguir entre especies arbóreas, basándose en la reflectancia capturada de las copas de los árboles.

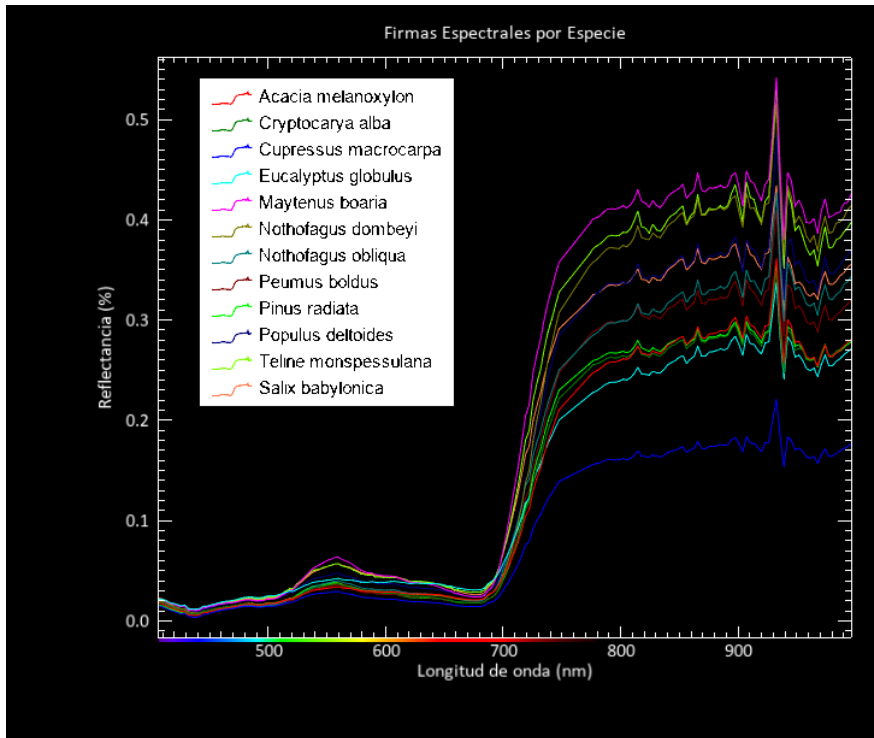


Figura 14. Firmas espectrales por especie.

La alta resolución espectral de las imágenes hiperespectrales facilita la identificación precisa de patrones de reflectancia característicos de cada especie arbórea. Al analizar estas firmas espectrales, la mayoría de las especies muestran una baja reflectancia en las bandas azul (450 nm) y roja (680 nm), lo que es típico debido a la absorción por la clorofila. Por otro lado, se pueden observar diferencias distintivas en las longitudes de onda del infrarrojo cercano (700-900 nm). Estas diferencias permiten distinguir entre especies y generar una clasificación más exacta y detallada de especies arbóreas.

5.4 Clasificación SVM y RF en imagen RGB

Los resultados obtenidos a partir de la clasificación de la imagen en color verdadero utilizando el modelo Support Vector Machine (SVM), logró una precisión global (Overall Accuracy) del 90% de predicción para todas las clases y un índice Kappa de 0,89. A través de la matriz de confusión (Figura 15), se calcularon los parámetros de desempeño (Tabla 4) para cada clase en particular.

Tabla 4. Parámetros de desempeño para la clasificación SVM en imagen RGB.

Clase	Especie	Precision	Recall	F-Score
1	<i>A. melanoxylon</i>	1,00	0,33	0,50
2	<i>C. alba</i>	0,60	0,33	0,43
3	<i>C. macrocarpa</i>	0,44	0,89	0,59
4	<i>E. globulus</i>	0,50	1,00	0,67
5	<i>M. boaria</i>	0,80	0,89	0,84
6	<i>N. dombeyi</i>	0,90	1,00	0,95
7	<i>N. obliqua</i>	1,00	0,67	0,80
8	<i>P. boldus</i>	0,63	0,56	0,59
9	<i>P. radiata</i>	0,80	0,44	0,57
10	<i>P. deltoides</i>	0,90	1,00	0,95
11	<i>S. babylonica</i>	1,00	0,89	0,94
12	<i>T. monspessulana</i>	1,00	0,78	0,88
13	Pasto	1,00	1,00	1,00

	A. melanoxylyon	C. alba	C. macrocarpa	E. globulus	M. boaria	N. dombeyi	N. obliqua	P. boldus	P. radiata	P. deltooides	S. babylonica	T. monspessulana	Pasto
A. melanoxylyon	8	1	0	0	0	0	0	0	0	0	0	0	0
C. alba	2	6	0	0	0	0	0	1	0	0	0	0	0
C. macrocarpa	0	0	6	0	0	0	0	0	3	0	0	0	0
E. globulus	0	0	0	9	0	0	0	0	0	0	0	0	0
M. boaria	0	0	0	0	9	0	0	0	0	0	0	0	0
N. dombeyi	0	0	0	0	0	9	0	0	0	0	0	0	0
N. obliqua	0	0	0	0	0	0	9	0	0	0	0	0	0
P. boldus	0	2	0	0	0	0	0	7	0	0	0	0	0
P. radiata	0	0	1	0	0	0	0	0	7	1	0	0	0
P. deltooides	0	0	0	0	0	0	0	0	0	9	0	0	0
S. babylonica	0	1	0	0	0	0	0	0	0	0	8	0	0
T. monspessulana	0	0	0	0	0	0	0	0	0	0	0	9	0
Pasto	0	0	0	0	0	0	0	0	0	0	0	0	9

Figura 15. Matriz de confusión de la clasificación SVM en imagen RGB.

Al observar la matriz de confusión, se puede concluir que la mayoría de las especies presenta una alta precisión de clasificación, con la mayoría de las muestras correctamente identificadas en la diagonal principal. Especies como *E. globulus*, *N. dombeyi*, *P. deltooides*, *T. monspessulana* y pasto tienen todas sus muestras correctamente clasificadas, demostrando una alta precisión en su clasificación. Sin embargo, también existen algunas confusiones, como dos muestras de *A. melanoxylyon* clasificadas erróneamente como *C. alba* y una muestra de *P. boldus* como pasto. Asimismo, *C. macrocarpa* tiene una muestra clasificada incorrectamente como *P. radiata*.

La imagen RGB clasificada con SVM muestra resultados muy satisfactorios (Figura 16), donde los diferentes colores representan los píxeles que componen la cubierta forestal del área de estudio. Se aprecia una gran precisión con la verdad en terreno, clasificando correctamente árboles pertenecientes a la especie que fueron identificadas en terreno. Sin embargo, algunos píxeles no se clasificaron correctamente, como es el caso de *C. macrocarpa* y *A. melanoxylon* que sobreestimaron la clasificación en zonas donde esta especie no se ubicaba.

