

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO FIN DE GRADO

PROCESADO DE DATOS MULTIMODALES PARA LA DETECCIÓN DE ESPECIES VEGETALES

Titulación: Grado en Ingeniería en Tecnologías de la Telecomunicación

Mención: Sistemas de Telecomunicación

Autor/a: Gabriel Manrique de Lara Rincón

Tutores/as: Francisco Javier Marcello Ruiz

Dionisio Rodríguez Esparragón

Fecha: junio de 2025

Agradecimientos

Aprovecho este espacio para agradecer a todas las personas que se han visto involucradas en este proyecto.

En mi primer lugar me gustaría agradecer a mis tutores Javier y Dionisio por su dedicación y paciencia durante el desarrollo del proyecto. Agradezco también su completa disponibilidad a la hora de resolver cualquier cuestión relacionada con el trabajo.

Me gustaría agradecer también a mi familia y amigos por el apoyo y la motivación que me han brindado, ayudándome a seguir adelante en momentos adversos.

Reconocimientos:

Agradecer a la dirección del Parque Nacional del Teide, y en especial a D. José Luis Martín Esquivel, por el suministro de los datos de 2019.

Parte de este trabajo se ha desarrollado en el contexto del proyecto SPIP2022-02897, *“Análisis del cambio global en los parques nacionales macaronésicos mediante teledetección multiplataforma y nuevas metodologías de procesado de datos”*, financiado por el Organismo Autónomo Parques Nacionales.

Resumen

Actualmente la teledetección está presente en multitud de aplicaciones, tomando cada vez un papel más relevante en estudios medioambientales por su capacidad de proporcionar información detallada acerca de la superficie terrestre tras la aplicación de técnicas de procesado de datos.

A este respecto, entre los tipos de datos que más información proporcionan se encuentran los datos multiespectrales y LiDAR. Estos son captados por diferentes sensores embarcados en plataformas aéreas como drones o satélites, y que utilizan energía externa o bien su propia energía para la obtención de información sobre la cubierta terrestre.

En este contexto se propone el presente Trabajo de Fin de Grado, en el cual se aplican técnicas de procesado de datos multiespectrales y LiDAR captados mediante dron sobre una parcela ubicada en la zona sur del Parque Nacional del Teide con el objetivo de obtener mapas vegetales clasificados, analizar la estructura tridimensional de la vegetación presente en esta y detectar los cambios con respecto a estudios previos.

Abstract

Currently, remote sensing is present in a wide range of applications, playing an increasingly relevant role in environmental studies due to its potential to provide detailed information about the Earth's surface through the application of data processing techniques.

Among the types of data that provide the most information are multispectral and LiDAR data. These are captured by different sensors mounted on airborne platforms such as drones or satellites, and use either external energy or their own energy to obtain information about the Earth's surface cover.

In this context, the present Final Degree Project is proposed, in which multispectral and LiDAR data processing techniques captured by drone are applied over a plot located in the southern area of Teide National Park, with the aim of obtaining classified vegetations maps, analysing the three-dimensional structure on the vegetation present in the area and detecting changes with respect to previous studies.

INDICE DE CONTENIDO

PARTE I: MEMORIA

Capítulo 1 Introducción	1
1.1 Antecedentes.....	1
1.2 Objetivos	2
1.3 Descripción de las tareas.....	3
1.4 Estructura de la memoria	3
Capítulo 2 Fundamentos de teledetección multiespectral y LiDAR	5
2.1 Fundamentos de la teledetección.....	5
2.2 Teledetección multiespectral	6
2.3 Teledetección LiDAR.....	10
2.4 Sensores de teledetección	13
2.4.1 Dron DJI Matrice 300 RTK	13
2.4.2 Sensor MicaSense RedEdge-Mx dual.....	14
2.4.3 Sensor Zenmuse L1	15
Capítulo 3 Técnicas de procesamiento de datos de teledetección	17
3.1 Introducción	17
3.2 Preprocesado de datos	18
3.2.1 Preprocesado de datos LiDAR	18
3.2.2 Preprocesado de datos multiespectrales	26
3.2.3 Registro de imágenes	28
3.3 Procesado de datos multiespectrales	32
3.3.1 Índices de vegetación	32
3.3.2 Clasificación de imágenes multiespectrales.....	35
3.4 Segmentación de nubes de puntos LiDAR.....	39
Capítulo 4 Clasificación de la vegetación en el Parque Nacional del Teide	43
4.1 Zona de estudio.....	43
4.2 Datos dron del Parque Nacional del Teide	45
4.3 Metodología.....	46
4.3.1 Pre-procesado LiDAR	47
4.4 Registro de imágenes.....	50
4.4.1 Registro usando como base la nube de puntos	50
4.4.2 Registro usando como base el CHM.....	51
4.5 Clasificación.....	56
4.5.1 ROIs.....	57

4.5.2 Clasificación multiespectral	60
4.5.3 Clasificación multisensor	63
Capítulo 5 Extracción de parámetros vegetales y análisis de cambios.....	69
5.1 Segmentación.....	69
5.2 Extracción de parámetros	75
5.3 Análisis de los cambios en la retama con respecto a 2019	75
5.3.1 Clasificación de la subparcela.....	76
5.3.2 Detección de cambios	78
Capítulo 6 Conclusiones.....	87
6.1 Revisión de los objetivos propuestos.....	87
6.2 Conclusiones del análisis de resultados.....	87
6.3 Líneas de trabajo futuras.....	89
PARTE II: BIBLIOGRAFIA	86
PARTE III: PRESUPUESTO	94
PARTE IV: ANEXO	95

INDICE DE FIGURAS

Figura 2.1. Elementos de un sistema de teledetección [4].	6
Figura 2.2. Espectro electromagnético [9].	7
Figura 2.3. Firmas espectrales del suelo, la vegetación y el agua.	8
Figura 2.4. Comparativa entre tipos de imágenes en función de las bandas espectrales capturadas [13].	9
Figura 2.5. Resolución espacial de un sensor.	9
Figura 2.6. Niveles de codificación en una imagen [15].	10
Figura 2.7. Diagrama de bloques de un sistema LiDAR.	11
Figura 2.8. Clasificación de la nube de puntos [19].	12
Figura 2.9. Bandas espectrales del sensor MicaSense RedEdge.Mx Dual [24].	14
Figura 3.1 Metodología seguida.	18
Figura 3.2 Diagrama de bloques de preprocesado LiDAR.	18
Figura 3.3. Distancia y ángulos evaluados [28].	20
Figura 3.4. Proceso de clasificación de puntos de suelo [27].	20
Figura 3.5. Ejemplo de interpolación.	21
Figura 3.6. Ponderación de cada punto [36].	22
Figura 3.7. Red TIN [39].	23
Figura 3.8. Interpolación de valores dentro de un triángulo de la red TIN.	24
Figura 3.9. (a) Nube de puntos representada en color natural. (b) Modelo digital de elevación.	24
Figura 3.10. (a) Nube de puntos representada en color natural. (b) Modelo digital de superficie.	25
Figura 3.11. Obtención del CHM.	26
Figura 3.12. (a) Nube de puntos representada en color natural. (b) Modelo de dosel arbóreo.	26
Figura 3.13 Recta de radiancia y nivel digital.	27
Figura 3.14 Diagrama de bloques del registro.	29
Figura 3.15. (a) Vecino más cercano. (b) Interpolación bilineal. (c) Convolución cúbica [45].	32

Figura 3.16. Firma espectral de la vegetación [53].	33
Figura 3.17. Reflectancia de la vegetación sana y enferma en las bandas roja e infrarroja cercana [56].	34
Figura 3.18. Probabilidades de que un píxel pertenezca a cada clase [62].	36
Figura 3.19. Elementos de una clasificación SVM [63].	37
Figura 3.20. Segmentación por watershed [28].	40
Figura 3.21. Segmentación por crecimiento de regiones [28].	41
Figura 4.1 Parque Nacional del Teide.	43
Figura 4.2 Retama del Teide.	44
Figura 4.3 Localización de la parcela en el Parque Nacional del Teide.	45
Figura 4.4 (a) Imagen multispectral. (b) Nube de puntos LiDAR en formato RGB.	45
Figura 4.5 Metodología seguida para el procesado de los datos multispectrales.	46
Figura 4.6 Diagrama de bloques del pre-procesado LiDAR.	47
Figura 4.7 Menú de clasificación de puntos de suelo.	48
Figura 4.8 Creación: (a) DEM. (b) DSM.	48
Figura 4.9 a) DEM. (b) DSM.	49
Figura 4.10 Mapa de alturas: (a) Escala de grises. (b) Con paleta a color.	49
Figura 4.11 Diagrama de bloques del proceso de registro.	50
Figura 4.12 (a) Zonas correctamente alineadas. (b) Zonas incorrectamente alineadas.	51
Figura 4.13 Parámetros para la generación de puntos de control.	52
Figura 4.14 Puntos de control generados en: (a) Prueba 1. (b) Prueba 2. (c) Prueba 3. (d) Prueba 4. (e) Prueba 5. (f) Prueba 6.	53
Figura 4.15 Imágenes registradas con transparencia: (a) Prueba 1. (b) Prueba 2. (c) Prueba 3. (d) Prueba 4. (e) Prueba 5. (f) Prueba 6.	54
Figura 4.16 Puntos de control mapa de retamas.	55
Figura 4.17 (a) Imagen multispectral 2019 registrada. (b) Mapa de retamas registrado.	55
Figura 4.18 Diagrama de bloques del proceso de clasificación.	56
Figura 4.19 Imagen dron de 2024: (a) Multispectral. (b) CHM.	57
Figura 4.20 (a) ROIs de entrenamiento. (b) ROIs de evaluación.	58
Figura 4.21 (a) Firma espectral de las regiones de entrenamiento (media). (b) Firma espectral de las regiones de entrenamiento (desviación típica).	60
Figura 4.22 (a) Firma espectral de las regiones de evaluación (media). (b) Firma espectral de las regiones de evaluación (desviación típica).	60
Figura 4.23 (a) Clasificación Support Vector Machine. (b) Clasificación Maximum Likelihood. (c) Clasificación Mahalanobis Distance. (d) Clasificación Spectral Angle Mapper.	61
Figura 4.24 Porcentaje de acierto de Maximum Likelihood y Support Vector Machine.	63
Figura 4.25 Acierto de cada imagen en función de las clases.	65
Figura 4.26 Acierto de cada clase en función de la imagen.	65

Figura 4.27 Clasificación SVM para: (a) MS. (b) LiDAR. (c) MSAVI2. (d) MS+LiDAR. (e) MS+MSAVI2. (f) MS+LiDAR+MSAVI2.	66
Figura 4.28 Sin clasificar. (b) Clasificada. (c) Clasificada y filtrada por mayoría. (d) Trozo de la parcela sin clasificar. (e) Trozo de la parcela clasificada. (f) Trozo de la parcela clasificada y filtrada por mayoría.	67
Figura 5.1 Nube de puntos: (a) RGB. (b) Segmentada.	69
Figura 5.2 (a) Altura otra vegetación. (b) Altura retama.	70
Figura 5.3 Segmentación con umbral de: (a) 1 metro. (b) 0.6 metros.	71
Figura 5.4 (a) Semillas generadas con umbral de 1 metro. (b) Semillas generadas con umbral de 1 metro corregidas.	72
Figura 5.5 (a) CHM. (b) Parcela segmentada final. (c) Trozo del CHM. (d) Trozo de la parcela segmentada final.	73
Figura 5.6 (a) Retama muerta. (b) Retama muerta segmentada en varias diferentes.	74
Figura 5.7 (a) Retama grande. (b) Retama grande segmentada correctamente.	74
Figura 5.8 Medidas de la retama.	74
Figura 5.9 (a) Subparcela segmentada del año 2019. (b) Subparcela RGB del año 2019.	76
Figura 5.10 Diagrama de bloques del procedimiento de la detección de cambios.	76
Figura 5.11 Clasificación de la subparcela del año: (a) 2024. (b) 2019.	77
Figura 5.12 Mapa de retamas segmentado superpuesto a la clasificación: (a) Completo. (b) Ampliado.	77
Figura 5.13 (a) Cambios detectados en la parcela. (b) Leyenda.	79
Figura 5.14 Cambio de retama de vegetación muerta.	81
Figura 5.15 Cambio de otra clase a retama.	81
Figura 5.16 Segmentación final: (a) 2D. (b) 3D.	83
Figura 5.17 (a) Clasificación por altura. (b) Clasificación por diámetro. (c) Clasificación por superficie. (d) Clasificación por volumen.	84
Figura 5.18 (a) Semillas clasificadas por altura. (b) Semillas clasificadas por diámetro. (c) Semillas clasificadas por superficie. (d) Semillas clasificadas por volumen.	85

INDICE DE TABLAS

Tabla 3.1 Estructura de una matriz de confusión.	39
Tabla 4.1 Pruebas de registro.	52
Tabla 4.2 Estadísticas de los ROIs de entrenamiento.	58
Tabla 4.3 Estadísticas de los ROIs de evaluación.	58
Tabla 4.4 Separabilidad de los ROIs de entrenamiento.	59
Tabla 4.5 Separabilidad de los ROIs de evaluación.	59
Tabla 4.6 Matriz de confusión en porcentaje de acierto de cada clase con Support Vector Machine.	62
Tabla 4.7 Matriz de confusión en porcentaje de acierto de cada clase con Maximum Likelihood.	62
Tabla 4.8 Porcentaje de acierto de cada clase para cada imagen con Support Vector Machine.	64
Tabla 5.1 Parámetros de la retama 503.	75
Tabla 5.2 Estadísticas de la segmentación de retamas.	75
Tabla 5.3 Estadísticas de la segmentación de retamas.	78
Tabla 5.4 Estadísticas de los cambios detectados.	79
Tabla 5.5 Estadísticas de los cambios detectados en retamas.	79
Tabla 5.6 Superficie total de retamas.	82
Tabla 5.7 Estadísticas de la segmentación de la parcela.	83

LISTADO DE ACRONIMOS

TFG	Trabajo de Fin de Grado
LiDAR	Light Detection and Ranging
DEM	Digital Elevation Model
DSM	Digital Surface Model
CHM	Canopy Height Model
ROI	Region Of Interest
MS	Multiespectral
ML	Maximum Likelihood
SVM	Support Vector Machine
SAM	Spectral Angle Mapper
MH	Mahalanobis Distance
ENVI	Environment for Visualizing Images
QGIS	Quantum Geographic Information System
3D	Tridimensional
NIR	Infrarrojo cercano
RGB	Red-Green-Blue
GPS	Global Positioning System
GNSS	Global Navigation System
IMU	Inertial Measurement Unit
NDVI	Normalized Difference Vegetation Index
MSAVI	Modified Soil Adjusted Vegetation Index
NDRE	Normalized Difference Red Edge Index
TIN	Triangulated Irregular Network
LAS	Lidar Data Exchange Format

PARTE I: MEMORIA

Capítulo 1 Introducción

En este capítulo se explican los objetivos y tareas a desarrollar para la elaboración del presente Trabajo de Fin de Grado (TFG).

1.1 Antecedentes

Actualmente existen numerosas plataformas que sobrevuelan la superficie terrestre u orbitan alrededor del planeta con el fin de recopilar datos acerca de la cubierta terrestre de forma remota, permitiendo obtener información del entorno que nos rodea sin necesidad de tener contacto físico.

En este contexto aparece la teledetección. Se trata de una técnica que permite recopilar información sobre objetos y superficies utilizando sensores remotos, sin necesidad de contacto físico directo, constituyendo una herramienta poderosa para el estudio, monitoreo y clasificación de las especies vegetales en áreas protegidas como el Parque Nacional del Teide. Esta tecnología se basa en el uso de ondas electromagnéticas y es esencial para el estudio de la superficie terrestre, así como el entorno. Según la fuente de energía que se emplea, los sistemas de teledetección se pueden dividir en activos, donde el sistema genera su propia energía y recibe la reflexión de esta en un cuerpo, o pasivos, los cuales reciben directamente la energía que refleja el propio cuerpo o la emitida por la cubierta terrestre [1].

Las principales plataformas para captar datos de teledetección son los satélites, aviones y drones. Actualmente, la teledetección mediante dron es una de las más empleadas, ya que permite captar datos de muy alta resolución y transportar diferentes sensores, tanto activos como pasivos [2].

Entre los sensores más usados para la teledetección pasiva se encuentran los sensores multispectrales, capaces de detectar y procesar la energía reflejada en varias longitudes de onda. Cada objeto tiene su propia estructura y composición química, por lo que refleja la radiación de manera diferente en cada longitud de onda del espectro, lo que se conoce como firma espectral. Estos sensores son capaces de capturar la información del objeto en función de su firma espectral, y, por lo tanto, generar imágenes en las que cada píxel representa un valor de reflectancia de la superficie terrestre en función de sus características [3].

Por otra parte, entre las tecnologías más relevantes de teledetección activa se encuentra el LiDAR (acrónimo de *Light Detection and Ranging*), un sistema que utiliza pulsos láser para

medir distancias a objetos [4]. Esta tecnología calcula el tiempo que tarda un pulso láser en reflejarse en un objeto y regresar al sensor. El LiDAR tiene múltiples aplicaciones, destacando en áreas como la topografía, la gestión de recursos forestales y la industria automotriz.

En el ámbito de la gestión forestal, el LiDAR se ha convertido en una herramienta clave para realizar estimaciones precisas de parámetros como el volumen, la biomasa, el área forestal o el crecimiento y la mortalidad de los bosques.

Gracias a su capacidad para generar nubes de puntos 3D detalladas, que representan la altura de los objetos, esta tecnología amplía enormemente las posibilidades de análisis. Esto facilita una mejor comprensión del estado de los ecosistemas forestales, lo que a su vez favorece decisiones más sostenibles, fundamentales para la gestión forestal y la conservación de la biodiversidad.

1.2 Objetivos

El Parque Nacional del Teide constituye uno de los entornos naturales más emblemáticos de España, abarcando una superficie de más de 18.000 hectáreas [5], que contiene alrededor de 200 especies vegetales, en su mayoría endémicas [6]. Este parque destaca por su extraordinaria biodiversidad y paisajes volcánicos únicos, donde confluyen hábitats de alta montaña que albergan un gran número de endemismos, adaptados a las extremas condiciones climáticas de altitud, baja humedad y alta radiación solar.

En este contexto se propone este Trabajo de Fin de Grado, en el cual se plantea realizar un análisis del estado de la vegetación en una parcela del Parque Nacional del Teide haciendo uso de datos multiespectrales y LiDAR captados desde un dron.

Para la consecución de este objetivo general, ha sido necesario abordar los siguientes objetivos específicos:

- O1: Análisis de los datos multiespectrales y LiDAR.
- O2: Generación de un mapa de vegetación clasificado en función de las diferentes especies vegetales de una parcela en el Teide con los datos multiespectrales y LiDAR captados por un dron en 2024.
- O3: Comparación de los cambios obtenidos en la vegetación con respecto a datos previos de un vuelo dron de 2019.
- O4: Análisis de la estructura 3D de las retamas en la parcela seleccionada.

1.3 Descripción de las tareas

Para el desarrollo de este Trabajo de Fin de Grado, se han abordado las siguientes tareas:

- Estudio de los datos multiespectrales y LiDAR: se han estudiado los datos multiespectrales y LiDAR captados por dron, incluyendo las herramientas necesarias para la recopilación y la manipulación de estos.
- Estudio de las técnicas de preprocesado y clasificación de datos multiespectrales y LiDAR: se han estudiado las diferentes técnicas de preprocesado y clasificación de datos multiespectrales y LiDAR, incluyendo co-registración y correcciones.
- Generación de cartografía vegetal a partir de los datos multiespectrales y LiDAR: se han aplicado las técnicas de preprocesado, co-registración y clasificación estudiadas previamente en la parcela seleccionada usando los datos multiespectrales y LiDAR captados por el dron, con el objetivo de discriminar las diferentes especies vegetales de interés en dicha parcela.
- Extracción de resultados y análisis de cambios con respecto a datos previos: se ha llevado a cabo la extracción de los parámetros relacionados con la superficie y el volumen por cada especie y se han analizado los cambios detectados con respecto a los datos clasificados de una campaña dron realizada en 2019.
- Análisis de la estructura 3D de las retamas: se han analizado diferentes parámetros de las retamas a partir de los datos LiDAR y la aplicación de técnicas de segmentación.