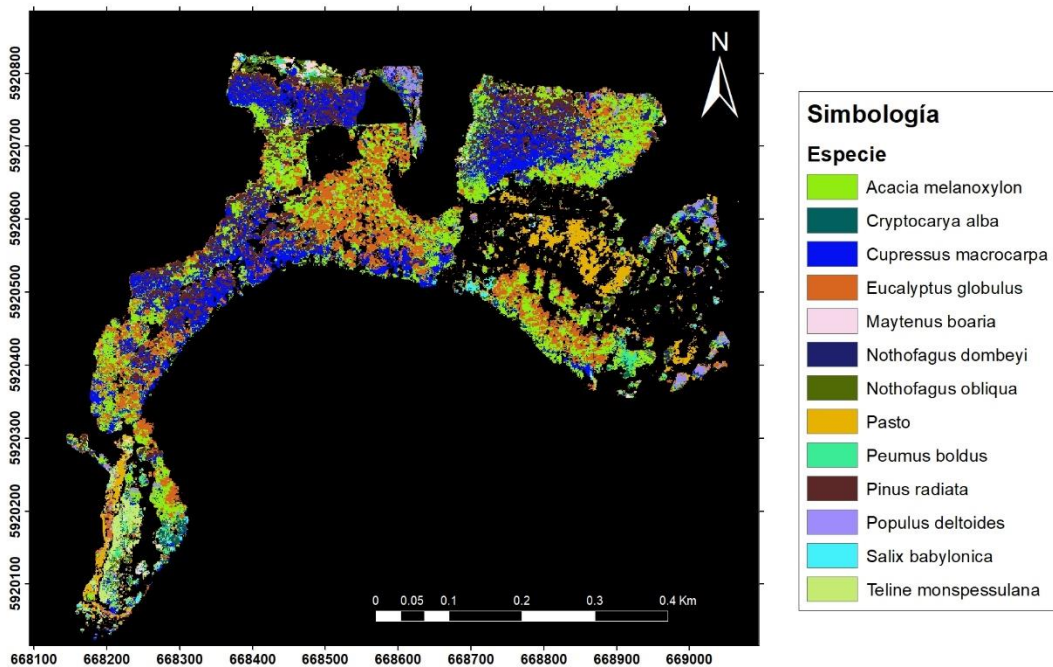


Figura 16. Clasificación SVM en imagen RGB.

La distribución de especies clasificadas (Figura 17) demuestra una gran diferencia de cobertura en m² de especies exóticas sobre las nativas. Especies como *A. melanoxylon*, *C. macrocarpa*, *E. globulus* y *P. radiata* dominan significativamente en cobertura forestal. Este fenómeno se puede derivar de la extensiva explotación forestal. En cuanto a las especies nativas estas representan una menor superficie de cobertura concentrándose en la zona sur del área de estudio.




Figura 17. Distribución de cobertura de especies a partir de la clasificación SVM en Imágenes RGB.

Los resultados de la clasificación de la imagen en color verdadero utilizando el modelo Random Forest, logró una precisión global (Overall Accuracy) del 43% y un índice Kappa de 0,33. Esto quiere decir que la clasificación no fue tan precisa. Se calcularon los parámetros de desempeño (Tabla 5) para cada clase en particular mediante el análisis de la matriz de confusión (Figura 18).

Tabla 5. Parámetros de desempeño para la clasificación RF en imagen RGB.

Clase	Especie	Precision	Recall	F-Score
1	<i>A. melanoxylon</i>	0,10	0,11	0,11
2	<i>C. alba</i>	0,19	0,33	0,24
3	<i>C. macrocarpa</i>	0,47	0,78	0,58
4	<i>E. globulus</i>	0,55	0,67	0,60
5	<i>M. boaria</i>	0,63	0,56	0,59
6	<i>N. dombeyi</i>	0,60	0,67	0,63
7	<i>N. obliqua</i>	0,25	0,11	0,15
8	<i>P. boldus</i>	0,33	0,11	0,17
9	<i>P. radiata</i>	0,30	0,33	0,32
10	<i>P. deltoides</i>	0,36	0,44	0,40
11	<i>S. babylonica</i>	0,33	0,11	0,17
12	<i>T. monspessulana</i>	0,43	0,33	0,38
13	Pasto	1,00	1,00	1,00

	<i>A. melanoxylo</i>	<i>C. alba</i>	<i>C. macrocarpa</i>	<i>E. globulus</i>	<i>M. boaria</i>	<i>N. dombeyi</i>	<i>N. obliqua</i>	<i>P. boldus</i>	<i>P. radiata</i>	<i>P. deltoides</i>	<i>S. babylonica</i>	<i>T. monspessulana</i>	Pasto
<i>A. melanoxylo</i>	1	2	2	1	0	0	1	0	1	1	0	0	0
<i>C. alba</i>	1	3	3	1	0	0	0	0	0	1	0	0	0
<i>C. macrocarpa</i>	0	0	7	0	0	0	0	0	2	0	0	0	0
<i>E. globulus</i>	1	0	0	6	0	0	0	0	2	0	0	0	0
<i>M. boaria</i>	0	1	0	0	5	0	1	0	0	0	1	1	0
<i>N. dombeyi</i>	0	1	0	0	1	6	0	1	0	0	0	0	0
<i>N. obliqua</i>	3	2	0	0	0	1	1	0	1	0	0	1	0
<i>P. boldus</i>	1	3	1	0	0	2	0	1	0	0	0	1	0
<i>P. radiata</i>	1	2	2	0	0	0	0	0	3	1	0	0	0
<i>P. deltoides</i>	0	1	0	0	0	1	0	1	1	4	0	1	0
<i>S. babylonica</i>	1	1	0	2	1	0	0	0	0	3	1	0	0
<i>T. monspessular</i>	1	0	0	1	1	0	1	0	0	1	1	3	0
Pasto	0	0	0	0	0	0	0	0	0	0	0	0	9

Figura 18. Matriz de confusión de la clasificación RF en imagen RGB.

Como se puede observar en la matriz de confusión, la mayoría de las clases fueron clasificadas erróneamente. Las especies *A. melanoxylo*, *N. dombeyi*, *P. boldus* y *S. babylonica* presentan problemas de clasificación, donde solo fueron correctamente clasificadas en una oportunidad en su propia clase. En contraste con lo anterior, *C. macrocarpa* y el pasto son las clases mejor clasificadas, con siete y nueve instancias correctamente identificadas, respectivamente.




Figura 19. Clasificación RF en imagen RGB.

El mapa de la clasificación de la imagen RGB con el modelo RF, representa una gran presencia de la especie *C. macrocarpa* distribuida en varias zonas del área de estudio, sin embargo, a pesar de la buena precisión de clasificación de las muestras proporcionadas, esta distribución no refleja con exactitud la realidad de que se presenta en el área de estudio. Es importante destacar que zonas cubiertas por sombras, fueron clasificadas como *C. macrocarpa*, esto se debe, en parte, a que *C. macrocarpa* tiende a confundirse con las sombras durante la clasificación, probablemente debido a la baja reflectividad de su firma espectral. En el caso de la especie *E. globulus*, se ubica en zonas donde si se encontraba distribuida espacialmente.