1.4 Estructura de la memoria

El presente documento está integrado de tres apartados: Memoria, Bibliografía, Presupuesto y Anexos. A continuación, se detalla el contenido los apartados:

Memoria

En este apartado se recoge el proceso llevado a cabo durante la realización del presente Trabajo de Fin de Carrera, que a su vez se divide en los siguientes capítulos:

- Capítulo 1. Introducción. En este capítulo se realiza una breve introducción y se explican los objetivos del presente Trabajo de Fin de Grado
- Capítulo 2. Fundamentos de teledetección multiespectral y LiDAR. En este capítulo se explican los principios básicos de la teledetección multiespectral y LiDAR, así como el estudio de los propios datos y las plataformas de recopilación de estos.

- Capítulo 3. Técnicas de procesado de datos de teledetección. En este capítulo se explican las diferentes técnicas de preprocesado, registración y clasificación de los datos multiespectrales y LiDAR.
- Capítulo 4. Clasificación de la vegetación en el Parque Nacional del Teide. En este capítulo se describen los procedimientos llevados a cabo para la clasificación de los datos multiespectrales y LiDAR en la parcela seleccionada del Parque Nacional del Teide.
- Capítulo 5. Extracción de resultados y análisis de cambios. En este capítulo se analizan los resultados obtenidos y los cambios detectados con respecto a los datos del año 2019.
- Capítulo 6. Conclusiones. En este capítulo se revisan los objetivos planteados y los resultados conseguidos. Finalmente se extraen las conclusiones y se plantean líneas futuras de investigación.

Bibliografía

En este apartado se recogen las fuentes bibliográficas consultadas para la realización del presente Trabajo de Fin de Grado.

Presupuesto

En este apartado se recogen realiza un análisis de la viabilidad económica del Trabajo de Fin de Grado.

Anexos

En este apartado se recogen las imágenes generadas en el proceso de clasificación, no incluidas en la memoria.

Capítulo 2 Fundamentos de teledetección multispectral y LiDAR

En este capítulo se introducen los fundamentos de la teledetección y de los datos con los que se va a trabajar en el presente Trabajo de Fin de Grado. Además, se estudiará el dron y los sensores usados para captar los datos multispectrales y LiDAR

2.1 Fundamentos de la teledetección

La teledetección, entendida de modo genérico, es la técnica mediante la cual se obtiene información de un objeto sin tener contacto físico con el mismo.

Aplicada al ámbito de las ciencias de la Tierra, la teledetección se define como la técnica que permite registrar información de un objeto por medio de sensores remotos, generalmente a bordo de plataformas aéreas, utilizando la energía electromagnética que el objeto emite, denominada teledetección pasiva; o refleja, conocida como teledetección activa. Esta técnica incluye, a su vez, los procesos de corrección, distribución y tratamiento de la información recopilada por los sensores [1], [2], [7].

La teledetección pasiva utiliza sensores pasivos que reciben directamente la energía que refleja el propio cuerpo o la emitida por la cubierta terrestre, para lo cual dependen de una fuente de energía externa, generalmente el sol.

La teledetección activa, en cambio, utiliza sensores activos, los cuales generan su propia energía que emiten y reciben mediante la reflexión de esta en un cuerpo, pudiendo medir el efecto que producen en ellos.

Todo sistema de teledetección está constituido de los siguientes elementos [1]:

- Fuente de energía, que emite la energía electromagnética reflejada en el objeto. Puede tratarse de un foco externo al emisor, como por ejemplo el sol, tratándose de un caso de teledetección pasiva, o puede tratarse de un emisor propio del sistema.
- Cubierta terrestre, en la cual se refleja la radiación emitida por la fuente emisora.
- Sistema sensor, ubicado en una plataforma que recibe la radiación reflejada por la cubierta terrestre y transforma su información a valores numéricos para enviarla al sistema de recepción.
- Sistema de recepción, en donde se recibe la información transmitida por la plataforma.

- Intérprete, que analiza y procesa la información recibida
- Usuario final, encargado de analizar el producto resultante.

En la Figura 2.1 pueden observarse los elementos de un sistema de teledetección previamente descritos [4].

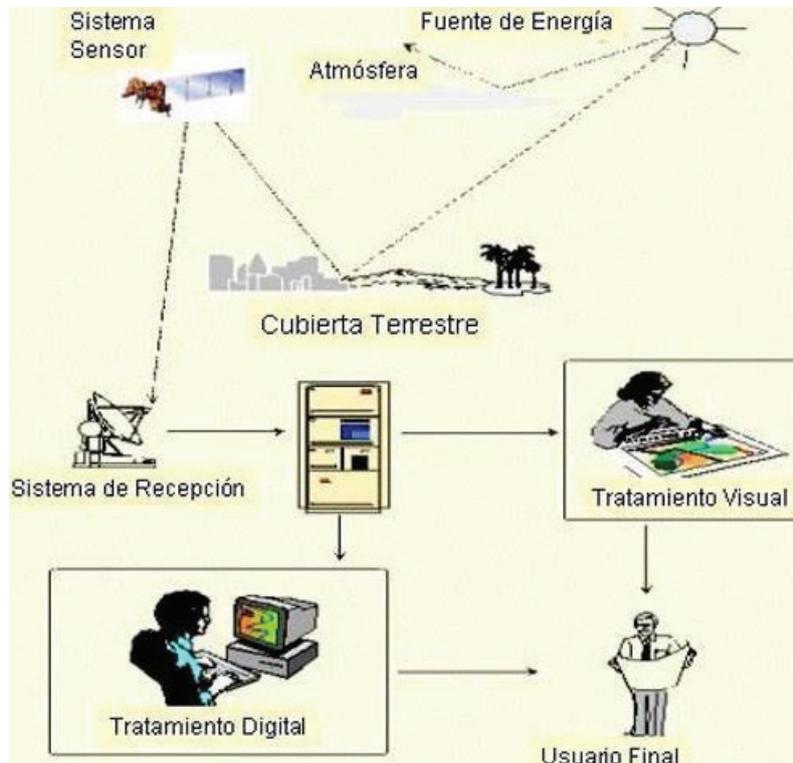


Figura 2.1. Elementos de un sistema de teledetección [4].

2.2 Teledetección multispectral

El espectro electromagnético es la gama completa de radiación electromagnética clasificada en función de la longitud de onda o la frecuencia. Las regiones que forman el espectro electromagnético son las siguientes [8]:

- Radiaciones de alta energía (a partir de 10 nm para abajo): incluye rayos X, rayos gamma y radiación ultravioleta.
- Luz visible (de 0,4 a 0,7 μm).
- Infrarrojo cercano (de 0,4 a 0,7 μm): radiación procedente del solo reflejado por la superficie de la Tierra.
- Infrarrojo medio (de 0,4 a 0,7 μm): región de mezcla entre la radiación solar incidente y reflejada y la radiación emitida por puntos calientes de la superficie
- Infrarrojo térmico (de 0,4 a 0,7 μm): radiación emitida por un objeto debido a su temperatura.

- Radiaciones de baja energía (a partir de 1 mm): incluye las microondas y las ondas de radio.

En la Figura 2.2 se pueden observar las diferentes regiones que componen el espectro electromagnético.

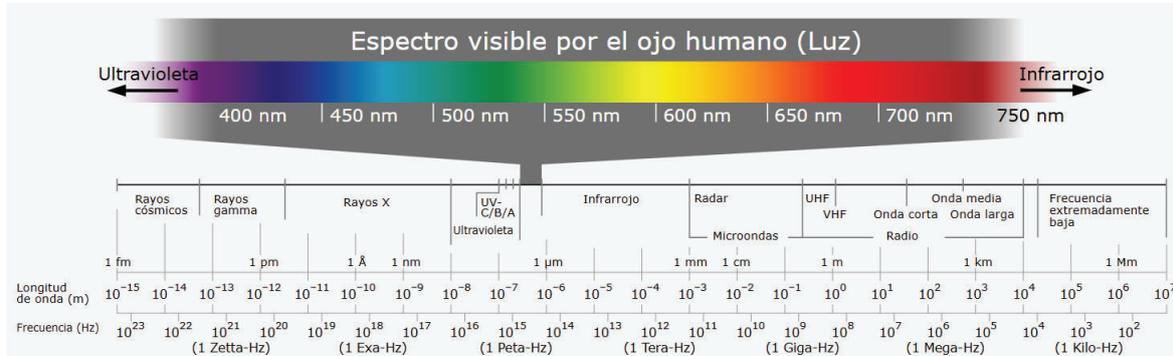


Figura 2.2. Espectro electromagnético [9].

En la teledetección pasiva, uno de los tipos de sensores más empleados son los multispectrales, los cuales pueden captar y analizar la energía reflejada en distintas longitudes de onda. Dado que cada objeto posee una estructura y composición química únicas, su comportamiento frente a la radiación varía según la longitud de onda, generando un patrón distintivo conocido como firma espectral [10].

El ojo humano es capaz de percibir una región del espectro electromagnético, lo que se conoce como visible, mientras que los sensores multispectrales son capaces de capturar la radiación reflejada por el objeto en función de su firma espectral en bandas que el ojo humano no es capaz de percibir, véase el infrarrojo cercano.

En la Figura 2.3 se muestran los valores de reflectancia de la vegetación, el suelo y el agua en función de la longitud de onda, que constituyen los tipos más frecuentes de cubiertas que se encuentran en la superficie terrestre [11], [12].

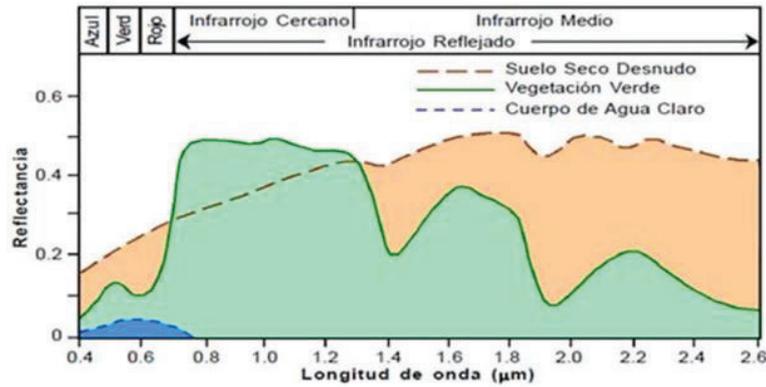


Figura 2.3. Firmas espectrales del suelo, la vegetación y el agua.

Como puede observarse, mayores valores de reflectancia de la vegetación se dan entre 0,7 y 1,3 μm , correspondiente a la región del infrarrojo cercano. Además, presenta valles en 0,45 y 0,6 μm , indicando una mayor absorción de la energía en el azul y el rojo para hacer la fotosíntesis. Este es la razón por la que las hojas sanas de la mayoría de las plantas se ven de color verde.

Las imágenes multispectrales dividen la radiación electromagnética que captan en bandas espectrales, en la mayoría de los casos entre 3 y 10 bandas. Las bandas con las que cuentan las imágenes multispectrales no tienen por qué ser contiguas. Cada píxel de la imagen contiene un valor de reflectancia en cada una de las bandas.

También existen imágenes hiperspectrales, que contienen un mayor número de bandas contiguas y de forma continua. Generalmente cuentan con decenas o centenas de bandas espectrales, por lo que ofrecen información mucho más detallada.

La Figura 2.4 muestra la comparativa entre los distintos tipos de imágenes en función del número de bandas espectrales que capturan [13]. En este TFG se han utilizado datos multispectrales.

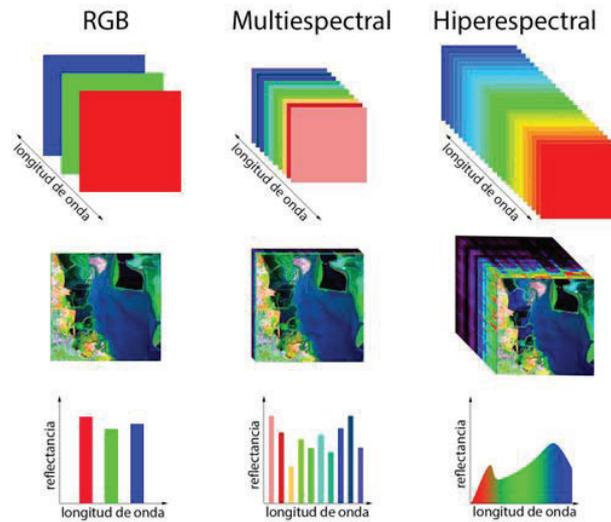


Figura 2.4. Comparativa entre tipos de imágenes en función de las bandas espectrales capturadas [13].

En los sensores, se define la resolución como la capacidad de registrar y discriminar información de forma detalladas. Podemos encontrar cuatro tipos de resoluciones diferentes [14], [1]:

- Resolución espacial: se refiere al campo de visión instantáneo (tamaño de píxel) en el caso de que el sensor se encuentre sobre una plataforma aérea, es decir, la sección angular que se observa en un determinado instante de tiempo. En la Figura 2.5 se muestra con mayor claridad el concepto.

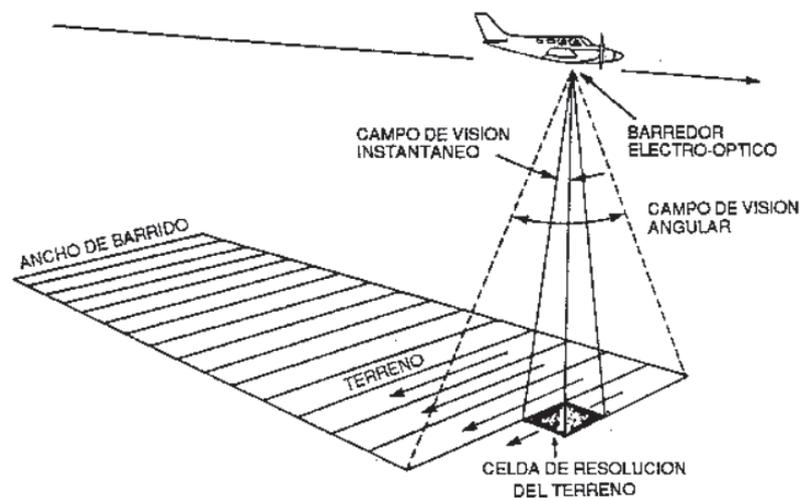


Figura 2.5. Resolución espacial de un sensor.

En función del tamaño de píxel de la imagen, se pueden distinguir varios niveles de resolución. Una baja resolución se encuentra entre los varios kilómetros de tamaño de

pixel, como puede ocurrir en satélites meteorológicos, mientras que una resolución muy alta tiene tamaños de píxel inferiores al metro en caso de satélites como WorldView (30 cm) o de unos pocos centímetros en aviones aeroportados y drones.

- Resolución espectral: indica el número de bandas que discrimina el sensor. Se distinguen cuatro tipos de sensores según su resolución espectral: pancromáticos, que contienen una única banda muy ancha; RGB, que contienen las bandas del rojo, verde y azul; multispectrales e hiperespectrales.
- Resolución radiométrica: se refiere a la capacidad del sensor para detectar variaciones en la energía que recibe, también llamada sensibilidad. Cada pixel de la imagen se convierte en un valor digital codificado en bits. Si el sensor codifica 2 bits, habría 4 posibles valores ($2^2 = 4$), mientras que, si se codificase 8 bits, habría 256 ($2^8 = 256$). En la Figura 2.6 se puede observar cómo se vería la imagen con distintos tipos de niveles de codificación.

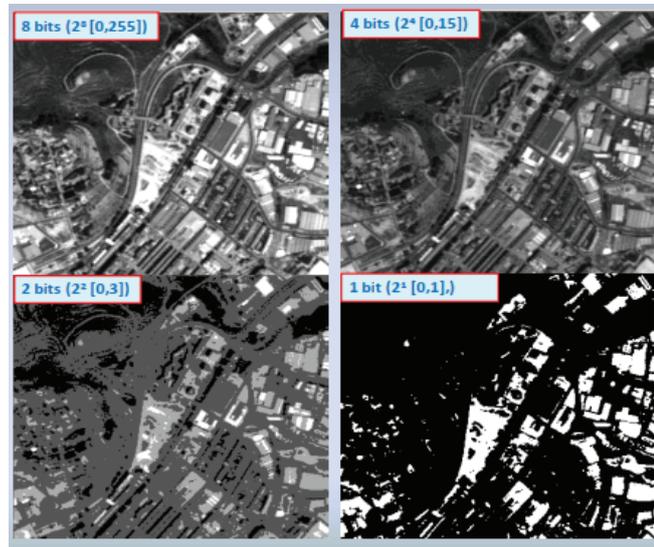


Figura 2.6. Niveles de codificación en una imagen [15].

- Resolución temporal: se relaciona con la frecuencia con la que el sensor repite una cobertura. Este término está más ligado a plataformas espaciales que orbitan alrededor del planeta, por lo que dependiendo del periodo de su órbita varía su resolución temporal.

2.3 Teledetección LiDAR

LiDAR, acrónimo de *Light Detection and Ranging*, es una técnica de teledetección activa que utiliza pulsos láser para estimar la distancia a la que se encuentra un objeto [16]. El funcionamiento se basa en la medición del tiempo transcurrido entre la emisión y la recepción de un pulso láser reflejado en un objeto, lo que se conoce como eco. A partir de este tiempo y, conociendo la velocidad a la que se propaga un pulso láser, correspondiente a la velocidad

de la luz (300.000 km/s), se puede estimar la distancia a la que se encuentra el objeto conociendo la siguiente relación:

$$R = c * \frac{t}{2} \quad (2.1)$$

donde R es la distancia entre el sensor y el objeto, c es la velocidad de la luz (300.000 km/s), y t es el tiempo que medido entre la emisión y la recepción del pulso laser. El factor ½ viene dado por que el tiempo medido corresponde al tiempo de ida y vuelta del pulso láser.

Estos sistemas registran cada retorno y lo asignan a un valor de coordenadas (x,y,z) mediante la integración de varios sub-sistemas que componen el sistema LiDAR, por lo que son capaces de generar nubes de puntos densas en 3 dimensiones que describen detalladamente el terreno escaneado.

Los componentes que forman el sistema LiDAR y que permiten georreferenciar cada retorno son: Sistema de Posicionamiento Global (GPS), Unidad de Medida Inercial (IMU) y escáner láser [17].

El escáner láser a su vez está formado por las siguientes unidades: unidad de medida de distancia láser, escáner y unidad de control y procesamiento, que se sincroniza con el GPS y la IMU.

En la Figura 2.7 se muestra el diagrama de bloques completo de un sistema LiDAR

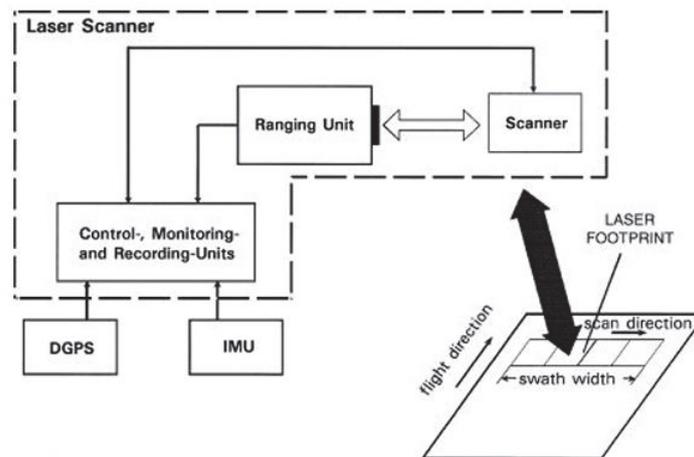


Figura 2.7. Diagrama de bloques de un sistema LiDAR.

El Sistema GPS permite conocer la posición a la que se encuentra el sensor en cada momento durante el vuelo, mientras que la Unidad de Medida Inercial registra los giros, rotaciones e inclinaciones realizadas por el vehículo aéreo. Las coordenadas de cada retorno se pueden deducir conociendo las coordenadas exactas del sensor (proporcionadas por el Sistema GPS), la distancia a la que se encuentra el objeto (proporcionada por la unidad de escáner

laser) y la orientación del sensor al momento de transmitir el pulso (proporcionada por la Unidad de Medida Inercial).