La cobertura de especies bajo la clasificación RF, proporciona una mayor abundancia de especies exóticas, como la especie *C. macrocarpa*, que es la más dominante, pero como se mencionó anteriormente, esta especie puede confundirse con sombras debido a la baja reflectividad de sus hojas, lo que puede haber influido en la sobreestimación de su cobertura.

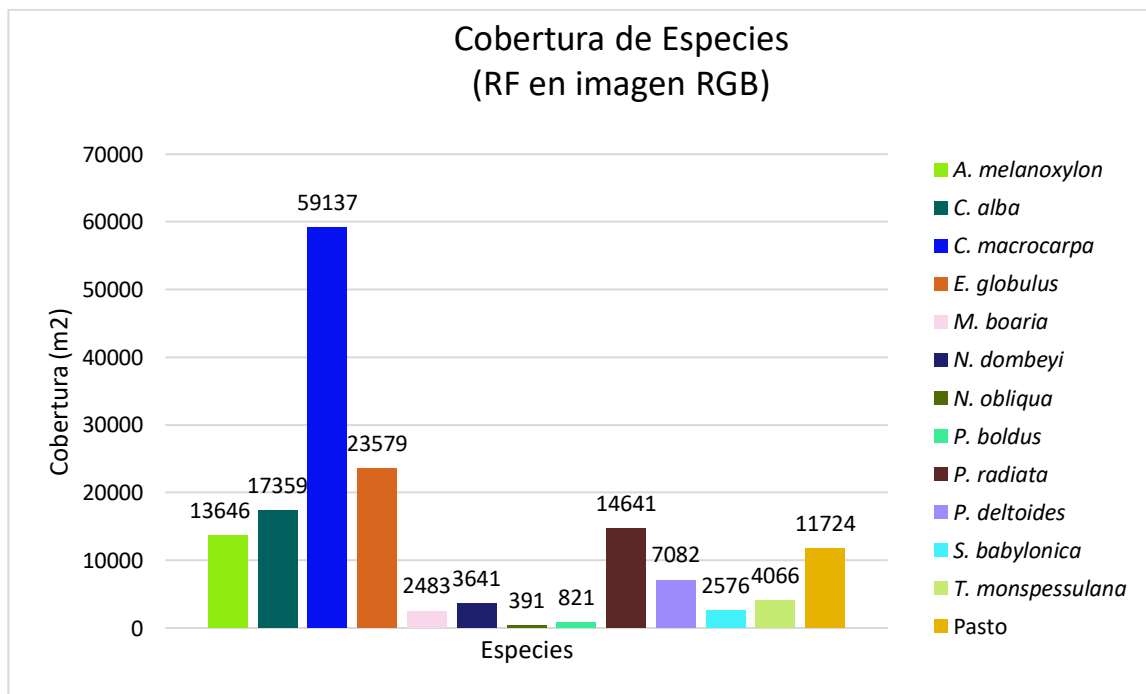


Figura 20. Distribución de cobertura de especies a partir de la clasificación RF en Imágenes RGB.

5.5 Clasificación RF y SVM en imagen MNF

Con respecto a la clasificación utilizando el modelo Random Forest sobre la imagen MNF, se logró una precisión global (Overall Accuracy) del 75% y un índice Kappa de 0,73. Se calcularon los parámetros de desempeño (Tabla 6) para cada clase en particular mediante el análisis de la matriz de confusión (Figura 21).

Tabla 6. Parámetros de desempeño para la clasificación RF en imagen MNF.

Clase	Especie	Precision	Recall	F-Score
1	<i>A. melanoxylon</i>	1,00	0,33	0,50
2	<i>C. alba</i>	0,60	0,33	0,43
3	<i>C. macrocarpa</i>	0,44	0,89	0,59
4	<i>E. globulus</i>	0,50	1,00	0,67
5	<i>M. boaria</i>	0,80	0,89	0,84
6	<i>N. dombeyi</i>	0,90	1,00	0,95
7	<i>N. obliqua</i>	1,00	0,67	0,80
8	<i>P. boldus</i>	0,63	0,56	0,59
9	<i>P. radiata</i>	0,80	0,44	0,57
10	<i>P. deltoides</i>	0,90	1,00	0,95
11	<i>S. babylonica</i>	1,00	0,89	0,94
12	<i>T. monspessulana</i>	1,00	0,78	0,88
13	Pasto	1,00	1,00	1,00

	A. melanoxylon	C. alba	C. macrocarpa	E. globulus	M. boaria	N. dombeyi	N. obliqua	P. boldus	P. radiata	P. deltoides	S. babylonica	T. monspessulana	Pasto
A. melanoxylon	3	0	2	4	0	0	0	0	0	0	0	0	0
C. alba	0	3	2	0	1	1	0	2	0	0	0	0	0
C. macrocarpa	0	0	8	0	0	0	0	0	1	0	0	0	0
E. globulus	0	0	0	9	0	0	0	0	0	0	0	0	0
M. boaria	0	0	1	0	8	0	0	0	0	0	0	0	0
N. dombeyi	0	0	0	0	0	9	0	0	0	0	0	0	0
N. obliqua	0	0	0	3	0	0	6	0	0	0	0	0	0
P. boldus	0	1	1	1	1	0	0	5	0	0	0	0	0
P. radiata	0	0	3	1	0	0	0	0	4	1	0	0	0
P. deltoides	0	0	0	0	0	0	0	0	0	9	0	0	0
S. babylonica	0	1	0	0	0	0	0	0	0	0	8	0	0
T. monspessulana	0	0	1	0	0	0	0	1	0	0	0	7	0
Pasto	0	0	0	0	0	0	0	0	0	0	0	0	9

Figura 21. Matriz de confusión de la clasificación RF en imagen MNF.

Los resultados de la matriz de confusión para la clasificación bajo en modelo RF, proporciono buenos resultados. Se puede observar en la diagonal principal, que la mayoría de las clases obtuvo buenos aciertos, donde se destaca *E. globulus*, *N. dombeyi*, *P. deltoides* y el pasto, poseen la totalidad de aciertos. En contraparte, errores de clasificación, ocurre en especies como *A. melanoxylon* y *C. alba*, la cuales solo obtuvo tres aciertos y *P. radiata* cuatro aciertos en su clasificación.




Figura 22. Clasificación RF en imagen MNF

La imagen clasificada mediante el modelo RF mostró una buena correspondencia con la realidad en terreno para la especie *E. globulus*, representando con precisión las zonas donde esta especie se encontraba. Asimismo, la especie nativa *P. boldus* fue representada adecuadamente en las áreas donde se encontraba aislada. Sin embargo, en zonas con mayor biodiversidad de especies, la clasificación presentó algunos errores. También se observaron errores en la clasificación de *C. macrocarpa*, que fue sobreestimada, indicando una abundancia en la imagen clasificada que no coincidía con las observaciones en terreno.

En el gráfico de niveles de cobertura arbórea (Figura 23), las especies *C. macrocarpa* y *E. globulus* dominan significativamente sobre las demás especies clasificadas. Sin embargo, *C. macrocarpa* presenta una notable sobreestimación de cobertura, principalmente debido a errores de clasificación en los que se confunde con sombras o áreas más oscuras del follaje, donde incluso, dominaba la presencia de *P. radiata*.