La información de las coordenadas de cada retorno (que incluye la localización y la altura) se almacena junto con los siguientes atributos adicionales [18]:

- Intensidad: indica la fortaleza de la devolución del pulso laser que genero el sensor al reflejarse
- Numero de retorno: indica el número de retorno de un pulso. Cuando un pulso láser es reflejado, dependiendo de la superficie en la que incide puede reflejarse un mayor número de veces.
- Cantidad de retornos: para un pulso recibido, indica el número total de devoluciones.
- Clasificación de puntos: indica en qué tipo de clase se reflejó el láser. Las clases pueden ser terreno, vegetación, agua, etc. Su clasificación sigue un formato específico. En la Figura 2.8 se muestra el formato de clasificación LAS 1.1 a 1.4 [19]. En el caso de este TFG el proveedor de los datos LiDAR no proporciona esta información.

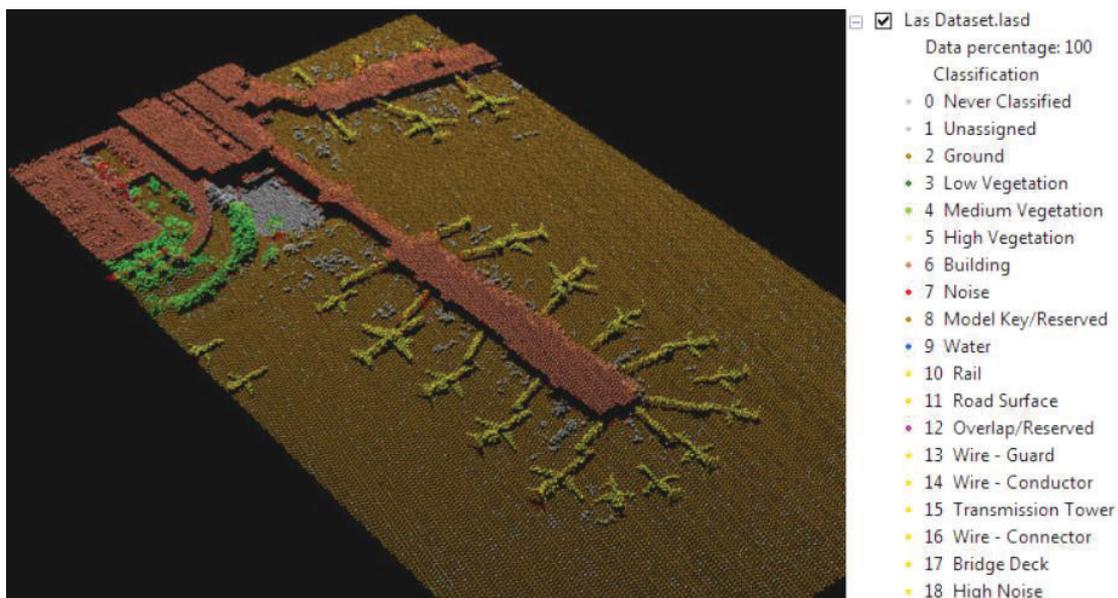


Figura 2.8. Clasificación de la nube de puntos [19].

- RGB: los datos LiDAR en ocasiones se atribuyen a bandas RGB o el sensor incorpora una cámara en la región visible del espectro electromagnético.
- Tiempo del GPS: indica la fecha en la que se emitió el pulso laser.
- Ángulo de escaneo: indica el ángulo al que se registra un retorno. Si es el ángulo es de 0 grados, quiere decir que el pulso recibido esta justo debajo del sensor, mientras que si es de -90 o +90 grados, indica que el pulso reflejado está en el lado izquierdo o

derecho del avión o dron respectivamente. Los sistemas LiDAR generalmente trabajan con ángulos de escaneo de -30 a +30 grados.

- Dirección de escaneo: indica la dirección en la que viaja el espejo de escaneo. Un valor de 1 indica un escaneo de izquierda a derecha, mientras que un valor de 0 indica un escaneo de derecha a izquierda.

2.4 Sensores de teledetección

A la hora de recopilar datos para su posterior análisis, el proceso de selección de los sensores es una etapa muy importante. En este el presente Trabajo de Fin de Grado, los sensores elegidos para este fin fueron el sensor MicaSense RedEdge Mx dual para imágenes multiespectrales y el sensor Zenmuse L1 para datos LiDAR. Ambos sensores fueron integrados en el dron el Dron DJI Matrice 300 RTK.

2.4.1 Dron DJI Matrice 300 RTK

El DJI Matrice 300 RTK es un dron diseñado para aplicaciones profesionales de alta precisión en diversos campos como topografía, silvicultura, agricultura de precisión y estudios ambientales. Su diseño modular permite integrar múltiples sensores simultáneamente, proporcionando flexibilidad y eficiencia. Algunas de las características más importantes del dron se recogen a continuación [20]:

- Autonomía de vuelo de hasta 55 minutos, gracias a su alimentación con dos baterías TB60 intercambiables en caliente.
- Dispone de 6 sensores anticolidión cubriendo los 360 grados.
- Permite la posibilidad de que dos personas controlen el equipo simultáneamente gracias al mando DJI Smart Controller Enterprise en caso de que uno de los dos pierda la conexión.
- Alcance operativo de 15 km, no obstante, gracias a que el dron puede ser controlado por dos personas simultáneamente, cuando este se acerca al rango de operabilidad (15 km), puede ser controlado por el segundo piloto y alcanzar distancias mayores.
- Capacidad de vuelo automática y periódica siguiendo un objeto o a un punto concreto determinado mediante IA.
- Carga de peso de 2.7 kg, permitiendo la integración de otros equipos para numerosas aplicaciones.

2.4.2 Sensor MicaSense RedEdge-Mx dual

El sensor MicaSense RedEdge dual combina dos cámaras multiespectrales, la RedEdge-Mx y la RedEdge Mx-Blue, con lo que consigue captar diez bandas espectrales. Las especificaciones de las bandas captadas por cada cámara se muestran a continuación [21][22], [23]:

- RedEdge- Mx
 - Azul (475 nm, BW 20 nm)
 - Verde (560 nm, BW 20 nm)
 - Rojo (668 nm, BW 10 nm)
 - Borde rojo 717 nm, BW 10 nm)
 - Infrarrojo cercano (840 nm, BW 40 nm)
- RedEdge Mx-Blue
 - Azul costero (444 nm, BW 28 nm)
 - Verde (531 nm, BW 14 nm)
 - Rojo (650 nm, BW 16 nm)
 - Borde rojo (705 nm, BW 10 nm)
 - Borde rojo (740 nm, BW 18 nm)

En la Figura 2.9 se puede observar las bandas espectrales con las que cuenta el cada sensor en comparación con otros satélites como Sentinel 2A y Landsat 8 [24].

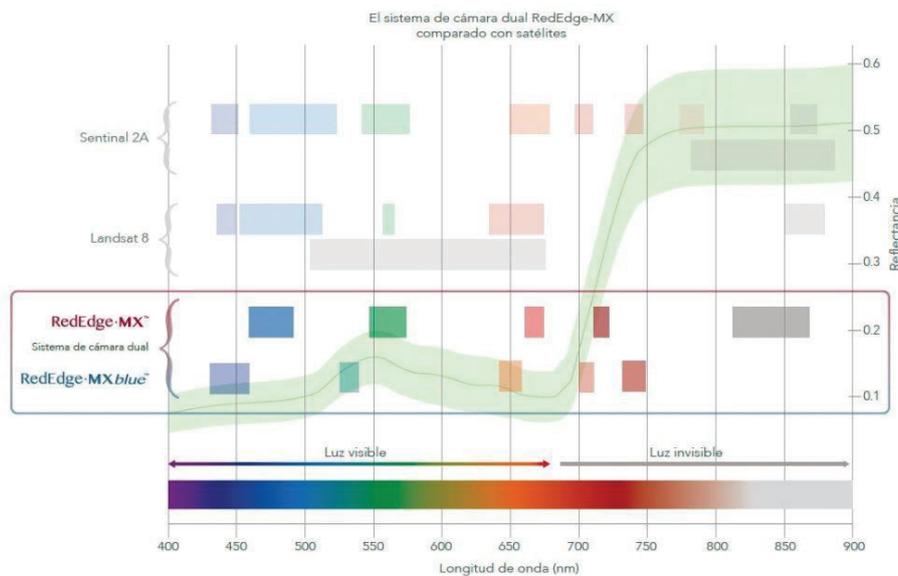


Figura 2.9. Bandas espectrales del sensor MicaSense RedEdge.Mx Dual [24].

Este sensor cuenta con una resolución de 1280 x 960 píxeles, obteniendo resoluciones espaciales típicas de 8 cm/píxel a 120 metros de altura.

Con las especificaciones técnicas mencionadas, el uso del sensor puede estar destinados a numerosas aplicaciones en el ámbito medioambiental, tales como el cálculo de índices de vegetación NDVI (Normalized Difference Vegetation Index) o NDRE (Normalized Difference Red Edge), el análisis de la salud vegetal y estrés hídrico o el monitoreo de biomasa y dinámica de crecimiento vegetal.

2.4.3 Sensor Zenmuse L1

El sensor Zenmuse L1 integra un módulo LiDAR, una cámara RGB y un sistema GNSS/IMU para generar nubes de puntos 3D georreferenciadas de alta precisión.

La Unidad de Medición Inercial (IMU) es capaz de medir la aceleración en los 3 ejes y la velocidad angular en tiempo real, permitiendo calcular la velocidad, posición y ángulo de la aeronave con una precisión de 0,025° (rotación/inclinación) y 0,15° (guiñada). Además, cuenta con un receptor GNSS de doble frecuencia y un estabilizador de 3 ejes, por lo que cualquier movimiento de rotación inadvertido del dron (inclinación, rotación y paneo) se estabiliza dinámicamente en $\pm 0,01^\circ$ [25].

La cámara RGB que integra el sistema se trata de un sensor CMOS de 20 MP y 1 pulgada, lo que permite obtener nubes de puntos 3D en color real.

Algunas de las especificaciones técnicas del sensor se recogen a continuación [26]:

- Frecuencia de pulsos: 240.000 pulsos por segundo (240 KHz).
- Ángulos de escaneo: 70° (horizontal), 4° (vertical).
- Altura máxima de vuelo: 450 metros, aunque la típica esta entre 50 y 150 metros.
- Tamaño de la huella: 5-10 cm a una altura de 50 metros.
- Densidad: 240 puntos por metro cuadrado a 50 metros de altura, aunque depende de la velocidad de vuelo.
- Precisión: ± 10 cm (horizontal) ± 5 cm (vertical).

Capítulo 3 Técnicas de procesado de datos de teledetección

En este capítulo se introducen las técnicas que se han utilizado para el procesado de los datos multiespectrales y LiDAR. Se analizan las técnicas de preprocesado, tanto de los datos multiespectrales como las que se han aplicado a los datos LiDAR.

3.1 Introducción

La obtención de cartografía vegetal a partir de datos multiespectrales y LiDAR requiere la aplicación de diferentes técnicas de tratamiento sobre las imágenes. Estas técnicas se conocen como preprocesado y procesado.

El preprocesado se refiere al conjunto de transformaciones y correcciones necesarias para preparar los datos para su posterior análisis. En el caso de los datos LiDAR, comprende procesos como la generación de los diferentes modelos digitales de terreno y elevación (DEM y DSM) o el modelo de dosel arbóreo (CHM). Por otra parte, el preprocesado de datos multiespectrales comprende principalmente técnicas de corrección, tales como la corrección radiométrica, la corrección atmosférica, la corrección geométrica u ortorrectificación o las correcciones de ruido y bandas defectuosas.

El procesado de los datos implica la transformación de la información preprocesada para la extracción de información útil para el usuario y su análisis. Las técnicas de procesado aplicadas a datos multiespectrales incluyen la clasificación de las imágenes registradas o la generación de índices de vegetación como NDVI (Normalized Difference Vegetation Index) o MSAVI (Modified Soil-Adjusted Vegetation Index). Las técnicas de procesado en datos LiDAR incluyen la segmentación y la extracción de características de la parcela.

En el presente Trabajo de Fin de Grado se han estudiado técnicas de preprocesado y procesado tanto de datos multiespectrales como de datos LiDAR, para su posterior aplicación con los datos obtenidos de la parcela del Parque Nacional del Teide. La metodología seguida se muestra en la Figura 3.1

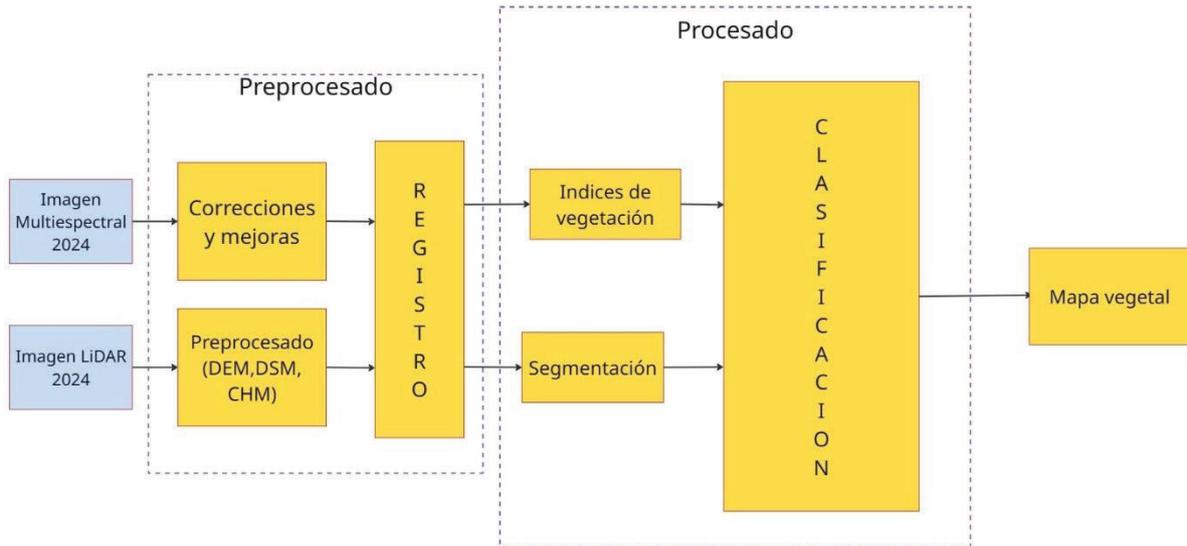


Figura 3.1 Metodología seguida.

3.2 Preprocesado de datos

Para el estudio de las diferentes técnicas de preprocesado de datos, se ha decidido realizar, por una parte, el estudio en los datos LiDAR y, por otra, el estudio en los datos multiespectrales, puesto que las técnicas aplicadas varían en función de los datos que se estén manipulando.

3.2.1 Preprocesado de datos LiDAR

El preprocesado de datos LiDAR tiene como principal objetivo la obtención del modelo de dosel arbóreo, es decir, la altura de la vegetación forestal tras eliminar la altitud del terreno. Para ello son necesarias una serie de etapas previas que se recogen en la Figura 3.2.

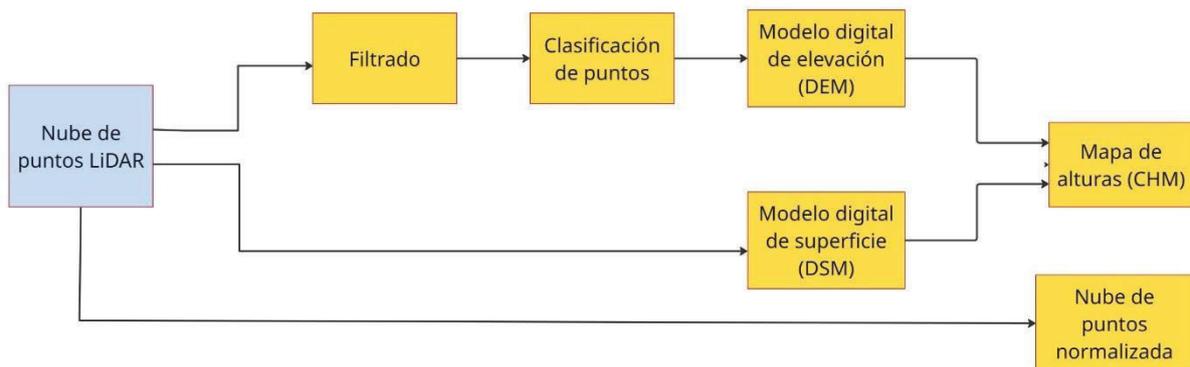


Figura 3.2 Diagrama de bloques de preprocesado LiDAR.

Filtrado de la nube de puntos

El primer paso previo a la aplicación de cualquier técnica es el filtrado de la nube de puntos. Es muy común que las nubes de puntos contengan valores anómalos que no representan las

características del terreno debido a factores externos o internos del sistema y que afectan a la calidad de los datos y de su posterior procesado y análisis [4].

Es por ello por lo que es indispensable el filtrado de aquellos puntos que representan valores incorrectos. Usualmente se aplican filtros en función de la altura, en los cuales se eliminan los puntos que se encuentran por encima de cierto valor umbral especificado previamente.

Clasificación de la nube de puntos

Previo a la generación del modelo digital de elevación, es necesario que los puntos correspondientes al suelo estén claramente identificados. En ciertos archivos, las nubes de puntos en formato .las, que contienen toda la información del vuelo LiDAR (número de retorno, intensidad del retorno, ángulo de escaneo...), se encuentran clasificadas. En ese caso, la clase 2 indica los retornos clasificados como suelo. No obstante, salvo que el proveedor de datos haga este preprocesado, los puntos LiDAR pueden no venir clasificados, siendo indispensable clasificar los puntos correspondientes al suelo para la generación del modelo digital de elevación de terreno [4].

Para llevar a cabo la clasificación, uno de los algoritmos más complejos y que obtiene mejores resultados es el algoritmo de filtrado IPTD (Iterative Progressive TIN densification) [27]. Este algoritmo se realiza en tres pasos. Primero se obtiene una cantidad de puntos que potencialmente pueden ser suelo, escogiendo aquellos que se encuentren a una altura considerablemente baja en una ventana que se va desplazando a lo largo de la imagen. Posteriormente se crea una red de triángulos, conocida como TIN (Traingulated Irregular Network), con aquellos puntos seleccionados. Finalmente se realiza una iteración mediante la cual se evalúan nuevos puntos vecinos para ver si pueden añadirse al TIN inicial. Existe un paso intermedio en el cual se calcula la distancia correspondiente entre el punto evaluado y el triángulo, y el ángulo máximo existente entre el punto y los vértices del triángulo generado por el TIN. Estos valores son comparados con los umbrales de distancia y ángulo de iteración, que se fijan previamente. Si son menores que el umbral, el punto se clasifica como punto de suelo.

En la Figura 3.3 se muestran gráficamente las distancias y ángulos evaluados por el algoritmo en un triángulo de la red TIN.

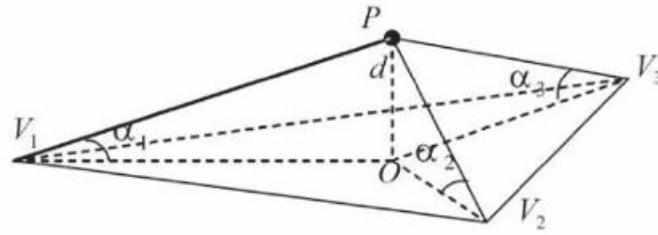


Figura 3.3. Distancia y ángulos evaluados [28].

El proceso de clasificación de los puntos se muestra en la Figura 3.4. En (a) se encuentran los puntos que se quieren clasificar, en (b) se seleccionan los puntos que pueden ser potencialmente suelo, en (c) se eliminan los puntos que se clasificaron como suelo potencialmente y en (d) se muestran los puntos correctamente clasificados [27].

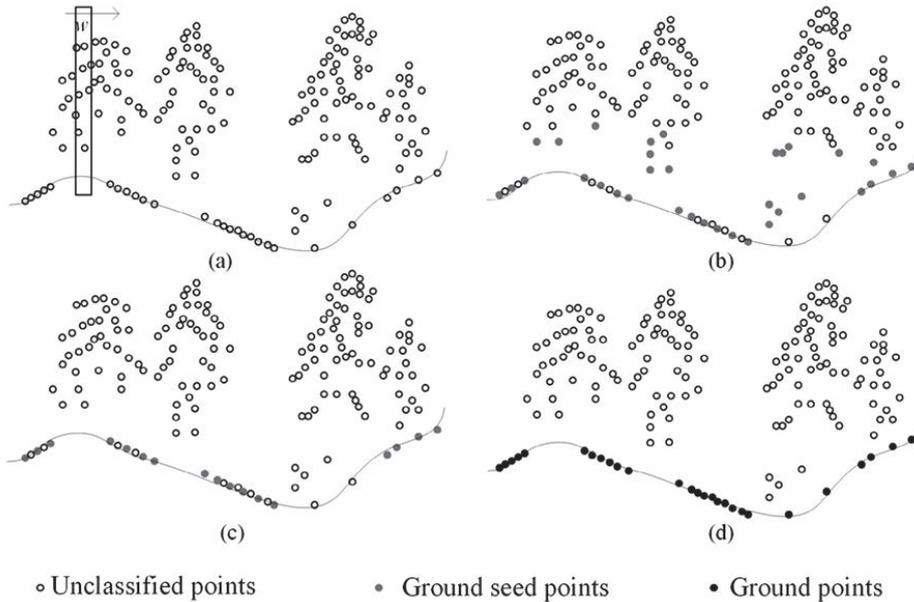


Figura 3.4. Proceso de clasificación de puntos de suelo [27].

Modelo digital de elevación (DEM)

El DEM es un modelo digital que representa la superficie del terreno desnuda, es decir, sin árboles, edificios o estructuras, simplemente suelo [4], [29]. Para la obtención de tanto el Modelo Digital de Elevación (DEM) como del Modelo Digital de Superficie a partir de una nube de puntos, se deben realizar fases de interpolación [30], [31], [32].

En el contexto matemático, se denomina interpolación a la obtención de nuevos puntos partiendo del conocimiento de un subconjunto de puntos [33]. Aplicado al procesamiento de

imágenes, los métodos de interpolación permiten generar superficies continuas a partir de medidas en localizaciones puntuales, como en el caso que nos ocupa.

Los métodos de interpolación espacial se pueden clasificar en deterministas, los cuales generan superficies continuas mediante el grado de similitud o suavizado; y en geoestadísticos, que generan las superficies continuas a partir de las propiedades estadísticas de los datos de partida. Un ejemplo de interpolación se muestra en la Figura 3.5. Se pretende estimar el punto intermedio entre el punto ubicado en [0,0] y el del [1,1] [33].

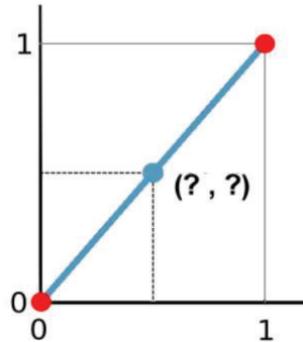


Figura 3.5. Ejemplo de interpolación.

Para determinar el valor del punto intermedio se puede usar la siguiente expresión correspondiente a una interpolación lineal, mediante la cual el valor final será 0.5 [33]:

$$y = y_a + (x - x_a) * \frac{y_b - y_a}{x_b - x_a} \quad (3.1)$$

En este Trabajo de Fin de Grado, se parte de una nube de puntos, en la cual se encuentran una gran cantidad de puntos discretos, y se pretende obtener una superficie regular mediante la interpolación que represente la elevación del terreno estudiado (DEM). Algunos de los métodos de interpolación más usados en el procesamiento de imágenes son los siguientes [34], [35]:

IDW (Inverse Distance Weigh)

El método de interpolación de Distancia Inversa Ponderada asume que los puntos más cercanos entre sí están son más parecidos que los que se encuentran más alejados. Cada punto contribuye a la interpolación con un valor de ponderación que disminuye con la distancia [33], [36].

En la Figura 3.6 se muestra un ejemplo de las ponderaciones asignadas a los puntos en función de la distancia [36].

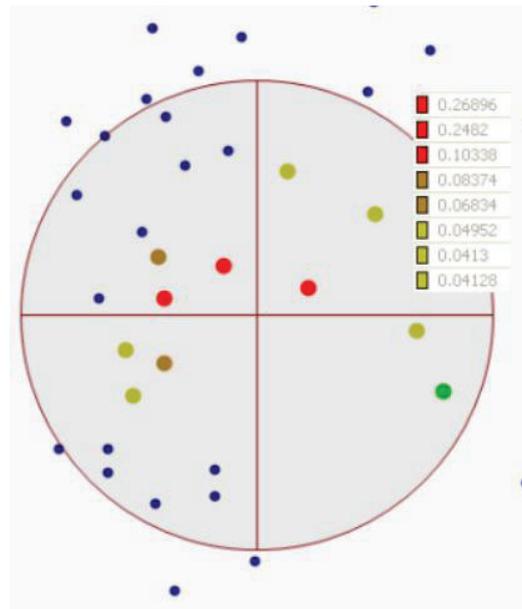


Figura 3.6. Ponderación de cada punto [36].

La expresión matemática usada en la interpolación IDW es la siguiente [36]:

$$z_j = \frac{\sum_i \frac{z_i}{d_{ij}^B}}{\sum_i \frac{1}{d_{ij}^B}} \quad (3.2)$$

donde z_j es el valor interpolado, z_i es el valor conocido en el punto, d_{ij} es la distancia entre los dos puntos y B es un exponente de ponderación, que controla la forma en la que el peso disminuye con la distancia. Cuando este exponente es igual a 0, el valor estimado será la media aritmética de los datos, mientras que si vale 2, el valor decae con el cuadrado de la distancia.

Este método permite una generación sencilla del modelo digital de elevaciones, no obstante, presenta limitaciones al no tener en cuenta tendencias espaciales y al depender del valor de B , generando superficies topográficas muy diferentes en función del valor del parámetro escogido.

Kriging

El kriging es un método de interpolación que, al igual que en el IDW, supone que la influencia de los puntos más lejanos es menor que la de los puntos vecinos. Sin embargo, se diferencia del IDW en que este define la altitud como una variable regionalizada, suponiendo por tanto que la variación espacial puede ser explicada parcialmente por funciones de autocorrelación espacial [37].

Este método estima la influencia de los puntos mediante la semivarianza entre datos separados por distancias diferentes. Para ello hace uso de una función que relaciona la

semivarianza con la distancia, denominada semivariograma, cuya expresión se muestra a continuación [37]:

$$\gamma(h) = \frac{1}{2*n} \sum_i (z_i - z_{i+h}) \quad (3.3)$$

donde γ es la semivarianza y n es el número de pares de valores separados por una distancia h .

El Kriging es un método óptimo para aquellas distribuciones que tienen grandes componentes estocásticas, sin embargo, para la generación de modelos digitales de elevaciones supone dificultades. Los patrones de variación de la elevación deben ser homogéneos, condición que no suele cumplirse en este método, por lo que su uso para la construcción de modelos digitales de elevaciones puede provocar posibles imprecisiones en el tratamiento de discontinuidades topográficas y de cambios bruscos en el terreno.

TIN (*Triangulated Irregular Network*)

La interpolación TIN es un método basado en una red de triángulos creada a partir de puntos conocidos que cubre el terreno de forma completa. Cada triángulo define una superficie del terreno y todos ellos están conectados entre sí. La generación de la red irregular de triángulos se realiza mediante un algoritmo conocido como triangulación de Delaunay. En la Figura 3.7 se muestra un ejemplo de una red TIN sobre un terreno [38], [39].

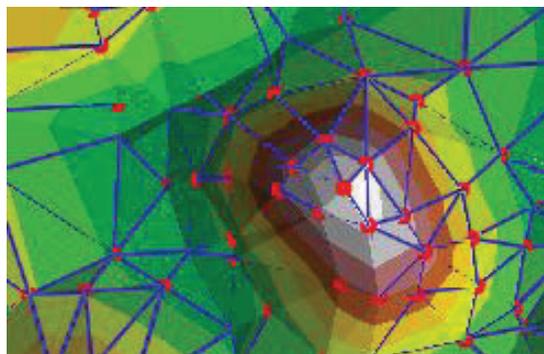


Figura 3.7. Red TIN [39].

Una vez generada la red de triángulos, se realiza el proceso de interpolación. Cada vértice del triángulo contiene un valor X, Y, Z , mediante el cual se puede obtener un modelo de regresión $Z = AX + BY + C$, que permite interpolar la variable Z en cualquier punto del triángulo. Los valores finales interpolados en cada triángulo están acotados por sus vértices. En la Figura 3.8 se muestra la interpolación en un triángulo de la red TIN.

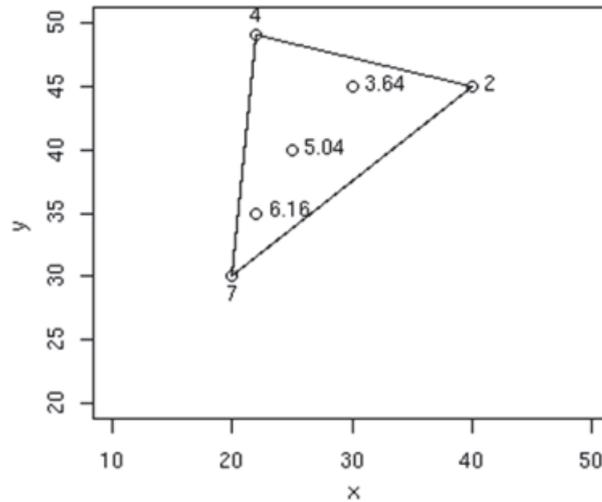


Figura 3.8. Interpolación de valores dentro de un triángulo de la red TIN.

Este método de interpolación es óptimo para la generación de modelos digitales de elevación y de superficie, obteniendo muy buenos resultados en terrenos con discontinuidades o pendientes abruptas.

En la Figura 3.9 se muestra el resultado de la generación de un modelo digital de elevación a partir de una nube de puntos para una parcela de vegetación usando el método de interpolación TIN.

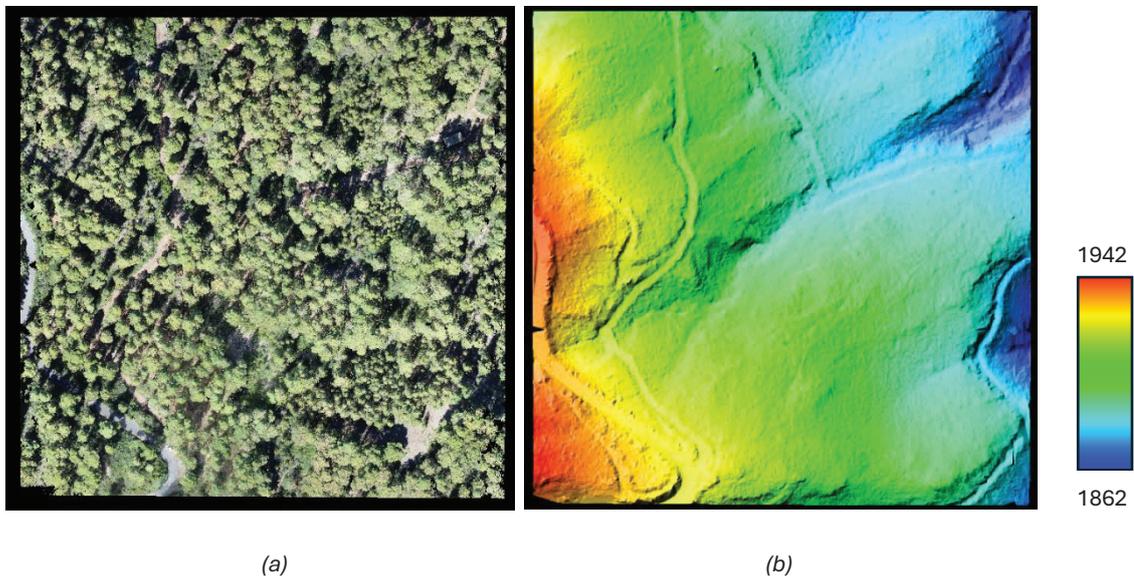


Figura 3.9. (a) Nube de puntos representada en color natural. (b) Modelo digital de elevación.

Modelo Digital de Superficie (DSM)

El DSM es un modelo digital que representa la superficie del terreno. A diferencia del DEM, que representa el suelo desnudo, el DSM contiene cualquier objeto que se encuentra en la superficie (vegetación, edificios, infraestructuras artificiales). El proceso de generación del DSM no requiere clasificación previa de los puntos de suelo, como en el caso del DEM, ya que interesan los retornos provenientes de todo tipo de clases. Los métodos de interpolación que se pueden aplicar coinciden con el DEM [40] [4].

En la Figura 3.10 se muestra el resultado de la generación del modelo digital de superficie en la misma parcela que el caso anterior.

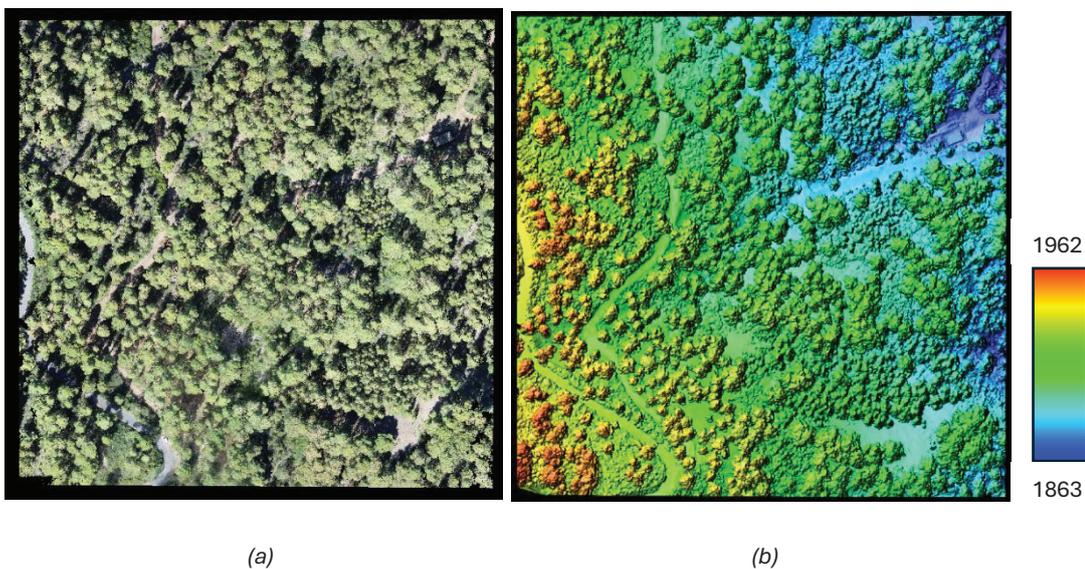


Figura 3.10. (a) Nube de puntos representada en color natural. (b) Modelo digital de superficie.

Modelo de dosel arbóreo (CHM)

El CHM (*Canopy Height Model*) es un modelo que representa la altura de los objetos sobre el suelo. El DEM y el DSM, representan los valores de altitud del terreno y de los objetos que se encuentran en la zona respectivamente, mientras que el CHM representa la altura de cada objeto. Si un árbol se tiene una altitud de 1530 metros y el suelo que se encuentra bajo él está a una altitud de 1500 metros, la altura del árbol es de 30 metros. En ese caso, la altitud del árbol es proporcionada por el DSM, mientras que altitud del suelo la proporciona el DEM [41] [4].

El CHM, por tanto, es una información muy potente en el análisis forestal, puesto que ofrece la posibilidad de obtener la altura individual de cada objeto del terreno, incluso en condiciones adversas como pendientes abruptas.

La forma de obtener, por tanto, el CHM consiste en calcular la diferencia entre el DSM y el DEM. En la Figura 3.11 se puede observar como la diferencia entre ambos modelos da como resultado un modelo normalizado que contiene la altura de cada objeto, que sería el CHM, mientras que en la Figura 3.12 se muestra el CHM sobre la nube de puntos anterior [4].

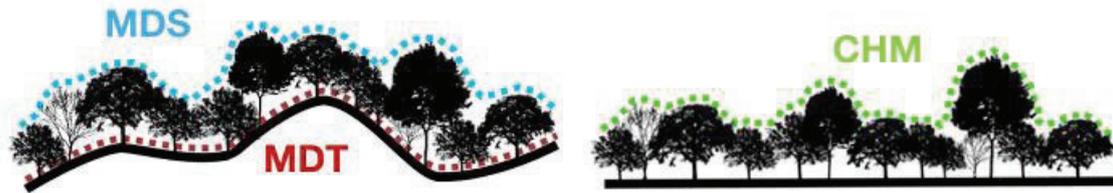


Figura 3.11. Obtención del CHM.

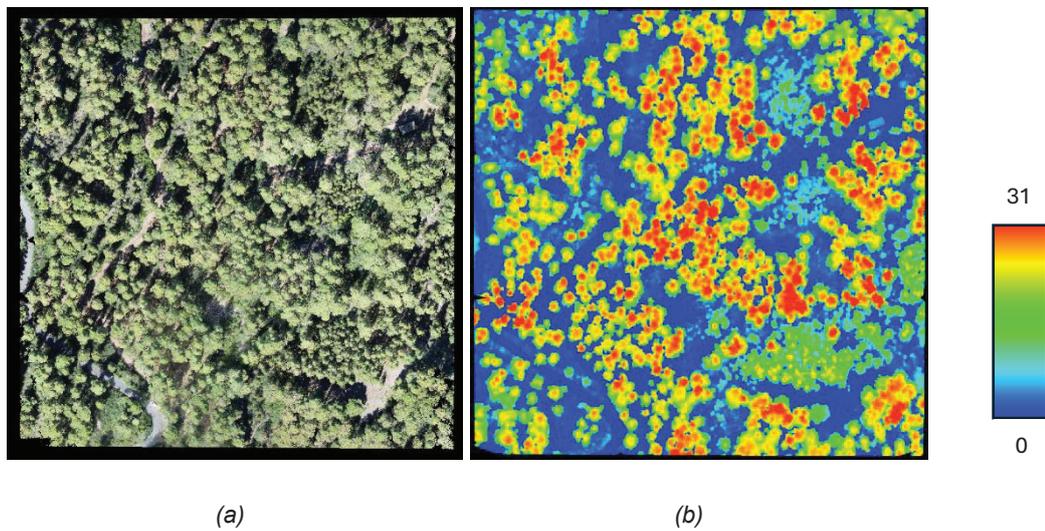


Figura 3.12. (a) Nube de puntos representada en color natural. (b) Modelo de dosel arbóreo.

3.2.2 Preprocesado de datos multiespectrales

Los sensores multiespectrales capturan la energía reflejada por un objeto en diferentes longitudes de onda y la convierten en un valor digital. En el proceso de captura y registro, los datos captados sufren alteraciones debido a diferentes factores tanto externos al sistema, véase la influencia de la atmósfera o la rotación de la Tierra (en el caso de los satélites), como internos, generados por el balanceo de la plataforma, la conversión de la energía en valores digitales o el ruido del sensor.

Para corregir estas alteraciones existen operaciones de corrección, que tienen como objetivo minimizar los errores radiométricos y geométricos producidos durante el proceso de adquisición de los datos [42], [43].

Corrección radiométrica

La corrección radiométrica es el proceso por el cual se modifican los valores digitales de la imagen con el objetivo de eliminar el efecto de las distorsiones. Estas se producen tanto por el proceso de captura del dato como por los efectos de la atmósfera.

El primer paso para la corrección radiométrica es la transformación del nivel digital a un valor de radiancia, que mide la intensidad de la energía. La relación entre esta energía y el nivel digital se establece mediante la siguiente recta mostrada en la Figura 3.13.

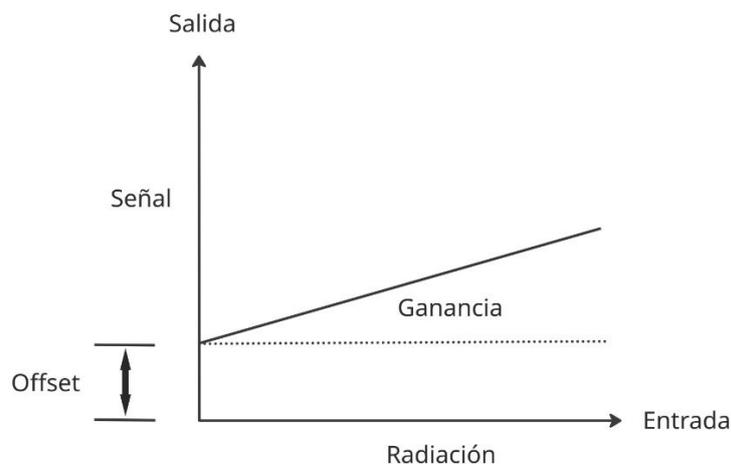


Figura 3.13 Recta de radiancia y nivel digital.