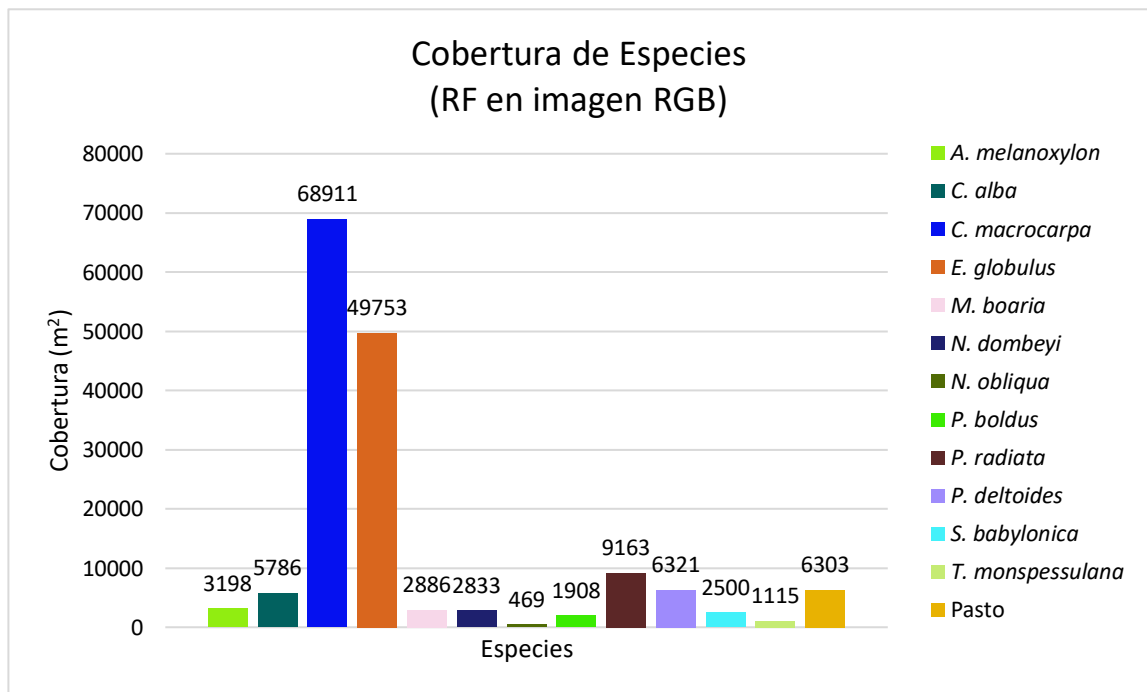


Figura 23. Distribución de cobertura de especies a partir de la clasificación RF en imagen MNF.

En cuanto a la clasificación con el modelo Support Vector Machine (SVM), se obtuvo una precisión global (Overall Accuracy) del 74% y un índice Kappa de 0,72. Los parámetros de desempeño para cada clase específica (Tabla 7) se calcularon mediante el análisis de la matriz de confusión (Figura 24).

Tabla 7. Parámetros de desempeño para la clasificación SVM en imagen MNF.

Clase	Especie	Precisión	Recall	F-Score
1	<i>A. melanoxylon</i>	0,44	0,44	0,44
2	<i>C. alba</i>	0,40	0,44	0,42
3	<i>C. macrocarpa</i>	0,75	0,67	0,71
4	<i>E. globulus</i>	0,71	0,56	0,63
5	<i>M. boaria</i>	1,00	1,00	1,00
6	<i>N. dombeyi</i>	0,90	1,00	0,95
7	<i>N. obliqua</i>	0,82	1,00	0,90
8	<i>P. boldus</i>	0,67	0,67	0,67
9	<i>P. radiata</i>	0,54	0,78	0,64
10	<i>P. deltoides</i>	0,71	0,56	0,63
11	<i>S. babylonica</i>	0,89	0,89	0,89
12	<i>T. monspessulana</i>	1,00	1,00	1,00
13	Pasto	1,00	0,67	0,80

En cuanto a la matriz de confusión, el modelo SVM proporcionó buenos resultados de clasificación en gran parte de las clases. Esto se evidencia en las especies *M. boaria*, *N. dombeyi*, *N. obliqua*, *S. babylonica* y *T. monspessulana*, las cuales se clasificaron correctamente en nueve ocasiones. Sin embargo, las demás clases presentaron algunos errores de clasificación, como el caso de *A. melanoxyton*, que fue clasificado incorrectamente como *E. globulus* en tres oportunidades.

	<i>A. melanoxyton</i>	<i>C. alba</i>	<i>C. macrocarpa</i>	<i>E. globulus</i>	<i>M. boaria</i>	<i>N. dombeyi</i>	<i>N. obliqua</i>	<i>P. boldus</i>	<i>P. radiata</i>	<i>P. deltoides</i>	<i>S. babylonica</i>	<i>T. monspessulana</i>	Pasto
<i>A. melanoxyton</i>	4	2	0	0	0	0	1	1	0	0	1	0	0
<i>C. alba</i>	0	4	0	0	0	0	1	2	1	1	0	0	0
<i>C. macrocarpa</i>	1	0	6	1	0	0	0	0	1	0	0	0	0
<i>E. globulus</i>	3	0	1	5	0	0	0	0	0	0	0	0	0
<i>M. boaria</i>	0	0	0	0	9	0	0	0	0	0	0	0	0
<i>N. dombeyi</i>	0	0	0	0	0	9	0	0	0	0	0	0	0
<i>N. obliqua</i>	0	0	0	0	0	0	9	0	0	0	0	0	0
<i>P. boldus</i>	0	1	0	1	0	0	0	6	1	0	0	0	0
<i>P. radiata</i>	0	1	0	0	0	0	0	0	7	1	0	0	0
<i>P. deltoides</i>	1	0	0	0	0	1	0	0	2	5	0	0	0
<i>S. babylonica</i>	0	1	0	0	0	0	0	0	0	0	8	0	0
<i>T. monspessulana</i>	0	0	0	0	0	0	0	0	0	0	0	9	0
Pasto	0	1	1	0	0	0	0	0	1	0	0	0	6

Figura 24. Matriz de confusión de la clasificación SVM en imagen MNF.

Los resultados obtenidos de la imagen MNF clasificada con SVM, entrego resultados visuales altamente precisos, logrando identificar de manera acertada la presencia de especies representadas en el mapa, concordando con la realidad observada en el terreno.




Figura 25. Clasificación SVM en imagen MNF.

El gráfico de cobertura de especies, generado mediante SVM en una imagen MNF, muestra que *E. globulus* y *C. macrocarpa* dominan significativamente con coberturas de 34.211 m² y 32.296 m², respectivamente. *A. melanoxylon* también presenta una alta cobertura. Sin embargo, especies como *C. alba*, *N. obliqua*, *N. dombeyi* y *S. babylonica* muestran coberturas relativamente bajas, un resultado esperado debido a que en terreno estas especies representaban una baja cobertura.