Los valores de radiancia y offset para cada una de las bandas dependen de la respuesta del sensor y son proporcionados por las empresas que tratan los datos, de forma que se pueden consultar que valor digital es el correspondiente para cada irradiancia.

Corrección atmosférica

Cuando se capturan datos a mediante un sensor a bordo de una plataforma aérea, entre el sensor y el objeto se encuentra la atmósfera, compuesta de gases que absorben parte de la energía reflejada, dispersan la onda o la emiten nueva energía que afecta a la que recibe el sensor. Todos estos procesos generan alteraciones que deben ser corregidas mediante correcciones atmosféricas, las cuales eliminan o disminuyen la influencia de la atmósfera en los datos capturados [44]. Para el caso de sensores embarcados en satélites ese proceso es importante, sin embargo, en datos dron la altura del vuelo es mínima y se hicieron calibraciones previas con blancos de referencia.

Corrección geométrica

Las herramientas de corrección geométrica se encargan de corregir la posición de los píxeles originales sin alterar sus valores digitales. Las distorsiones geométricas son producidas por el movimiento de la plataforma (alabeo, cabeceo, giro, variación de altura y velocidad), los efectos panorámicos y, en sistemas de teledetección satelitales, la rotación de la Tierra [43], [44].

Un procedimiento dentro de la corrección geométrica es la georreferenciación. Este proceso se encarga de ajustar la imagen a un sistema cartográfico de referencia. Para ello es necesario disponer de una imagen de referencia o un mapa cartográfico mediante el cual relacionar, por medio de puntos de control, la imagen a corregir y la imagen de referencia. Los puntos de control seleccionados deben ser aquellos que tengan en común ambas imágenes. Posteriormente se debe aplicar un polinomio de transformación para relacionar las posiciones originales y las de referencia, para finalmente transferir los valores de la imagen original a sus nuevas posiciones mediante técnicas de remuestreo. Los principales métodos de remuestreo se recogen a continuación [43]:

- Vecino más próximo (*nearest neighbor*): se asigna el valor del píxel más cercano de la imagen original a cada píxel de la imagen corregida.
- Interpolación bilineal (*bilinear interpolation*): el valor asignado a cada píxel es la media ponderada de los cuatro píxeles más cercanos de la imagen original.
- Convolución cúbica (*cubic convolution*): asigna a cada píxel un valor ponderado de los 16 valores de los píxeles más cercanos de la imagen original.

En el presente Trabajo de Fin de Grado no se han realizado este tipo de correcciones a la imagen multiespectral, puesto que ya viene georreferenciada. Sin embargo, dado que existen pequeños errores de localización y es necesario garantizar la superponibilidad de imágenes en estudios multitemporales o multisensor, en el siguiente apartado se detalla el proceso de registro para alinear los datos LiDAR y multiespectrales.

3.2.3 Registro de imágenes

El registro de imágenes es el proceso de ajustar y alinear diferentes imágenes capturadas en diferentes bandas del espectro electromagnético para que estén espacialmente alineadas. El registro se realiza aplicando transformaciones matemáticas a una imagen en función de la información de otra imagen, denominada imagen de base o referencia.

Generalmente, el registro de imágenes se realiza de forma manual mediante puntos de control. Estos puntos se colocan manualmente en zonas distintivas de ambas imágenes con

el fin de que cada uno de ellos sea utilizado para calcular los parámetros de las transformaciones geométricas.

A cada punto común en ambas imágenes se le mide la similitud mediante diferentes algoritmos de alineación de características. Posteriormente, se aplica un modelo de transformación a la imagen a deformar y finalmente se construye la imagen final mediante técnicas de remuestreo [45], [46].

En la Figura 3.14 se muestra el diagrama de bloques del proceso de registro simplificado.



Figura 3.14 Diagrama de bloques del registro.

Alineación de características

Para establecer los puntos de control, se puede optar por un proceso automático. En función de la forma en la que se mide la similitud entre los puntos de las dos imágenes, principalmente, se distinguen dos métodos: Cross Correlation (correlación cruzada) y Mutual Information (información mutua) [46].

Cross Correlation

El método de correlación cruzada se utiliza para medir la similitud entre dos imágenes, típicamente de la misma naturaleza. El proceso utiliza la mayoría de los píxeles de la imagen y partiendo del supuesto de que existe alguna relación matemática que genere información de similitud entre las dos imágenes, como por ejemplo una traslación. Para detectar la correspondencia existente entre dos imágenes se utiliza un coeficiente de correlación cruzada, que mide el grado de coincidencia de una imagen con otra basándose en la correlación entre ambas en una ventana. La expresión matemática correspondiente al coeficiente de correlación cruzada se muestra a continuación [47], [48]:

$$C(u, v) = \sum_x \sum_y f(x, y) * g(x - u, y - v) \quad (3.4)$$

siendo x,y las coordenadas de los píxeles y u,v el desplazamiento aplicado a la imagen g. El valor máximo del coeficiente indica el desplazamiento donde se alcanza la mayor similitud entre ambas imágenes, obteniendo una posible correspondencia. Para verificar la consistencia de esta correspondencia, se puede aplicar una verificación inversa, donde se calcula nuevamente la correlación utilizando como referencia la imagen objetivo y el punto

previamente identificado. Si el máximo vuelve a coincidir con la posición inicial, la correspondencia se considera válida.

Mutual Information

Este método para encontrar puntos de control es adecuado en imágenes de diferente naturaleza, por ejemplo multiespectral y LiDAR. Proporciona información acerca de la dependencia estadística de dos variables aleatorias, es decir, como de bien puede explicar una imagen a la otra [49], [50].

Se define la entropía como una medida de incertidumbre de una variable aleatoria. Se obtiene un valor máximo cuando las probabilidades de la variable aleatoria son iguales, mientras que el mínimo se da cuando una muestra tiene máxima probabilidad y el resto 0. Su expresión matemática es la siguiente [50]:

$$H(x) = \sum_x p(x) * \log(1/p(x)) = - \sum_x p(x) * \log(p(x)) \quad (3.5)$$

siendo $p(x)$ la función densidad de probabilidad, es decir, la probabilidad de que ocurra el evento x . Se define la entropía condicional de una variable aleatoria x sobre otra variable aleatoria y como [51]:

$$H(y/x) = \sum_x p(x,y) * \log(p(y/x)) \quad (3.6)$$

siendo $p(x,y)$ la probabilidad conjunta de x,y , es decir, la probabilidad de que los eventos x,y ocurran simultáneamente; y $p(y/x)$ la probabilidad condicionada de y,x , es decir, la probabilidad de que ocurra y una vez ha ocurrido x .

Finalmente, se defina la información mutua como la entropía relativa entre las funciones de densidad de probabilidad de dos variables aleatorias, cuya expresión es la siguiente [51]:

$$MI(x; y) = \sum_{x,y} p(x, y) * \log \left(\frac{p(x,y)}{p(x)*p(y)} \right) \quad (3.7)$$

También puede ser expresada en base a las entropías mediante [50]:

$$MI(x; y) = H(A) + H(B) - H(A, B) = H(A) - H(A/B) \quad (3.8)$$

Métodos de transformación

Posterior a la alineación de características, se debe transformar la imagen objetivo mediante un método de transformación. Principalmente existen, tres tipos de transformaciones dependiendo del tipo de distorsión que se le aplique a la imagen que se quiere registrar [45]:

- Transformaciones afines: este método se basa en la aplicación de técnicas de rotación, escalado y traslación de la imagen (RST). Cuenta con polinomios de transformación como los que se muestran a continuación:

$$\bullet \quad X = a_1 * x + a_2 * y + a_3 \quad (3.9)$$

$$\bullet \quad Y = b_1 * x + b_2 * y + b_3 \quad (3.10)$$

- Transformaciones polinómicas: utilizan polinomios de transformación con diferentes grados. En los de primer orden, el polinomio incluye un término de interacción XY que indica el grado de inclinación o shearing:

$$X = a_1 * x + a_2 * y + a_3 + a_4 * XY \quad (3.11)$$

$$Y = b_1 * x + b_2 * y + b_3 + b_4 * XY \quad (3.12)$$

- Transformaciones por splines o triangulación: utilizan interpolación local entre los puntos de control mediante una malla. Suele ser útil cuando las deformaciones existentes en la imagen no son uniformes.

Dependiendo de la cantidad de datos de la imagen que sean utilizados para la transformación, los métodos se pueden dividir en dos categorías [45]:

- Métodos globales: Usan todos los puntos de control creados para estimar los parámetros de transformación en la imagen entera.
- Métodos locales: dividen la imagen en diferentes sectores y los parámetros elegidos para la transformación dependen de cada sector.

Reconstrucción de la imagen

En esta parte del registro se aplican técnicas de remuestreo con el fin de obtener una imagen final. Cada píxel de la imagen representa un valor digital. Tras el registro, el valor de cada píxel debe ser trasladado a una nueva posición para su correcta alineación con la imagen de referencia. Las técnicas de remuestreo se encargan de construir la nueva imagen en función de los valores digitales de los píxeles de la imagen antes de ser transformada y la nueva posición de cada uno de ellos tras el registro. Para ello, existen diversas técnicas que se recogen a continuación y que ya se presentaron con anterioridad [45]:

- Vecino más cercano: usa el valor del píxel más cercano para asignar el valor del píxel de salida. Para ello, las coordenadas rectificadas de dicho píxel son transformadas al sistema de coordenadas previo. El píxel más cercano a las nuevas coordenadas retransformadas es el nuevo valor del píxel final.

- Interpolación bilineal: usa los niveles de intensidad de cuatro píxeles aplicando una ventana de 2x2. El valor del píxel se basa en la distancia entre las coordenadas retrasnformadas y los cuatro píxeles de la ventana.
 - Convolución cúbica: en este caso se realiza el mismo proceso que en el caso anterior, pero evaluando 16 píxeles en una ventana de 4x4. El valor del píxel se obtiene mediante un promedio aplicando una función cúbica a los 16 píxeles de la ventana.
- En la Figura 3.15 se muestra cada técnica de reconstrucción de la imagen.

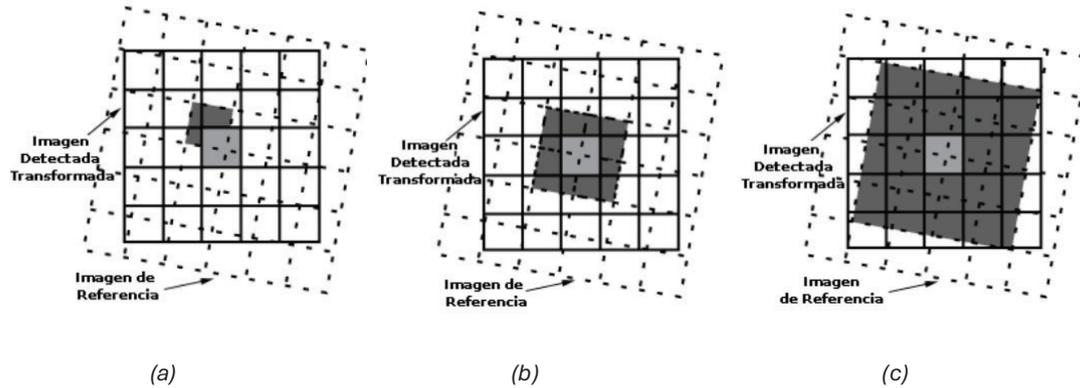


Figura 3.15. (a) Vecino más cercano. (b) Interpolación bilineal. (c) Convolución cúbica [45].

3.3 Procesado de datos multispectrales

El procesado de datos multispectrales incluye técnicas que transforman la información preprocesada para facilitar su análisis. En este apartado se recogen las diferentes técnicas que se aplican para el procesado de datos multispectrales.

3.3.1 Índices de vegetación

Los índices de vegetación son mapas del estado de la cubierta vegetal obtenidos a partir de la combinación matemática de los valores digitales correspondientes a dos o más bandas de una imagen multispectral. Su fundamento es aprovechar la reflectividad espectral de la vegetación para detectar su presencia y estado con una rápida inspección visual [52].

Como puede observarse en la Figura 3.16, la reflectividad de la vegetación es baja en las bandas visibles por el efecto de absorción de los pigmentos de clorofilas, xantofilas y carotenos, por lo que aproximadamente en los $0.5 \mu\text{m}$ y los $0.6 \mu\text{m}$ la vegetación absorbe gran parte de la radiación electromagnética dificultando el análisis. No obstante, en la región de infrarrojo cercano, la absorción de la radiación electromagnética por parte de la vegetación es menor debido a la estructura de la hoja, produciendo un pico en la reflectividad entre los $0.7 \mu\text{m}$ y los $1.45 \mu\text{m}$ [4].

Por ello, con el fin de obtener más información acerca de la salud de la vegetación, se decide combinar matemáticamente la información de bandas espectrales del visible con el infrarrojo cercano.

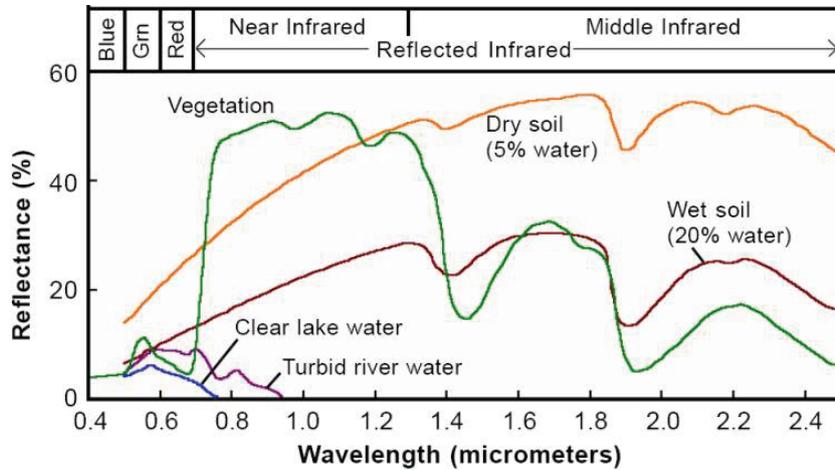


Figura 3.16. Firma espectral de la vegetación [53].

Existen numerosos índices de vegetación adecuados para el estudio de la salud de la vegetación. Los dos más interesantes para analizar en el caso que nos ocupa son los siguientes:

NDVI (Normalized Difference Vegetation Index)

El NDVI es uno de los índices de vegetación más usados en la teledetección, concretamente en estudios forestales y en la agricultura de precisión. Se trata de un indicador de biomasa fotosintéticamente activa, adecuado para estimar el vigor de la vegetación. El NDVI ayuda en la diferenciación entre vegetación y otros tipos de suelo [54], [55], [56].

Se calcula mediante la combinación matemática de los valores registrados en las bandas roja e infrarroja cercana, siguiendo la siguiente expresión:

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (3.13)$$

siendo NIR la banda de infrarrojo cercano y RED la banda roja.

La vegetación sana tiene menor reflectancia en la banda roja y mayor en el infrarrojo cercano, mientras que la vegetación enferma tiene menor reflectancia en el infrarrojo cercano y mayor en la banda roja en comparación con la vegetación sana, como puede observarse en la Figura 3.17 [56].

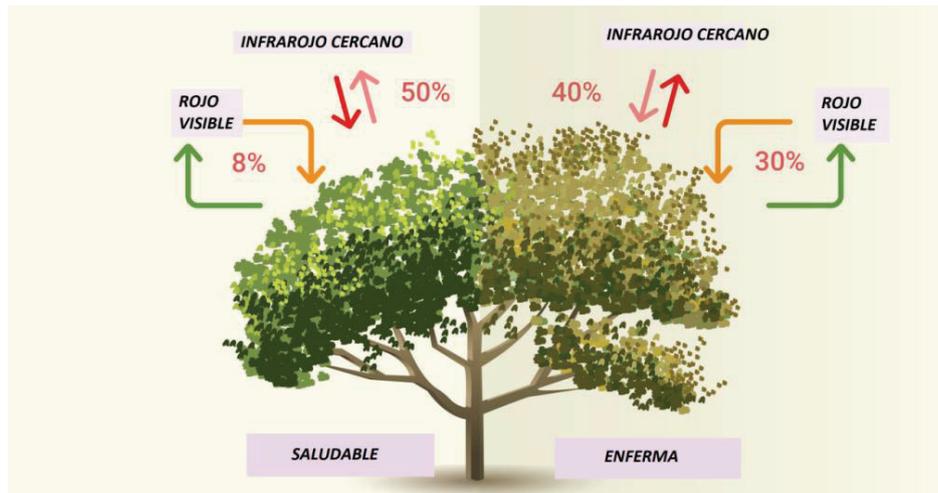


Figura 3.17. Reflectancia de la vegetación sana y enferma en las bandas roja e infrarroja cercana [56].

El índice de vegetación NDVI está normalizado, por lo que sus valores se encuentran entre -1 y 1. Valores comprendidos entre -1 y 0 indican suelo, agua o que la vegetación está muerta, mientras que los típicamente comprendidos entre 0.3 y 1 consideran la vegetación completamente sana [56].

MSAVI2 (Modified Soil Adjusted Vegetation Index)

El MSAVI2 o índice de vegetación ajustado al suelo modificado se utiliza como variante al NDVI, con el fin de ampliar sus límites de aplicación en zonas con mayor abundancia de suelo desnudo. Se suele utilizar para minimizar la influencia del suelo y aumentar el rango dinámico [57], [58], [59].

Al igual que el NDVI, utiliza los valores registrados en las bandas roja e infrarroja cercana, sin embargo, su expresión matemática es la siguiente:

$$MSAVI2 = \frac{\left(2 * NIR + 1 - \sqrt{\left((2 * NIR + 1)^2 - 8 * (NIR - RED)\right)}\right)}{2} \quad (3.14)$$

En agricultura el índice de vegetación MSAVI2 suele ser utilizado en etapas iniciales del cultivo, ya que el NDVI puede tener limitaciones en estas etapas a la hora de detectar el crecimiento inicial. Cuando la planta tiene un tamaño de pocos centímetros o en situaciones en las que hay una mayor proporción de suelo que de vegetación, el NDVI proporciona valores muy pequeños, siendo muy difícil la monitorización del avance de la vegetación [59].

Se ha seleccionado este índice pues en el Parque Nacional del Teide la vegetación es típicamente arbustiva y bastante dispersa, por lo que es más adecuado que el índice de vegetación NDVI.

3.3.2 Clasificación de imágenes multispectrales

El proceso de clasificación multispectral se basa en el análisis de los valores de reflectancia de las bandas espectrales de la imagen con el fin de identificar y separar las diferentes clases existentes en ella [4], [46]. En este TFG, las clases a discriminar serán principalmente los diferentes tipos de vegetación existentes.

Este proceso es llevado a cabo mediante una serie de algoritmos que utilizan la información espectral capturada por los sensores para asignar una clase a cada píxel de la imagen. Existen dos tipos de clasificación en rasgos generales: clasificaciones supervisadas y clasificaciones no supervisadas [4], [46].

Por una parte, en las clasificaciones no supervisadas las agrupaciones de píxeles con valores digitales comunes en las diferentes bandas son asignadas a una clase automáticamente por un software. Los algoritmos K-Means e IsoData son algunos de los más empleados en este tipo de clasificaciones [60].

Por otra parte, las clasificaciones supervisadas están guiadas por el usuario. Así, previo a la aplicación de un algoritmo de clasificación supervisada, se deben especificar regiones de entrenamiento (ROIs) correspondientes a píxeles representativos de cada clase con el fin de proporcionar al algoritmo de clasificación la información estadística sobre las diferentes clases existentes en la imagen [4], [46].

En el presente Trabajo de Fin de Grado, se han aplicado técnicas supervisadas, puesto que ofrecen mejores resultados al proporcionar más información al algoritmo.

Algoritmos de clasificación supervisada

En este subapartado se estudiarán los dos algoritmos de clasificación utilizados en este TFG, concretamente el ML (*Maximum Likelihood*) y SVM (*Support Vector Machine*), ya que han demostrado buenos resultados en estudios anteriores.

El algoritmo *Maximum Likelihood*, o también conocido como clasificador de máxima probabilidad, parte de la premisa de que los niveles digitales de cada clase siguen una distribución normal, por lo que cada una de ellas puede ser descrita mediante la función densidad de probabilidad [1], [61], [62].

Para ello utiliza el vector de medias y la matriz de varianza-covarianza de cada clase, permitiendo calcular la probabilidad de que un píxel con un determinado nivel digital pertenezca a una clase u otra. El proceso se realiza para cada clase y píxel de la imagen, por lo que aquella categoría que consiga maximizar la función densidad de probabilidad será a la cual se asigna el píxel examinado [62].

En la Figura 3.18 se muestra cómo se obtienen las probabilidades de que un píxel pertenezca a cada clase extendido a dos bandas diferentes de la imagen [62].

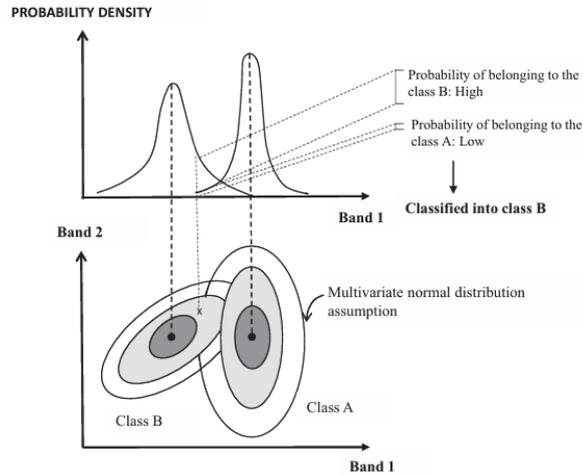


Figura 3.18. Probabilidades de que un píxel pertenezca a cada clase [62].

Este método es uno de los más empleados por su robustez y buenos resultados [62], [1].

Por otra parte, el algoritmo SVM, basado en máquinas de vectores de soporte, tiene como principal objetivo encontrar un hiperplano multidimensional para separar las diferentes clases, generado de forma iterativa con el fin de minimizar el error en función de las muestras de entrenamiento [63], [64].

El hiperplano es un plano de decisión que separa un conjunto de datos pertenecientes a clases diferentes. A las muestras de cada clase más cercanas al hiperplano se les denomina vectores de soporte.

En este método, se pretende aumentar el margen, es decir, el espacio que se encuentra entre los vectores de soporte de cada clase. Cuanto mayor se el margen, mayor será la separabilidad entre las diferentes clases y por tanto mejor será la clasificación.

En la Figura 3.19 se muestran los elementos de una clasificación por SVM [63].

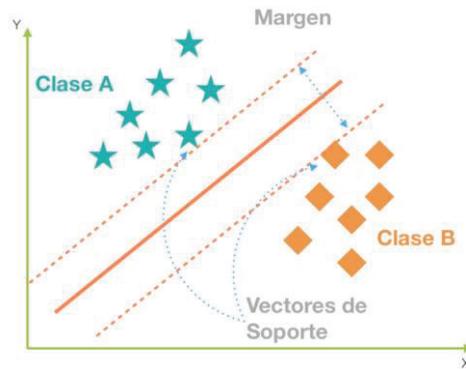


Figura 3.19. Elementos de una clasificación SVM [63].

En términos computacionales, el algoritmo SVM es más costoso que ML, por lo que el uso de cada uno puede depender de las necesidades de la clasificación. Se recomienda el uso de *Maximum Likelihood* en situaciones en las que se desee verificar la calidad de las regiones de entrenamiento creadas de forma rápida y efectiva, sin necesidad de una clasificación perfecta, mientras que, por otra parte, SVM está más destinado a casos en los que se requiere una mayor precisión en la clasificación por su alto costo computacional [1].

En este Trabajo de Fin de Grado, se probarán principalmente estos dos algoritmos, no obstante, también se realizarán pruebas con otros métodos como “*Spectral Angle Mapper*” (SAM) o “*Mahalanobis Distance*”.

Por una parte, el algoritmo SAM mide el ángulo entre el vector espectral de un píxel y el vector espectral de una clase de referencia. Es una herramienta robusta frente a variaciones de iluminación y condiciones atmosféricas.

Por otra parte, Mahalanobis Distance mide la distancia de una muestra a la media de una clase usando la varianza y la covarianza de los datos. El píxel es clasificado a la clase para la cual tiene menor distancia de Mahalanobis.

Separabilidad entre clases

Previo a la aplicación de un algoritmo de clasificación supervisado a partir de las regiones de entrenamiento, es recomendable la evaluación de la calidad de dichas regiones con el fin de verificar si son óptimas para la clasificación, es decir, si espectralmente son suficientemente diferentes para que sean discriminados. Esta verificación se realiza mediante el estudio de la separabilidad entre clases [65].

La separabilidad es una medida estadística que indica que tan fácil es diferenciar dos clases en una imagen usando la información espectral extraída de las regiones de entrenamiento creadas [65].

Para ello existen diferentes criterios cuantitativos que permiten evaluar la posibilidad de separar las clases de la imagen con valores numéricos. Entre los principales métodos se encuentra la distancia de Jeffries-Matusita y la Divergencia Transformada.

El método Jeffries-Matusita utiliza la distancia de Bhattacharyya para medir la similitud de dos variables con distribuciones de probabilidad. Los valores numéricos están acotados entre 0 y 2, siendo 0 el mínimo valor de separabilidad y, por tanto, un indicador de que las clases existentes no son separables, y 2 el máximo valor. A partir de 1.8 se consideran buenos valores de separabilidad espectral para la clasificación. Las expresiones de la distancia de Bhattacharyya y del índice de Jeffries-Matusita se muestra a continuación [65].

$$B = \frac{1}{8} * (u_i - u_j)^T * \frac{(C_i - C_j)^{-1}}{2} * (u_i - u_j) + \frac{1}{2} * \ln \left(\frac{\frac{|C_i + C_j|}{2}}{\sqrt{|C_j| |C_i|}} \right) \quad (3.15)$$

$$JM_{ij} = \sqrt{2 * (1 - e^{-B})} \quad (3.16)$$

donde B es la distancia de Bhattacharyya, JM_{ij} es el índice de Jeffries-Matusita, C_i y C_j son las matrices de varianza y covarianza y u_i y u_j son los vectores de medias.

Por otra parte, el método de la Divergencia Transformada utiliza una expresión en función de la divergencia estadística, mostrada a continuación [65].

$$D_{ij} = \frac{1}{2} tr \left((C_i - C_j) * (C_i^{-1} - C_j^{-1}) \right) + \frac{1}{2} tr \left((C_i^{-1} - C_j^{-1}) * (u_i - u_j) * (u_i - u_j)^T \right) \quad (3.17)$$

$$1DT_{ij} = 2 * \left(1 - e^{-\frac{D_{ij}}{8}} \right) \quad (3.18)$$

donde D_{ij} es la divergencia estadística, DT_{ij} es el índice de Divergencia Transformada y tr se refiere a la suma de los elementos de la diagonal de la matriz.

Matriz de confusión

Con el fin de evaluar los errores en la clasificación, se utilizan las matrices de confusión. En ellas se representa el grado de acierto de la imagen clasificada para cada clase en función de regiones de evaluación. Estas regiones se seleccionan siguiendo el mismo criterio que las regiones de entrenamiento usadas para clasificar la imagen, a diferencia de que estas no deben coincidir con las usadas para entrenar [65].

En la Tabla 3.1 se muestra la estructura de una matriz de confusión. El porcentaje de acierto de cada clase sigue la diagonal de la matriz, mientras que el resto de los elementos indican el porcentaje de error de la clasificación con las demás clases [65].

Tabla 3.1 Estructura de una matriz de confusión.

	Clase 1	Clase 2	Clase 3	Clase n	Total
Clase 1	X_{11}	X_{12}	X_{13}	X_{1n}	
Clase 2	X_{21}	X_{22}	X_{23}	X_{2n}	
Clase 3	X_{31}	X_{32}	X_{33}	X_{3n}	
Clase n	X_{n1}	X_{n2}	X_{n3}	X_{nn}	
Total					$\sum X_{ij}$

Para evaluar la precisión de la clasificación se pueden usar diferentes métricas de exactitud, aunque las más utilizadas son el Overall Accuracy y el coeficiente kappa.

El Overall Accuracy proporciona el porcentaje de exactitud global de la clasificación. Se define mediante la siguiente expresión [65].

$$OA = \frac{\sum_{i=1}^n x_{ii}}{\sum_{i=1}^n \sum_{j=1}^n x_{ij}} \quad (3.19)$$

donde x_{ii} es la diagonal de la matriz y x_{ij} cualquier posición de la matriz.

El coeficiente kappa es un estadístico que mide la coincidencia de las categorías de la imagen clasificada. La expresión se muestra a continuación [65].

$$k = \frac{n \cdot \sum_{i=1}^n x_{ii} - \sum_{i=1}^n x_{i+} x_{+i}}{n^2 - \sum_{i=1}^n x_{i+} x_{+i}} \quad (3.20)$$

donde n es el número de muestras y $x_{i+} x_{+i}$ es el producto total de filas y columnas.

3.4 Segmentación de nubes de puntos LiDAR

La segmentación es la técnica empleada habitualmente para el análisis a nivel de objeto individual. Consiste en separar los elementos de una imagen en varios grupos, donde cada uno puede simbolizar cosas diferentes. En el presente Trabajo de Fin de Grado, la segmentación será aplicada para separar individualmente cada retama de la parcela de vegetación usando datos LiDAR.

Existen numerosos algoritmos de segmentación cuyo empleo depende el contexto en el que se apliquen. En los casos que se realiza la segmentación en base al modelo 2D de dosel arbóreo CHM, uno de los algoritmos más empleados es el watershed, mientras que, si se realiza la segmentación en base a una nube de puntos 3D LiDAR, los algoritmos basados en crecimiento de regiones suelen ser bastante empleados.

El watershed es una técnica de segmentación que interpreta la imagen como un relieve topográfico. Inicia una inundación desde los puntos en los que se encuentran los mínimos

locales de la imagen, de forma que, en las fronteras, donde se unen varias inundaciones, se crea una pared que representa el borde entre varios segmentos de la imagen y donde generalmente, estas divisiones corresponden a los bordes de las copas de los árboles [66], [67], [68], [69].

En la Figura 3.20 se muestra un ejemplo de la segmentación utilizando el algoritmo watershed [66], [69].



Figura 3.20. Segmentación por watershed [28].

Por otra parte, los algoritmos de crecimiento de regiones se basan en criterios de similitud y proximidad entre los puntos de la nube [70], [71]. El software LiDAR360 implementa un algoritmo de crecimiento para la segmentación, en donde los máximos globales de la nube de puntos se seleccionan como puntos de semilla. A partir de los puntos seleccionados se examinan los puntos vecinos utilizando reglas de distancia crítica para decidir si un punto cercano pertenece a un árbol o a otro distinto [72], [28].

En la Figura 3.21 se muestra un ejemplo de la segmentación comparando las distancias entre cada punto [28].

Supongamos un punto A clasificado como semilla la semilla del Arbol1. Un punto B cuya distancia hasta el punto A sea mayor que un valor crítico indicado por parámetro será clasificado como parte de otro Arbol2. Por otra parte, si existe un punto C cuya distancia hasta el punto A es menor que el valor crítico, se estudia si pertenece al Arbol1 o al Arbol2, en función de si la distancia AC es mayor o menor que la distancia BC [72], [28].

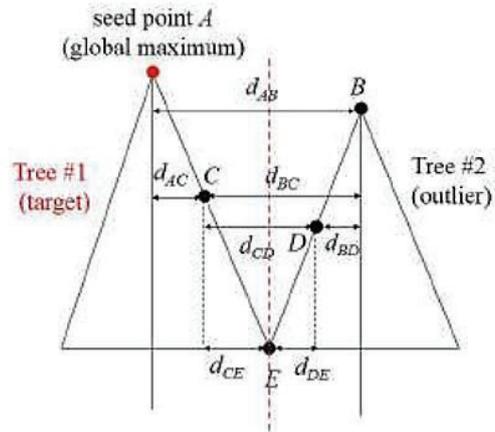


Figura 3.21. Segmentación por crecimiento de regiones [28].

Capítulo 4 Clasificación de la vegetación en el Parque Nacional del Teide

En este capítulo se describen los procedimientos llevados a cabo para el análisis de los datos obtenidos del Parque Nacional del Teide. Se aplican las diferentes técnicas de procesado a los datos multiespectrales y LiDAR para la generación de cartografía vegetal en la parcela seleccionada.

4.1 Zona de estudio

El Parque Nacional del Teide (Figura 4.1) fue el primer Parque Nacional declarado en Canarias en 1954. Se encuentra en el centro de la isla de Tenerife y se trata del Parque Nacional de mayor extensión de las islas Canarias con alrededor de 18.000 hectáreas. El volcán del Teide, siendo el pico más alto de España con 3.718 metros de altitud, le da nombre al Parque Nacional. En 2007 la UNESCO lo proclamó Patrimonio Mundial debido a su extraordinario valor natural, geológico y estético. El sistema volcánico del Teide aporta información de importante valor geológico sobre la evolución de las islas oceánicas, siendo el Teide la tercera estructura volcánica más alta del mundo desde su base en el fondo oceánico.



Figura 4.1 Parque Nacional del Teide.

En este entorno se dan condiciones climatológicas muy diferentes al resto del archipiélago canario, lo que permite gran biodiversidad de especies, surgimiento de flora endémica, plantas con adaptaciones únicas que les permiten sobrevivir en condiciones extremas de alta montaña

(bajas temperaturas, altas radiaciones solares, suelos volcánicos con escasos nutrientes, vientos y escasez de recursos hídricos).

Un singular ejemplo de dichas extraordinarias adaptaciones lo constituye la retama del Teide. Se trata de un arbusto vigoroso y ramificado de numerosas y largas ramas que se encuentra en ecosistemas de alta montaña. Su altura se encuentra entre 1.50 y 2.50 metros, aunque en condiciones óptimas (precipitaciones) pueden llegar a medir entre 3-4 metros. Asimismo, la singularidad de su adaptación a condiciones extremas la convierte en un recurso valioso para investigaciones sobre evolución, genética y ecología. En la Figura 4.2 se muestra un ejemplar de retama del Teide.



Figura 4.2 Retama del Teide.

En este contexto, en el presente Trabajo de Fin de Grado se propone realizar un análisis del estado de salud de la vegetación del Parque Nacional del Teide, prestando especial atención a las retamas y complementado con un estudio de los cambios en el entorno a lo largo de cinco años.

Para ello se usaron datos multiespectrales y LiDAR captados por un dron en una campaña de vuelo el 25 de mayo de 2024. La comparación se ha realizado con datos multiespectrales captados por dron en 2019.

La parcela elegida para realizar dicho análisis se encuentra en la zona sur del Parque Nacional del Teide. En ella existe una gran biodiversidad de flora, de las cuales se destacan especies vegetales como la retama del Teide, el rosalillo de cumbre y la hierba pajonera. En la Figura 4.3 se muestra la localización de la parcela en cuestión.



Figura 4.3 Localización de la parcela en el Parque Nacional del Teide.

4.2 Datos dron del Parque Nacional del Teide

Los datos captados por el dron en 2024 fueron obtenidos de una parcela correspondiente a la zona del sur del Parque Nacional del Teide. Para ello se realizó un vuelo para captar los datos multiespectrales y otro para los datos LiDAR.

Como se indicó, el dron usado se trata del DJI Matrice 300 RTK, diseñado para aplicaciones profesionales de alta precisión. A bordo del dron, para la obtención de los datos multiespectrales, se instaló el sensor MicaSense RedEdge-Mx dual. Por su parte, para los datos LiDAR se utilizó el sensor Zenmuse L1.

Los datos multiespectrales resultantes del vuelo dron contienen 10 bandas espectrales. El tamaño de píxel de la imagen se ajustó a 10 cm, por lo que la resolución espacial aproximadamente es de 100 píxeles por metro cuadrado. En la Figura 4.4 se puede observar la imagen multiespectral captada por el dron y la nube de puntos LiDAR captadas en 2024.

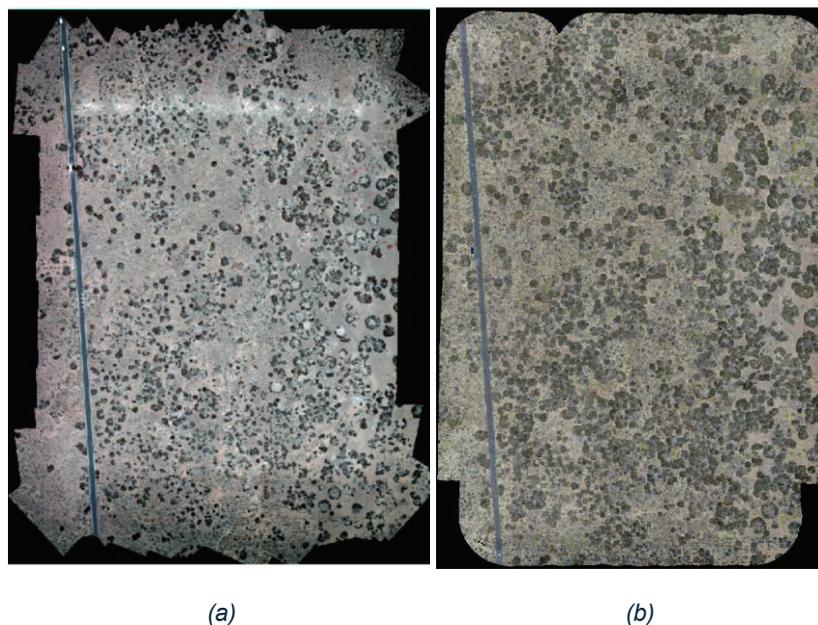


Figura 4.4 (a) Imagen multiespectral. (b) Nube de puntos LiDAR en formato RGB.

4.3 Metodología

Para la consecución de los objetivos del presente Trabajo de Fin de Grado se han seguido una serie de pasos que se detallan a continuación:

1. Obtención de datos multiespectrales y LiDAR.
2. Pre-procesado de datos LiDAR: se obtienen los modelos digitales de terreno y superficie (DEM y DSM) con el fin de generar el mapa de alturas normalizado (CHM) para su posterior registro.
3. Registro de los datos multiespectrales y LiDAR de 2024, así como de los datos previos correspondientes al vuelo realizado en 2019.
4. Generación de índices de vegetación a partir de los datos multiespectrales.
5. Clasificación de los datos obtenidos: se clasifican los datos multiespectrales y LiDAR registrados, así como los índices de vegetación por separado y fusionados.
6. Análisis de la estructura de las retamas: se analizarán tanto el área como el volumen de las retamas por medio de los datos LiDAR.
7. Extracción de resultados y análisis de cambios: se analizan los resultados obtenidos y se comparan con los resultados previos del año 2019.

En la Figura 4.5 se puede observar la metodología seguida en este TFG. Una parte de la metodología se explica en este capítulo, mientras que el análisis del área y volumen de las retamas en 2024, y los cambios obtenidos con respecto al año 2019 se muestra en el siguiente capítulo. (Capítulo 5).

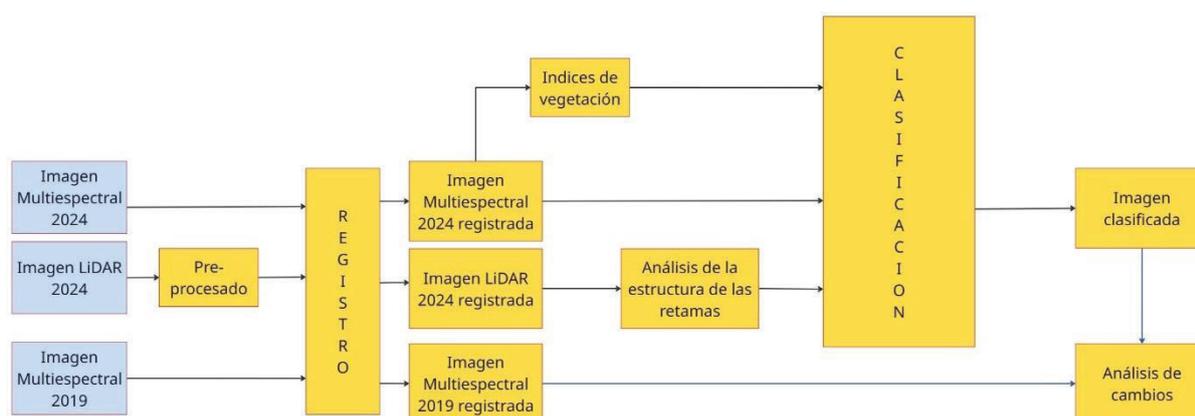


Figura 4.5 Metodología seguida para el procesamiento de los datos multiespectrales.