Figura 26. Distribución de cobertura de especies a partir de la clasificación RF en imagen MNF.

VI. DISCUSIÓN

La investigación demuestra que las imágenes hiperespectrales poseen un gran potencial para identificar especies arbóreas alrededor del Santuario de la Naturaleza Laguna Grande – Humedal Los batros. Las imágenes hiperespectrales son capaces de capturar firmas espectrales, que permiten distinguir entre especies arbóreas con alta precisión. La capacidad de estas imágenes para proporcionar datos espectrales a alta resolución facilita la identificación de patrones de reflectancia específicos de cada especie, lo que se ha demostrado en la diferenciación de especies en el área de estudio.

Es importante destacar el proceso de identificación y georreferenciación en-situ, cruciales para entrenar y validar los modelos de clasificación espectral. Las muestras recopiladas en terreno proporcionaron una base de datos sólida y precisa que permitió evaluar la exactitud de las clasificaciones espectrales realizadas. Una acción importante para considerar en futuros estudios es seleccionar arboles de copas grandes o también arboles aislados. Estas medidas permitirán mejorar el proceso de elaboración de las regiones de interés (ROI) para las futuras muestras de entrenamiento y validación.

La clasificación de especies utilizando métodos Machine Learning, como Support Vector Machine (SVM) y Random Forest (RF), mostró resultados variados. El modelo SVM aplicado inicialmente a la imagen en color verdadero logró una precisión global del 90% y un índice Kappa de 0,89, lo que indica una alta exactitud en la identificación de especies arbóreas. Sin embargo, el modelo RF, tuvo una menor precisión global del 43% con un índice Kappa de 0,33, lo que sugiere dificultades en la clasificación.

Al utilizar la imagen MNF, el desempeño del modelo RF mejoró significativamente, alcanzando una precisión global del 75% y un índice Kappa de 0,73. Esto resalta la importancia de seleccionar adecuadamente el tipo de procesamiento en la imagen hiperespectral y el método de clasificación para obtener resultados óptimos. Las imágenes MNF proporcionaron características espectrales más claras y eliminación de ruido (González et al., 2010), mejorando la capacidad de los modelos para distinguir entre especies.

Se observaron algunos errores en la clasificación, especialmente con especies como *A. melanoxylon* y *C. macrocarpa*, siendo esta última confundida con sombras debido a la baja reflectividad de sus hojas. Estos errores resaltan la necesidad de mejorar las técnicas de preprocesamiento y un mejor ajuste de los algoritmos de clasificación para manejar mejor las condiciones de iluminación

variables y otras complejidades del entorno. Para mejorar los resultados de clasificación espectral en futuras aplicaciones, se podría implementar una máscara de sombra, de esta manera se podría eliminar gran parte de las sombras que se puedan presentar en la imagen.

Las imágenes clasificadas, revelaron una dominancia de especies forestales exóticas como *E. globulus*, *P. radiata*, *A. melanoxylon* y *C. macrocarpa*. Esta dominancia puede estar vinculada a la historia de plantación con fines forestales y su capacidad de competir con especies nativas (Vargas et al., 2017). La distribución georreferenciada muestra que, aunque las especies nativas tienen una menor cobertura, su presencia es significativa en ciertas áreas específicas del Santuario.

En conclusión, la recopilación de datos in-situ combinada con técnicas de clasificación de imágenes hiperespectrales constituye una herramienta poderosa para la identificación y análisis de la distribución espacial de especies arbóreas. La aplicación de imágenes MNF, que reduce el ruido de las imágenes hiperespectrales, ha demostrado su capacidad para proporcionar resultados más estables al utilizar modelos RF y SVM. Esto no solo facilita la gestión forestal y la conservación, sino que también ofrece valiosa información para futuros estudios en silvicultura y biodiversidad.

VII. CONCLUSIONES

Al reconocer la importancia de la identificación de especies arbóreas en el ámbito forestal, surge la necesidad de implementar tecnologías vanguardistas que ofrezcan resultados rápidos y representativos, reflejando la realidad in-situ. Por ello, se aplicaron técnicas de espectrometría de imágenes hiperespectrales para identificar y clasificar especies arbóreas en el Santuario de la Naturaleza Laguna Grande - Humedal Los Batros, ubicado en San Pedro de la Paz, Concepción, Chile.

Los resultados confirman la hipótesis de que es posible utilizar imágenes hiperespectrales para identificar especies arbóreas con alta precisión en esta área. La combinación de técnicas de espectrometría de imágenes y modelos de clasificación de Machine Learning, especialmente con el uso de imágenes MNF, ha demostrado ser efectiva. Sin embargo, se identificaron variables que redujeron la precisión de la clasificación, resaltando la necesidad de mejorar las técnicas de preprocesamiento y ajustar los algoritmos de clasificación para manejar mejor las condiciones de reflectividad y otras complejidades del entorno. Para mejorar la clasificación espectral en futuras aplicaciones, se podrían implementar máscaras de sombras y aumentar la cantidad de muestras in-situ, lo que permitiría una mejor validación de los datos clasificados y un mayor control sobre la realidad en terreno.

Los objetivos específicos se cumplieron satisfactoriamente, proporcionando una base sólida para futuras aplicaciones y estudios en teledetección y clasificación espectral de especies arbóreas. Estos hallazgos subrayan la importancia de las técnicas avanzadas de teledetección para la gestión y conservación de ecosistemas forestales.

El modelo SVM mostró una alta precisión en la clasificación usando las bandas de reflectancia, mientras que el modelo RF no fue tan efectivo debido a un ajuste inadecuado del método de clasificación. No obstante, la aplicación de la técnica MNF para la reducción de ruido y componentes principales proporcionó una mayor estabilidad en los resultados de ambos modelos de aprendizaje automático, destacando la superioridad de las imágenes MNF sobre las bandas separadas de reflectancia.

La clasificación de especies arbóreas mediante imágenes hiperespectrales es una herramienta valiosa que proporciona mapas detallados de la distribución espacial de las especies. Esto puede guiar proyectos de conservación de biodiversidad, control de especies invasoras y apoyo en planes de manejo forestal, además de ofrecer contenido visual educativo para el público sobre las especies predominantes en su entorno.

Las proyecciones de este estudio indican que la integración de imágenes hiperespectrales y técnicas de Machine Learning puede revolucionar la gestión forestal y la conservación de biodiversidad. A medida que se mejoren las técnicas de preprocesamiento y se ajusten los algoritmos de clasificación, se espera una mayor precisión y eficiencia en la identificación de especies arbóreas. Además, la expansión de estas metodologías a otras regiones permitirá la creación de mapas detallados de distribución de especies, facilitando el control de especies invasoras y la planificación de proyectos de conservación a gran escala. Estos avances no solo contribuirán a la ciencia forestal, sino que también proporcionarán herramientas valiosas para la educación ambiental y la gestión sostenible de los recursos naturales.