A continuación, se describe en detalle cada etapa de procesamiento.

4.3.1 Pre-procesado LiDAR

Usando como referencia la nube de puntos, el principal objetivo es generar el mapa de alturas CHM, el cual indica la altura normalizada de la vegetación, siendo el modelo más importante para el análisis vegetal. Para ello, es necesario obtener el modelo digital de elevación del terreno (DEM) y el modelo digital de superficie (DSM). El mapa de alturas CHM se obtiene mediante la diferencia entre el DSM, que contiene la altitud de la vegetación, y el DEM, que contiene por su parte la altitud del suelo. La diferencia entre estos dos modelos, por tanto, será la altura de la vegetación.

Para la obtención de los diferentes modelos digitales se hizo uso del software LiDAR360. Este software permite obtener dichos modelos en función de diferentes parámetros.

Previo a la generación del DEM, es necesario que los puntos LiDAR procedentes del suelo estén clasificados, puesto que para generar el DEM, el software se encarga de filtrar todos los puntos no correspondientes al suelo. En algunos archivos LiDAR los puntos vienen clasificados. En el caso que nos ocupa, los datos LiDAR no estaban clasificados, por lo que se hizo uso del software LiDAR360 para clasificar los puntos de suelo.

El procedimiento seguido para la obtención del mapa de alturas se muestra en un diagrama de bloques en la Figura 4.6.

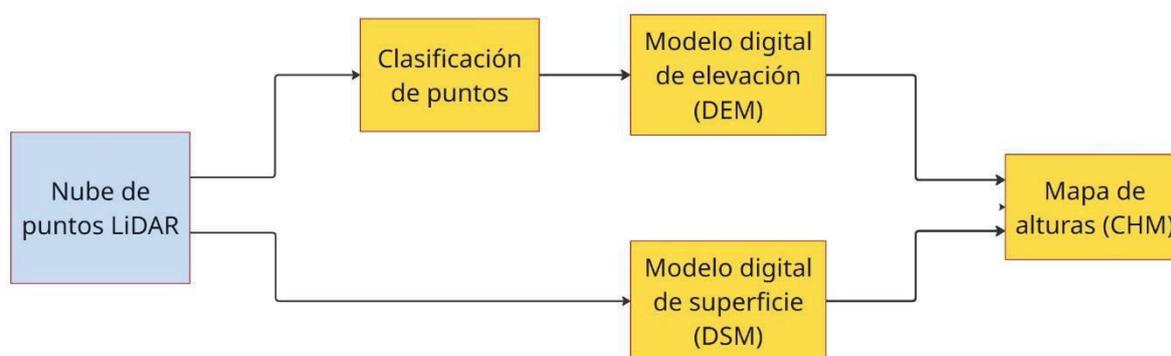


Figura 4.6 Diagrama de bloques del pre-procesado LiDAR.

El software LiDAR360 contiene una herramienta llamada “*Classify Ground Points*”, la cual clasifica los puntos resultantes de la nube de puntos correspondientes al suelo (clase 2) en función del tipo de terreno que se esté trabajando. En el caso que nos ocupa, las altitudes máxima y mínima en el terreno son de 2180 y 2160, respectivamente, existiendo un desnivel de alrededor de 20 metros a lo largo de toda la imagen (longitud de 490 metros), por lo que la pendiente es aproximadamente del 0.05 %. Por este motivo se seleccionó un tipo de terreno plano para el terreno. En la Figura 4.7 se muestra el menú utilizado para la clasificación.

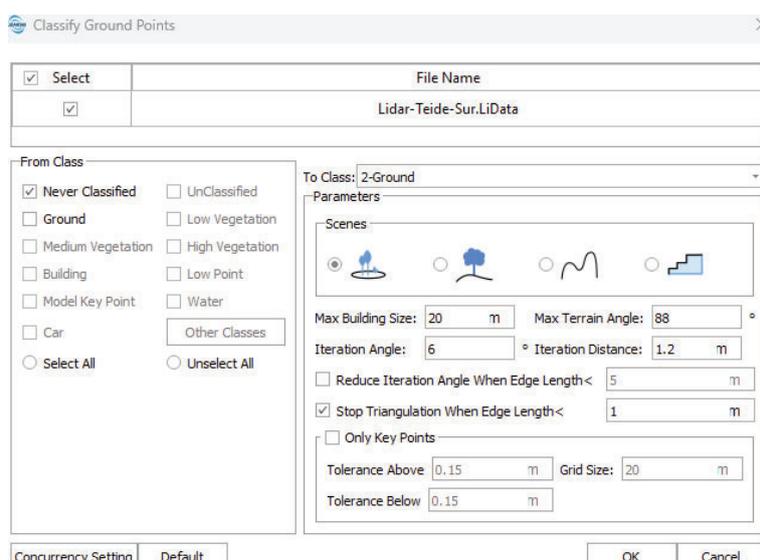


Figura 4.7 Menú de clasificación de puntos de suelo.

En la Figura 4.8 se muestran los parámetros usados para la generación del DEM y el DSM. La mayoría de los parámetros se dejaron por defecto, no obstante, el tamaño del píxel se fijó a 0.1 metros y en el método de interpolación se seleccionó la opción TIN (Triangulated Irregular Network) al proporcionar buenos resultados.

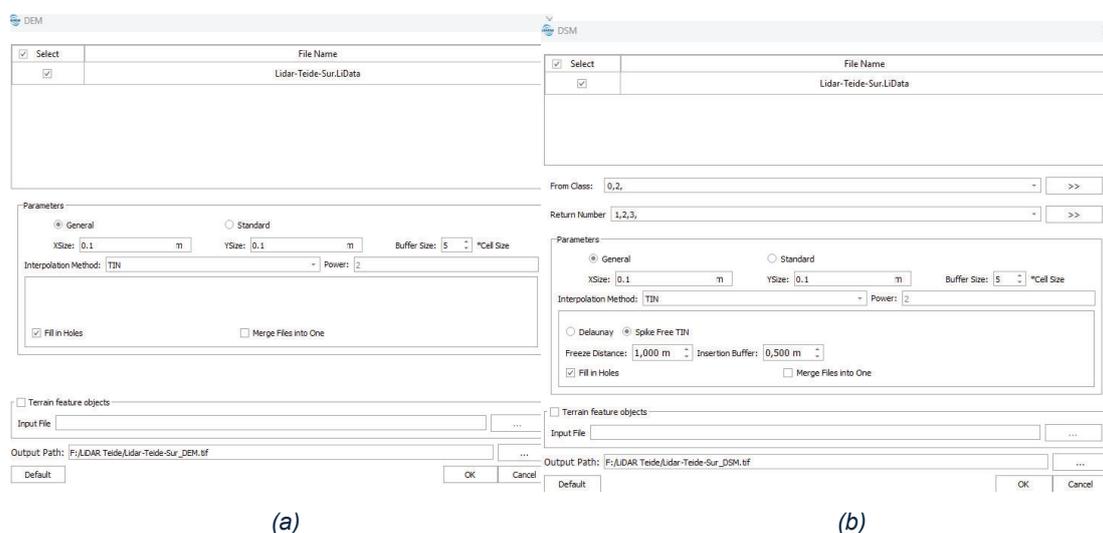


Figura 4.8 Creación: (a) DEM. (b) DSM.

Una vez obtenidos los modelos digitales de terreno y superficie, el software genera directamente el mapa de alturas CHM mediante la diferencia de ambos, tras indicar que fichero corresponde al DEM y al DSM.

Los resultados obtenidos de los modelos digitales de elevación y superficie se muestran en la Figura 4.9 usando una paleta de color arcoíris entre 2160 y 2180 metros.

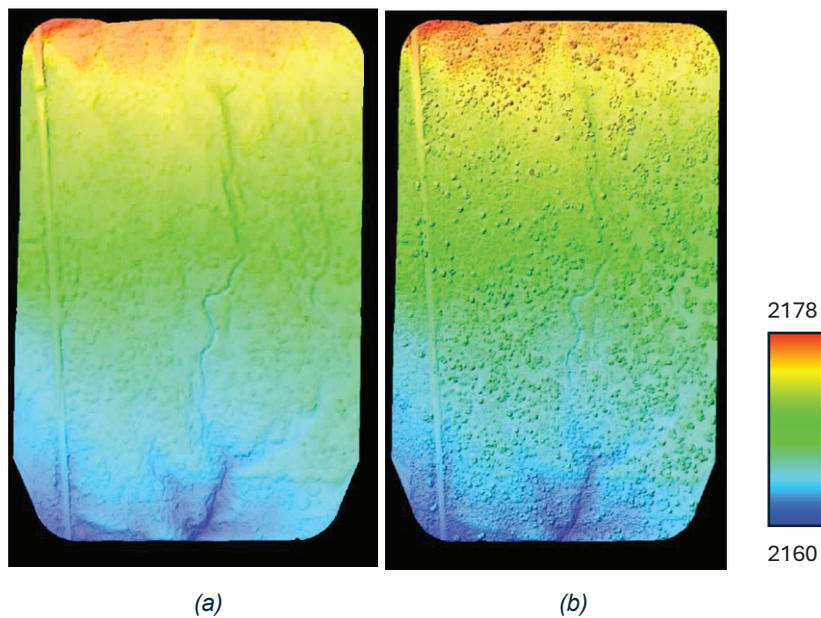


Figura 4.9 a) DEM. (b) DSM.

En la Figura 4.10 se muestra el resultado final del mapa de alturas CHM obtenido, que servirá como base para el registro y extracción de área y superficie de la vegetación.

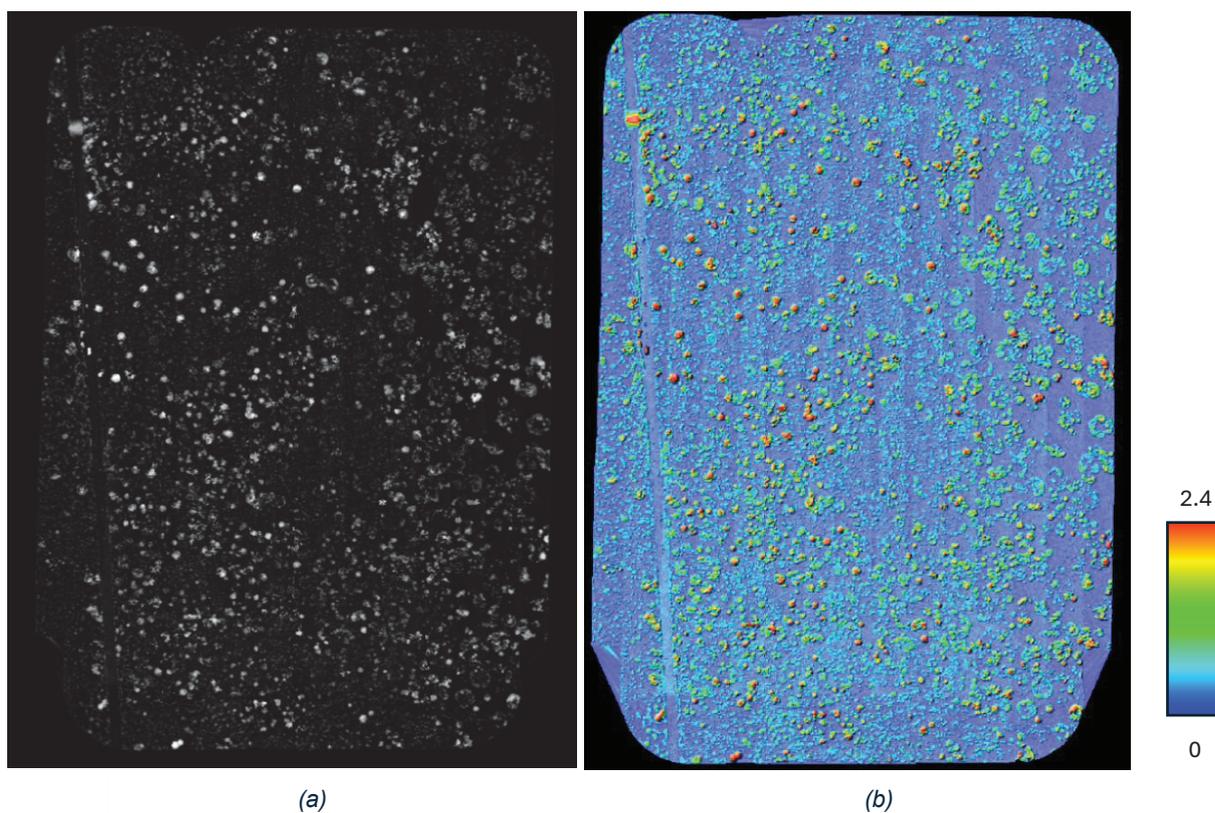


Figura 4.10 Mapa de alturas: (a) Escala de grises. (b) Con paleta a color.

4.4 Registro de imágenes

A pesar de las correcciones geométricas aplicadas a los datos multiespectrales y LiDAR, existen todavía pequeños errores de georeferenciación que hacen que ambas imágenes no sean superponibles.

El registro de imágenes se basa en la transformación de una imagen original con el objetivo de alinearla espacialmente con otra imagen. Para ello es necesaria una imagen de referencia, con la cual se generan puntos de control para poder alinear esta misma con la imagen original.

El primer paso para el registro de las imágenes es la selección de la imagen de referencia, es decir, la que no se modifica. Cuando esta imagen sea seleccionada y se tengan tanto la imagen original como la imagen base, se puede comenzar el registro.

El proceso llevado a cabo durante el registro se muestra en la Figura 4.11, en el cual se generan puntos de control sobre las imágenes y, posteriormente, se le aplica una transformación.

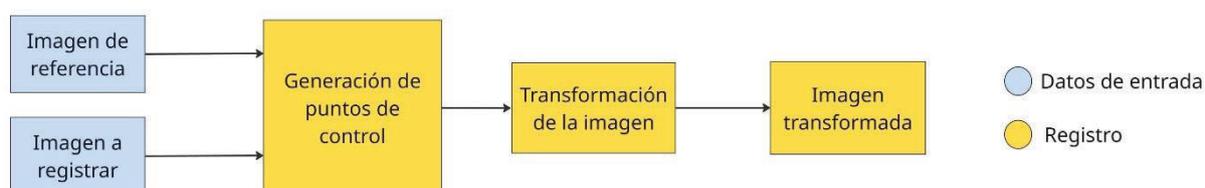


Figura 4.11 Diagrama de bloques del proceso de registro.

Para el desarrollo del proceso de registro se planearon principalmente dos opciones. Deformar las imágenes multiespectrales de ambos años usando como base la nube de puntos (QGIS) y usando el mapa de alturas CHM o la imagen multiespectral del 2019 (ENVI).

4.4.1 Registro usando como base la nube de puntos

Tras estudiar distintas alternativas, para el desarrollo de este proceso se hizo uso del plugin “Free Hand Raster Georeferencer” disponible en QGIS. Esta herramienta permite mover manualmente una imagen multiespectral usando como base una nube de puntos LiDAR. Entre las operaciones que permite el plugin destacan la de generar puntos de control y escalar, rotar y trasladar la imagen.

En el caso que nos ocupa, se optó por trasladar manualmente la imagen multiespectral de forma que coincidiera lo máximo posible con la nube de puntos. El resultado obtenido fue muy preciso en algunas zonas, mientras que en otras, a pesar de lograr una mejora, los elementos de la imagen no quedaron perfectamente alineados. En la Figura 4.12 se muestra un ejemplo con transparencia de la imagen multiespectral del 2024 registrada con el mapa de alturas

CHM. Se puede apreciar en la Figura 4.12 (b) como existen zonas más oscuras que corresponden a la imagen base y por tanto demuestran una incorrecta alineación.

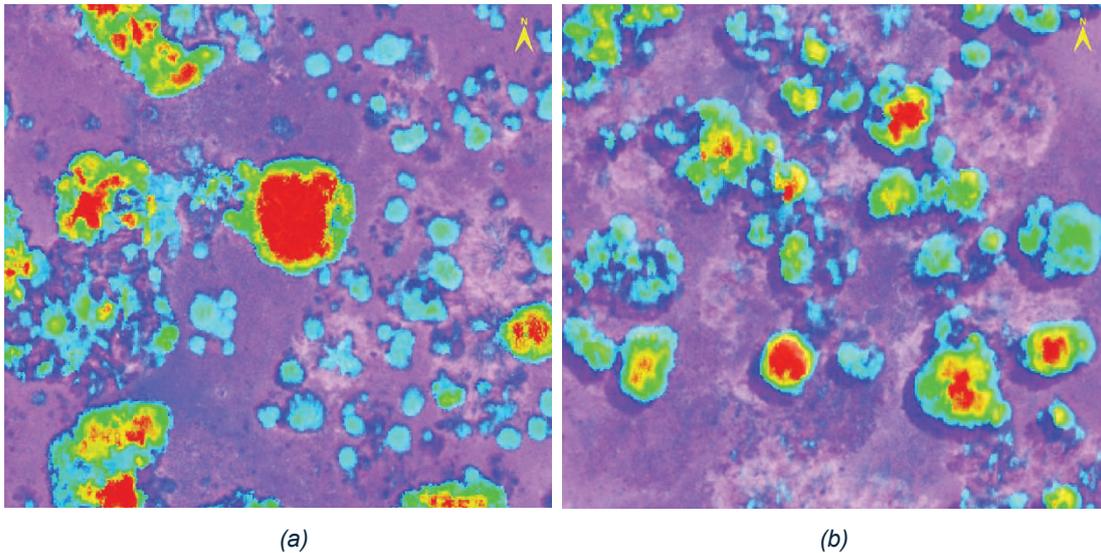


Figura 4.12 (a) Zonas correctamente alineadas. (b) Zonas incorrectamente alineadas.

4.4.2 Registro usando como base el CHM

Seguidamente se realizaron pruebas para deformar las imágenes del 2024 usando como base la imagen multiespectral del 2019. En este proceso se hizo uso de la herramienta “Image Registration Workflow” disponible en ENVI.

Una vez seleccionadas las imágenes base y deformada, la herramienta permite seleccionar una serie de parámetros que influyen en la deformación, tales como el método de emparejamiento, el modelo geométrico y de transformación y el número máximo de puntos generados, entre otros. Una vez seleccionados los parámetros deseados se generan los puntos de control automáticamente. Los puntos de control que se obtienen no pueden ser editados, no obstante, se pueden añadir puntos de control en zonas en la que el programa no haya generado.

En la Figura 4.13 se puede observar con mayor detalle los parámetros seleccionados para la generación de puntos y la transformación de la imagen.

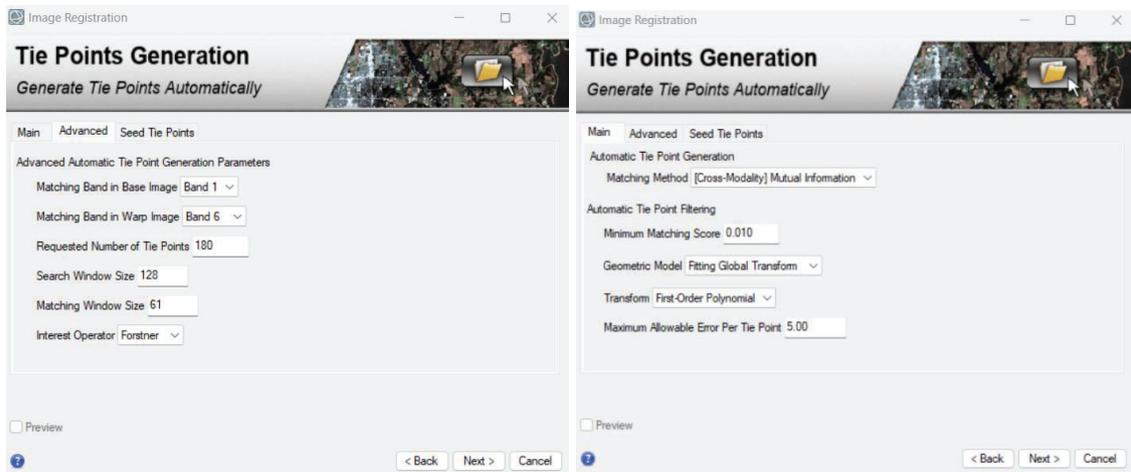


Figura 4.13 Parámetros para la generación de puntos de control.

En este apartado se realizaron varias pruebas a la hora de generar los puntos de control. Concretamente, se añadieron puntos de control de tres formas diferentes: de forma automática, de forma semiautomática modificando los puntos de control generados automáticamente, y de forma completamente manual, añadiendo pocos puntos pero bien localizados y correctamente distribuidos a lo largo de toda la imagen.