VIII. BIBLIOGRAFÍA

- Acuña, T., Mattar, C., & Hernández, H. (2016). Caracterización espectral de Quillaja saponaria (Mol.). *Revista de Teledetección*(47), 65-73.
- Ahmad, I., Basher, M., Iqbal, M. J., & Rahim, A. (2018). Performance comparison of support vector machine, random forest, and extreme learning machine for intrusion detection. *IEEE access*, 6, 33789-33795.
- Alonso, C., Moreno, V., & Rodríguez, E. (1999). Determinación experimental de la firma espectral de la vegetación. una sencilla práctica de introducción a la teledetección. TELEDETECCIÓN. Avances y Aplicaciones. VIII Congreso Nacional de Teledetección. Albacete, España,
- Brandeis, T., Freitas, J., Lara, R., Arana, A., Boscana, M., Cuchiatti, A., Saucedo, R., Marcano-Vega, H., Valiente, C., Ramirez, C., Villela, S., & Alberdi, I. (2021). Desafíos y oportunidades de los Inventarios Forestales Nacionales. In (pp. 39-47).
- Bravo, J. D. (2000). *Breve introducción a la cartografía ya los sistemas de información geográfica (SIG)*. Ciemat.
- Breiman, L. (2001, 2001/10/01). Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Calvario, G. (2019). Paradigmas de aprendizaje automático aplicados a la teledetección: imágenes RGB e imágenes multiespectrales.
- Cárdenas, A. P., Martínez Martínez, F. P., & Bugeño Rubio, H. (2023, 2023-02-15). Paisaje Natural y Cultural en Chile frente a los desafíos del cambio climático. *Cuadernos del Centro de Estudios de Diseño y Comunicación*, 26(185), 137-137-151. <https://search.ebscohost.com/login.aspx?direct=true&db=asu&AN=163816582&site=eds-live>

- Cho, M. A., Mathieu, R., Asner, G. P., Naidoo, L., van Aardt, J., Ramoelo, A., Debba, P., Wessels, K., Main, R., Smit, I. P. J., & Erasmus, B. (2012, 2012/10/01/). Mapping tree species composition in South African savannas using an integrated airborne spectral and LiDAR system. *Remote Sensing of Environment*, *125*, 214-226.
<https://doi.org/https://doi.org/10.1016/j.rse.2012.07.010>
- Cortes, C., & Vapnik, V. (1995, 1995/09/01). Support-vector networks. *Machine Learning*, *20*(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Dalponte, M., Ørka, H., Gobakken, T., Gianelle, D., & Næsset, E. (2013, 05/01). Tree Species Classification in Boreal Forests With Hyperspectral Data. *IEEE Transactions on Geoscience and Remote Sensing*, *51*, 2632-2645.
<https://doi.org/10.1109/TGRS.2012.2216272>
- Daniel, R. P., Noela, S. C., Antonio, D. G. J., & SANTA MARTA PASTRANA, C. (2015). *Cuestiones de teledetección*. Editorial UNED.
- Decreto 42 de 2022 del Ministerio de Medio Ambiente, Declara Santuario de La Naturaleza Laguna Grande - Humedal Los Batros. Diario Oficial de la Republica de Chile, Santiago, Chile, el 03 de marzo de 2022.
- Echeverri, M. P. D. (2013). *Satélites de teleobservación de la tierra: aspectos técnicos y jurídicos* Uniandes.
- Espinosa, M., Acuña, C., García Sandoval, J., Rodríguez Leiva, R., & Rubilar Pons, R. A. (2017). *Silvicultura de bosques plantados con fines productivos*. Universidad de Concepción.
- García, N. y C. Ormazábal. 2008. Árboles Nativos de Chile. Energía S.A. Santiago, Chile. 196 p.
<https://fundacionphilippi.cl/wp-content/uploads/2018/10/arboles-nativos-enersis.pdf>
- García, N. y C. Ormazábal. 2008. Árboles Nativos de Chile. Energía S.A. Santiago, Chile. 196 p.
<https://fundacionphilippi.cl/wp-content/uploads/2018/10/arboles-nativos-enersis.pdf>

- González, F., Martínez, M. H., Cuevas, J. M., Martínez, S., Gomez, J. A., & De Miguel, E. (2010). Utilización de imágenes hiperespectrales AHS para el estudio de zonas afectadas por incendios forestales. *Revista de Teledetección*, 33, 29-46.
- Gonzalez, V., & Vargas, N. (2013, 09/25). Análisis de Imágenes Hiperespectrales. *Revista Ingeniería & Desarrollo*, 14-17.
- Hernández, J., & Montaner, D. (2009). Patrones de respuesta espectral. *Tecnologías Geoespaciales: Experiencias Aplicadas al Estudio y Gestión del Territorio*. Carlos Mena (Ed.) ISBN, 978-956.
- Jorquera, C., Vega, J. A., ABURTO, J., MARTÍNEZ-TILLERÍA, K., LEON, F., A PÉREZ, M., GAYMER, C. F., & SQUEO, F. A. (2012). Conservación de la biodiversidad en Chile: Nuevos desafíos y oportunidades en ecosistemas terrestres y marinos costeros. *Revista chilena de historia natural*, 85(3), 267-280.
- Landis, J. R., & Koch, G. G. (1977). The Measurement of Observer Agreement for Categorical Data. *Biometrics*, 33(1), 159-174. <https://doi.org/10.2307/2529310>
- Ley Nº 17.288 de 1970. Diario Oficial de la Republica de Chile, Santiago, Chile, el 04 de febrero de 1970.
- Ley Nº 20.283 de 1970. Diario Oficial de la Republica de Chile, Santiago, Chile, el 04 de febrero de 1970.
- Linares, S., & Tisnes, A. (2011). *Extracción y análisis de superficies urbanas construidas empleando imágenes LANDSAT 5 (TM)*.
- Liu, L., Coops, N. C., Aven, N. W., & Pang, Y. (2017). Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data. *Remote Sensing of Environment*, 200, 170-182.
- Martin, H. R. (2013). Una mirada a la naturaleza de la luz y el espectro electromagnético. *Hojitas de Conocimiento. Ciencia; n° 12*.

- Medina, N., Vidal, P., Cifuentes, R., Torralba, J., & Keusch, F. (2018). Evaluación del estado sanitario de individuos de *Araucaria araucana* a través de imágenes hiperespectrales. *Revista de Teledetección*(52), 41-53.
- Mena, C., Ormazábal, Y., Morales, Y., Santelices, R., & Gajardo, J. (2011). Índices de área verde y cobertura vegetal para la ciudad de Parral (Chile), mediante fotointerpretación y SIG. *Ciência Florestal*, 21, 521-531.
- Modzelewska, A., Fassnacht, F. E., & Stereńczak, K. (2020, 2020/02/01/). Tree species identification within an extensive forest area with diverse management regimes using airborne hyperspectral data. *International Journal of Applied Earth Observation and Geoinformation*, 84, 101960.
<https://doi.org/https://doi.org/10.1016/j.jag.2019.101960>
- García, N., & Ormazabal, C. (2008). Árboles nativos de Chile.
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217-222.
- Paoletti, M. E., Haut, J. M., Plaza, J., & Plaza, A. (2019). Estudio comparativo de Técnicas de clasificación de imágenes hiperespectrales. *Revista Iberoamericana de Automática e Informática industrial*, 16(2), 129-137.
- Perez, C., & Muñoz, A. L. (2006). *Teledetección: nociones y aplicaciones*. carlos perez.
- Poblete, P., Gysling Caselli, J., Alvarez González, V., Bañados, M., Carlos, J., Kahler González, C., Pardo, V., Soto Aguirre, D., & Baeza Rocha, D. (2023). Anuario forestal 2023.
- Richter, R., & Schläpfer, D. (2019). Atmospheric and topographic correction (ATCOR theoretical background document). *DLR IB*, 1, 0564-0503.
- Rodas, V., & Godínez, B. (2012). Manual para la implementación de mecanismos de Pago por Servicios Ambientales (PSA). *San Marcos-Guatemala: Ambiens Infinitus*.

- Rodríguez, R., Ruiz, E., Elissetche Martínez, J. (2005). Árboles en Chile. Concepción, Chile: Universidad de Concepción.
- Sandoval, L. J. (2018). Algoritmos de aprendizaje automático para análisis y predicción de datos. *Revista Tecnológica*; no. 11.
- Santos, C., & Renovato, R. (2019). *FOTOPROTEÇÃO: Uma proposta interdisciplinar para o Ensino Médio*.
- Schläpfer, D., & Richter, R. (2002, 2002/01/01). Geo-atmospheric processing of airborne imaging spectrometry data. Part 1: Parametric orthorectification. *International Journal of Remote Sensing*, 23(13), 2609-2630. <https://doi.org/10.1080/01431160110115825>
- Scott, C. T., & Gove, J. H. (2002). Forest inventory. *Encyclopedia of environmetrics*, 2, 814-820.
- Servicio Nacional Forestal y de Fauna Silvestre SERFOR (2019). Consideraciones básicas para el manejo forestal de bosques comunales-Guía número 3. <https://repositorio.serfor.gob.pe/bitstream/SERFOR/723/4/SERFOR%202019%20MFC%20GUIA%2003%20%202019.pdf#:~:text=El%20inventario%20forestal%20es%20el%20conteo%20y%20medici%C3%B3n,el%20%C3%A1rea%20delh>
- Sierralta, L., Serrano, R., Rovira, J., & Cortés, C. (2011). Las áreas protegidas de Chile, antecedentes, institucionalidad, estadísticas y desafíos.
- Sims, D. A., & Gamon, J. A. (2002, 2002/08/01/). Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, 81(2), 337-354. [https://doi.org/https://doi.org/10.1016/S0034-4257\(02\)00010-X](https://doi.org/https://doi.org/10.1016/S0034-4257(02)00010-X)
- Tapella, E. (2012). Heterogeneidad social y valoración diferencial de servicios ecosistémicos. Un abordaje multi-actoral en el oeste de Córdoba (Argentina). *DThesis, Universidad Nacional de Córdoba, Córdoba, Argentina*.
- Toro, C., Gygli, B., Romo, D., & Benohr, J. (2017). *Bosques de la tierra del Biobío*.

- Trier, Ø. D., Salberg, A.-B., Kermit, M., Rudjord, Ø., Gobakken, T., Næsset, E., & Aarsten, D. (2018, 2018/01/01). Tree species classification in Norway from airborne hyperspectral and airborne laser scanning data. *European Journal of Remote Sensing*, 51(1), 336-351. <https://doi.org/10.1080/22797254.2018.1434424>
- Valladares, F., Aranda, I., & Sánchez-Gómez, D. (2004). La luz como factor ecológico y evolutivo para las plantas y su interacción con el agua. *Ecología del bosque mediterráneo en un mundo cambiante*, 335-369.
- Vargas, P., Torrejón, F., Pauchard, A., & Urrutia, R. (2017). Rápido movimiento de plantas exóticas en la zona central de Chile: Una reconstrucción a través de evidencia histórica y palinológica. *Boletín de la Sociedad Argentina de Botánica*, 52(1), 121-140.
- Verma, R. K., Sharma, L. K., & Lele, N. (2023). Efficacy of AVIRIS-NG data for species-specific recognition towards a comparative analysis by hyperspectral classifiers. *Advances in Space Research*. <https://doi.org/10.1016/j.asr.2023.01.064>
- Vílchez, L. O. (2002). *Inventarios forestales para bosques latifoliados en América Central*. CATIE.
- Zartuche, J., Gurrola, F., Ortega, L. et al (2018). Manual de identificación de árboles y arbustos forrajeros en Tamaulipas. <https://www.gob.mx/cms/uploads/attachment/file/415726/MANUAL-DE-ARBOLES-FINAL-WEB-1-79.pdf>
- Zhang, Z.-H., Hu, G., Zhu, J.-D., Luo, D.-H., & Ni, J. (2010, 2010/11/01). Spatial patterns and interspecific associations of dominant tree species in two old-growth karst forests, SW China. *Ecological Research*, 25(6), 1151-1160. <https://doi.org/10.1007/s11284-010-0740-0>

IX. APÉNDICE

Tabla A.1

N° Árbol	Especie	Longitud	Latitud
1	<i>Populus deltoides</i>	-73.104373	-36.847270
2	<i>Populus deltoides</i>	-73.104655	-36.847348
3	<i>Peumus boldus</i>	-73.104919	-36.847339
4	<i>Acacia melanoxylon</i>	-73.105080	-36.846849
5	<i>Eucalyptus globulus</i>	-73.106401	-36.846796
6	<i>Eucalyptus globulus</i>	-73.106784	-36.846644
7	<i>Eucalyptus globulus</i>	-73.106986	-36.846404
8	<i>Salix babylonica</i>	-73.107612	-36.846315
9	<i>Salix babylonica</i>	-73.107810	-36.846260
10	<i>Cupressus macrocarpa</i>	-73.108183	-36.845920
11	<i>Eucalyptus globulus</i>	-73.108592	-36.846159
12	<i>Salix babylonica</i>	-73.108452	-36.846200
13	<i>Cupressus macrocarpa</i>	-73.109156	-36.845909
14	<i>Eucalyptus globulus</i>	-73.109682	-36.845716
15	<i>Pinus radiata</i>	-73.110369	-36.845683
16	<i>Pinus radiata</i>	-73.111120	-36.845842
17	<i>Pinus radiata</i>	-73.111443	-36.845957
18	<i>Pinus radiata</i>	-73.111851	-36.846199
19	<i>Pinus radiata</i>	-73.112408	-36.846411
20	<i>Eucalyptus globulus</i>	-73.112691	-36.846897
21	<i>Eucalyptus globulus</i>	-73.113071	-36.847974
22	<i>Acacia melanoxylon</i>	-73.112995	-36.848163
23	<i>Acacia melanoxylon</i>	-73.112845	-36.848335
24	<i>Peumus boldus</i>	-73.112804	-36.848715
25	<i>Cryptocarya alba</i>	-73.112622	-36.849345
26	<i>Peumus boldus</i>	-73.105466	-36.847141
27	<i>Peumus boldus</i>	-73.105642	-36.846860
28	<i>Nothofagus obliqua</i>	-73.105906	-36.846599
29	<i>Nothofagus dombeyi</i>	-73.106047	-36.846519
30	<i>Nothofagus dombeyi</i>	-73.105767	-36.846523
31	<i>Nothofagus obliqua</i>	-73.105729	-36.846436
32	<i>Nothofagus obliqua</i>	-73.106506	-36.845972
33	<i>Acacia melanoxylon</i>	-73.107428	-36.845581

34	<i>Pinus radiata</i>	-73.107318	-36.844585
35	<i>Pinus radiata</i>	-73.106848	-36.844451
36	<i>Pinus radiata</i>	-73.107510	-36.844087
37	<i>Populus deltoides</i>	-73.108810	-36.844426
38	<i>Eucalyptus globulus</i>	-73.108966	-36.844898
39	<i>Eucalyptus globulus</i>	-73.109325	-36.844679
40	<i>Pinus radiata</i>	-73.109740	-36.844267
41	<i>Pinus radiata</i>	-73.109862	-36.844172
42	<i>Pinus radiata</i>	-73.110221	-36.844375
43	<i>Pinus radiata</i>	-73.111857	-36.846355
44	<i>Acacia melanoxylon</i>	-73.113197	-36.848759
45	<i>Peumus boldus</i>	-73.113264	-36.848980
46	<i>Teline monspessulana</i>	-73.113283	-36.849231
47	<i>Acacia melanoxylon</i>	-73.113627	-36.850229
48	<i>Peumus boldus</i>	-73.113589	-36.850308
49	<i>Acacia melanoxylon</i>	-73.113342	-36.850333
50	<i>Peumus boldus</i>	-73.113233	-36.850300
51	<i>Peumus boldus</i>	-73.113304	-36.850221
52	<i>Cryptocarya alba</i>	-73.113037	-36.850024
53	<i>Maytenus boaria</i>	-73.112959	-36.849901
54	<i>Cryptocarya alba</i>	-73.112834	-36.849765
55	<i>Cryptocarya alba</i>	-73.112543	-36.849704
56	<i>Peumus boldus</i>	-73.112513	-36.849594
57	<i>Cryptocarya alba</i>	-73.112451	-36.849479
58	<i>Peumus boldus</i>	-73.112487	-36.849384
59	<i>Cryptocarya alba</i>	-73.112356	-36.849364
60	<i>Cryptocarya alba</i>	-73.112302	-36.849241
61	<i>Acacia melanoxylon</i>	-73.112582	-36.849133
62	<i>Acacia melanoxylon</i>	-73.112681	-36.849012
63	<i>Eucalyptus globulus</i>	-73.112509	-36.848996
64	<i>Peumus boldus</i>	-73.112872	-36.848807
65	<i>Cryptocarya alba</i>	-73.112926	-36.848651
66	<i>Pinus radiata</i>	-73.112735	-36.848474
67	<i>Acacia melanoxylon</i>	-73.112962	-36.848384
68	<i>Teline monspessulana</i>	-73.113253	-36.848064
69	<i>Eucalyptus globulus</i>	-73.113435	-36.847660
70	<i>Pinus radiata</i>	-73.112815	-36.846579
71	<i>Pinus radiata</i>	-73.112704	-36.846302
72	<i>Eucalyptus globulus</i>	-73.109304	-36.845516
73	<i>Eucalyptus globulus</i>	-73.108993	-36.845535

74	<i>Acacia melanoxylon</i>	-73.107618	-36.845837
75	<i>Eucalyptus globulus</i>	-73.106088	-36.847165
76	<i>Acacia melanoxylon</i>	-73.106105	-36.846741
77	<i>Acacia melanoxylon</i>	-73.105160	-36.847124
78	<i>Eucalyptus globulus</i>	-73.107071	-36.846096
79	<i>Salix babylonica</i>	-73.108111	-36.846271
80	<i>Acacia melanoxylon</i>	-73.108111	-36.845340
81	<i>Pinus radiata</i>	-73.107873	-36.844793
82	<i>Pinus radiata</i>	-73.106565	-36.844550
83	<i>Eucalyptus globulus</i>	-73.106011	-36.844480
84	<i>Eucalyptus globulus</i>	-73.105930	-36.844491
85	<i>Cupressus macrocarpa</i>	-73.105922	-36.844531
86	<i>Maytenus boaria</i>	-73.107009	-36.845386
87	<i>Cryptocarya alba</i>	-73.106897	-36.845405
88	<i>Cupressus macrocarpa</i>	-73.109329	-36.846128
89	<i>Eucalyptus globulus</i>	-73.109693	-36.845982
90	<i>Acacia melanoxylon</i>	-73.111423	-36.846205
91	<i>Pinus radiata</i>	-73.112153	-36.846541
92	<i>Pinus radiata</i>	-73.112398	-36.846873
93	<i>Pinus radiata</i>	-73.113073	-36.847139
94	<i>Eucalyptus globulus</i>	-73.113106	-36.847427
95	<i>Peumus boldus</i>	-73.112996	-36.850128
96	<i>Peumus boldus</i>	-73.113019	-36.850261
97	<i>Maytenus boaria</i>	-73.112853	-36.849949
98	<i>Peumus boldus</i>	-73.112479	-36.849634
99	<i>Pinus radiata</i>	-73.111873	-36.845894
100	<i>Pinus radiata</i>	-73.111618	-36.845696
101	<i>Pinus radiata</i>	-73.111156	-36.845363
102	<i>Pinus radiata</i>	-73.110944	-36.845031
103	<i>Pinus radiata</i>	-73.110984	-36.843928
104	<i>Acacia melanoxylon</i>	-73.110593	-36.844201
105	<i>Eucalyptus globulus</i>	-73.109586	-36.844846
106	<i>Acacia melanoxylon</i>	-73.109621	-36.845273
107	<i>Cupressus macrocarpa</i>	-73.108239	-36.845949
108	<i>Eucalyptus globulus</i>	-73.109299	-36.845351
109	<i>Eucalyptus globulus</i>	-73.109744	-36.845716
110	<i>Eucalyptus globulus</i>	-73.110136	-36.845724
111	<i>Pinus radiata</i>	-73.111810	-36.846226
112	<i>Pinus radiata</i>	-73.112161	-36.846501
113	<i>Pinus radiata</i>	-73.112358	-36.846778

114	<i>Pinus radiata</i>	-73.112907	-36.847376
115	<i>Eucalyptus globulus</i>	-73.113256	-36.847855
116	<i>Acacia melanoxylon</i>	-73.113000	-36.848104
117	<i>Pinus radiata</i>	-73.113798	-36.848239
118	<i>Acacia melanoxylon</i>	-73.113481	-36.848443
119	<i>Acacia melanoxylon</i>	-73.112623	-36.848882
120	<i>Cryptocarya alba</i>	-73.112318	-36.849212