En todas las pruebas realizadas se usó el método de información mutua como alineación de características, transformación polinómica y reconstrucción de la imagen mediante interpolación bilineal. En la Tabla 4.1 se muestran las estadísticas de los puntos de control generados mediante los métodos mencionados.

Tabla 4.1 Pruebas de registro.

Prueba	Imagen base	Imagen deformada	Método	Puntos de control	Error rms
1	MS 2019	MS 2024	Automático	103	2.2
2	MS 2019	MS 2024	Semiautomático	140	2.8
3	CHM 2024	MS 2024	Manual	18	2.3
4	CHM 2024	MS 2024	Manual	46	2.9
5	MS 2024 registrada	MS 2019	Manual	24	2.4
6	CHM 2024	MS 2019	Manual	24	2.6

En las dos primeras pruebas se usó la imagen multiespectral de 2019 como base, no obstante, en pruebas posteriores se decidió usar la imagen CHM como base al obtener mejores

resultados. La imagen multispectral del 2024 final fue la realizada en la prueba 3, mientras que la del año 2019 fue la obtenida en la prueba 6, tras haber probado el registro con el CHM y la imagen del 2024 correctamente registrada como base en la prueba 5. Los puntos de control generados en cada caso se muestran en la Figura 4.14.

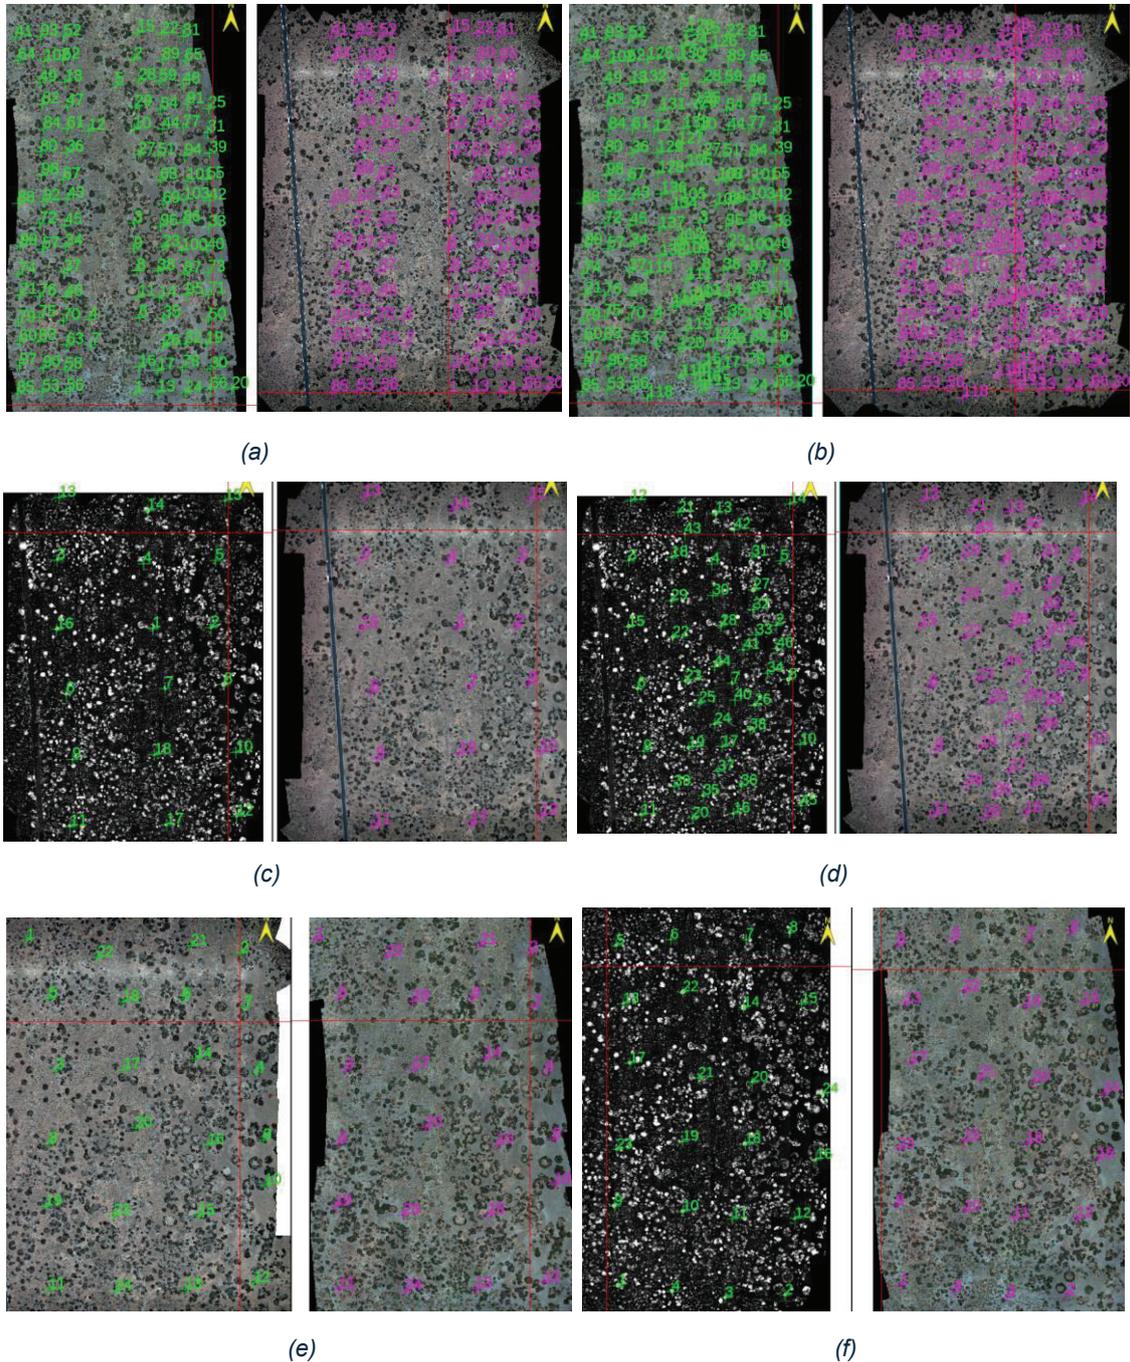


Figura 4.14 Puntos de control generados en: (a) Prueba 1. (b) Prueba 2. (c) Prueba 3. (d) Prueba 4. (e) Prueba 5. (f) Prueba 6.

En la Figura 4.15 se muestran los resultados de las imágenes originales superpuestas a las imágenes correctamente registradas con transparencia en cada prueba realizada del registro.

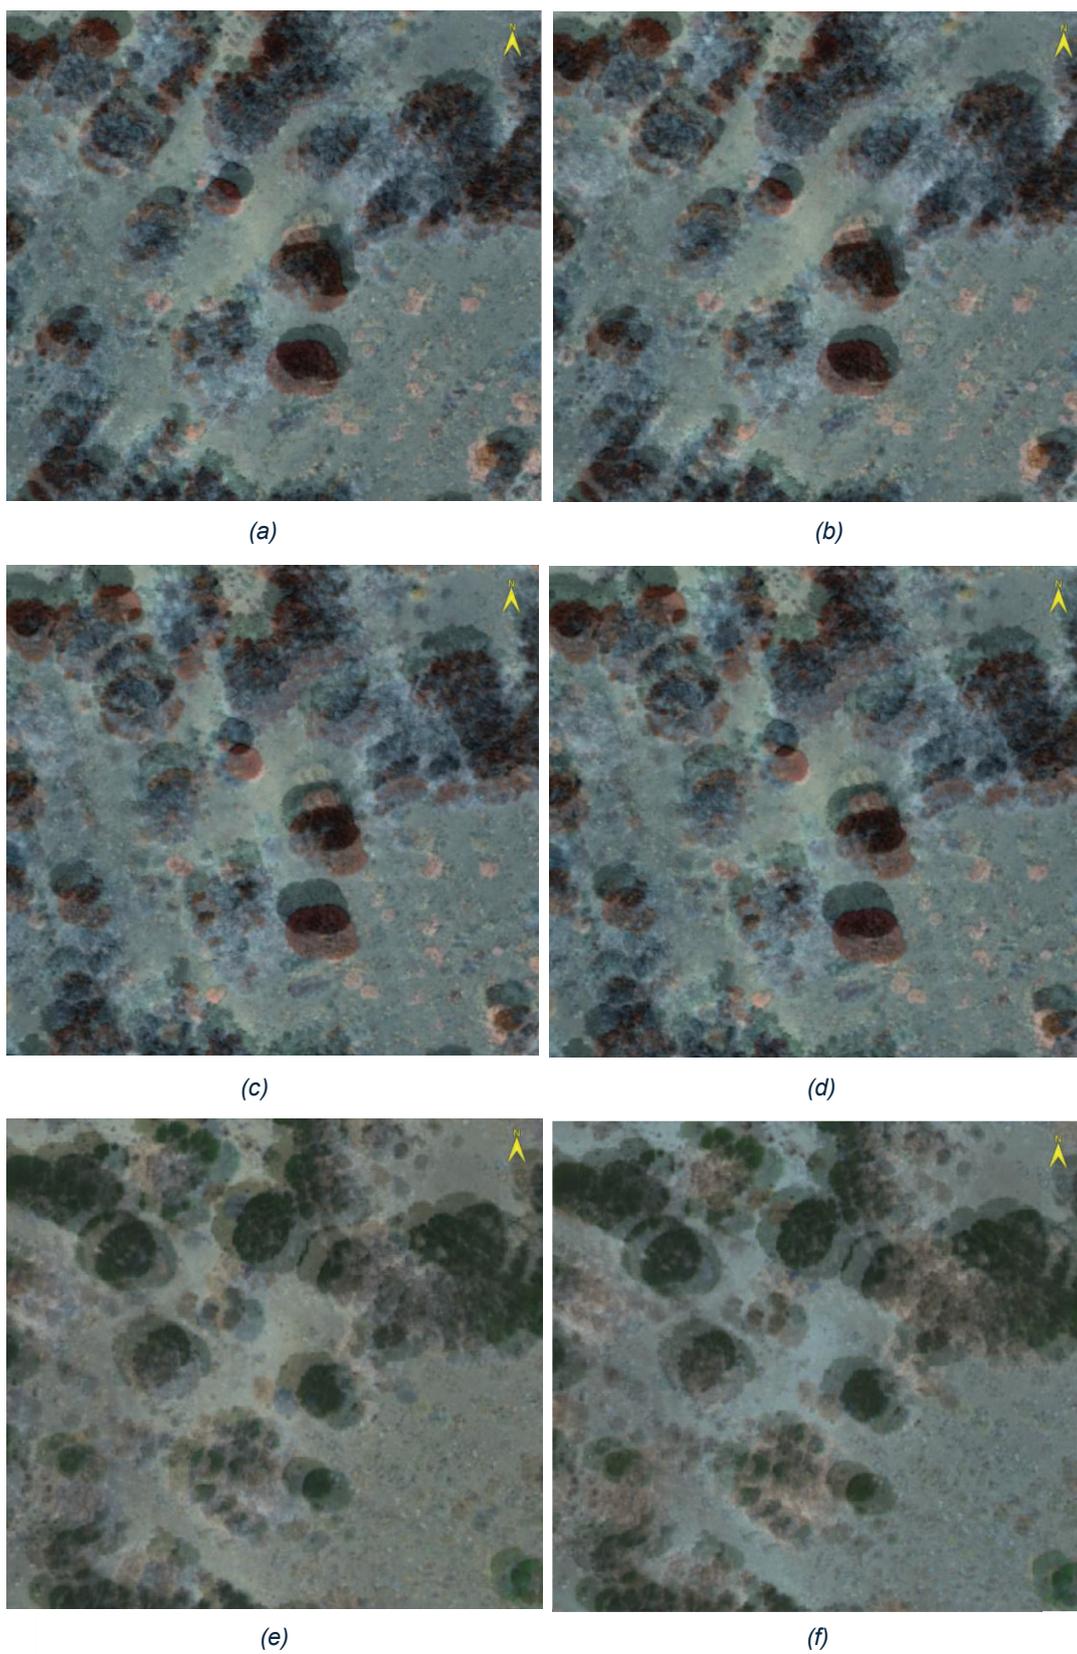


Figura 4.15 Imágenes registradas con transparencia: (a) Prueba 1. (b) Prueba 2. (c) Prueba 3. (d) Prueba 4. (e) Prueba 5. (f) Prueba 6.

Como último paso, se registró el mapa de retamas de la imagen multiespectral de 2019 habiéndola convertido previamente de formato shape a raster. Para registrar el mapa de retamas de 2019, se usó como base la imagen multiespectral de 2019 registrada habiendo usado como base previamente la imagen LiDAR, ya que fue la que mejor resultado dio en la anterior prueba. Se añadieron un total de 16 puntos de control uniformemente distribuidos con error promedio de 2.1 (Figura 4.16).

En la Figura 4.17 se muestra el mapa de retamas del año 2019 registrado con la imagen multiespectral del año 2019 como base.

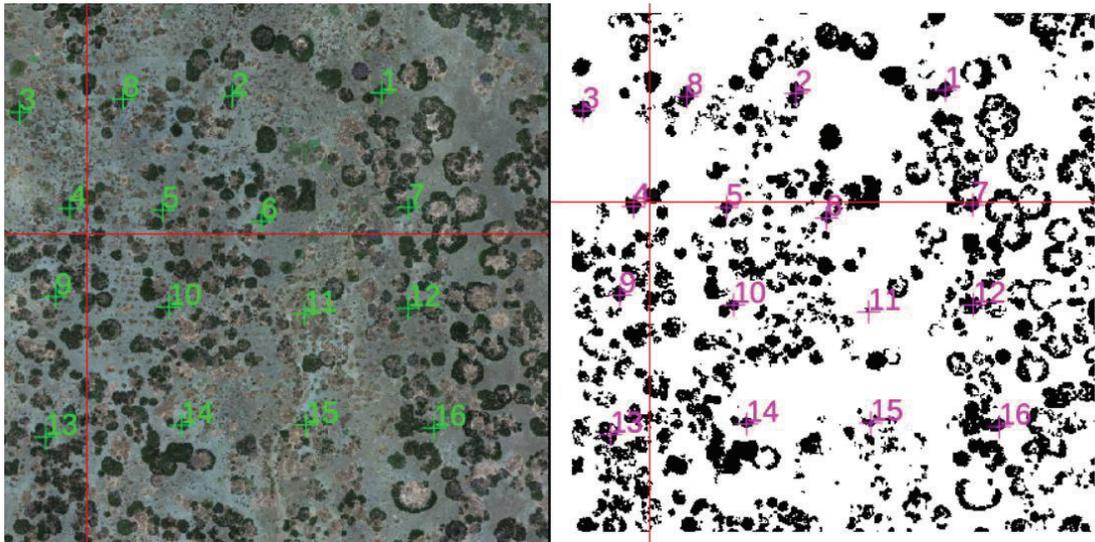


Figura 4.16 Puntos de control mapa de retamas.

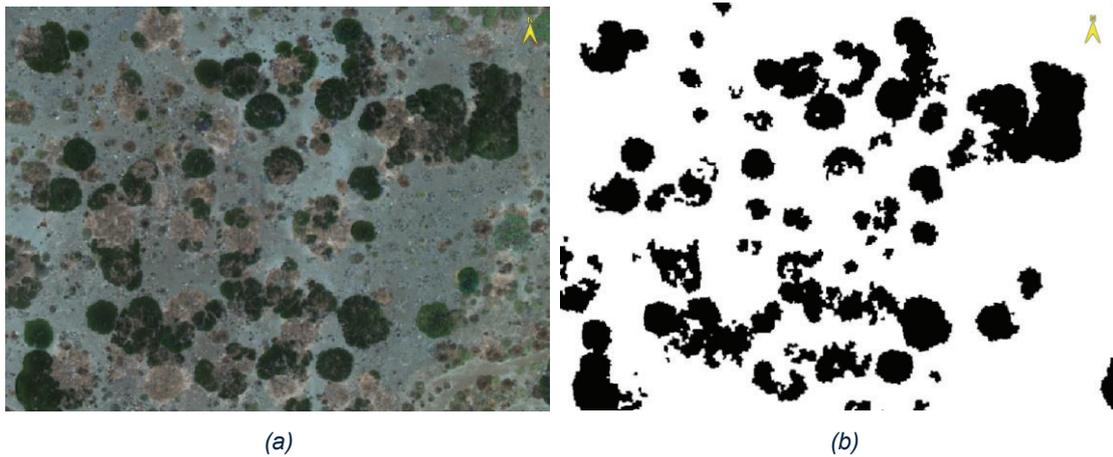


Figura 4.17 (a) Imagen multiespectral 2019 registrada. (b) Mapa de retamas registrado.

4.5 Clasificación

Para el análisis de los tipos de vegetación en la parcela es imprescindible una buena clasificación de los datos. Es por ello, que en este TFG se han probado numerosos métodos de clasificación utilizando diferentes algoritmos con el fin de encontrar el que mejor resultado obtenga. En este apartado, se muestran los pasos seguidos para la clasificación de los datos multiespectrales y LiDAR y los resultados obtenidos con cada método.

Para la realización de las clasificaciones de los datos se ha usado el software ENVI, el cual permite realizar tanto clasificaciones no supervisadas como supervisadas. Para este TFG se han realizado únicamente estas últimas.

En las clasificaciones supervisadas, se deben generar varias regiones de entrenamiento que proporcionan al algoritmo de clasificación información sobre las diferentes clases que se encuentran en la imagen. Estas regiones se conocen como ROIs (*Region Of Interest*) Por lo tanto, se deben crear la misma cantidad de ROIs como clases tenga la imagen. Dentro de cada ROI se pueden añadir tantos ejemplos representativos de cada clase como se deseen distribuidos uniformemente en la imagen y tratando de tener una cantidad de píxeles similar en cada ROI.

Una vez se hayan creado los ROIs, se aplica un algoritmo de clasificación supervisada a la imagen usando los ROIs creados previamente. Cuando se ha obtenido un resultado de la clasificación, ENVI permite generar matrices de confusión que cuantifican la fiabilidad de la clasificación usando unos ROIs diferentes a los usados para clasificar la imagen, conocidos como ROIs de evaluación.

Finalmente, en el último paso se le aplica un filtrado por mayoría a la imagen clasificada usando una ventana de 5x5 píxeles, con el fin de eliminar los píxeles aislados y mejorar la visualización de la imagen clasificada final.

En la Figura 4.18 se muestra el proceso descrito en un diagrama de bloques.

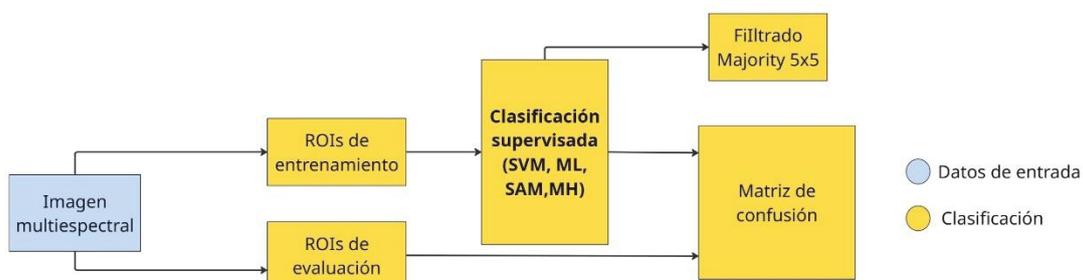


Figura 4.18 Diagrama de bloques del proceso de clasificación.

4.5.1 ROIs

Antes de la generación de los ROIs, es necesario recortar tanto la imagen multiespectral como la imagen CHM para que abarque la misma superficie, ya que, si se generan regiones de entrenamiento o evaluación en la imagen multiespectral sin haberla ajustado previamente, es posible que una de esas regiones quede fuera de la imagen LiDAR.

Existen numerosas formas de recortar una imagen. En este caso se decidió recortar la imagen mediante ROI. Para ello se creó una región en el menú de creación de ROIs con un área que abarcara tanto la imagen multiespectral como el CHM. Posteriormente se seleccionó la herramienta “Subset Data From ROIs” que proporciona ENVI y se aplicó el recorte a ambas imágenes. El resultado del recorte se muestra en la Figura 4.19.

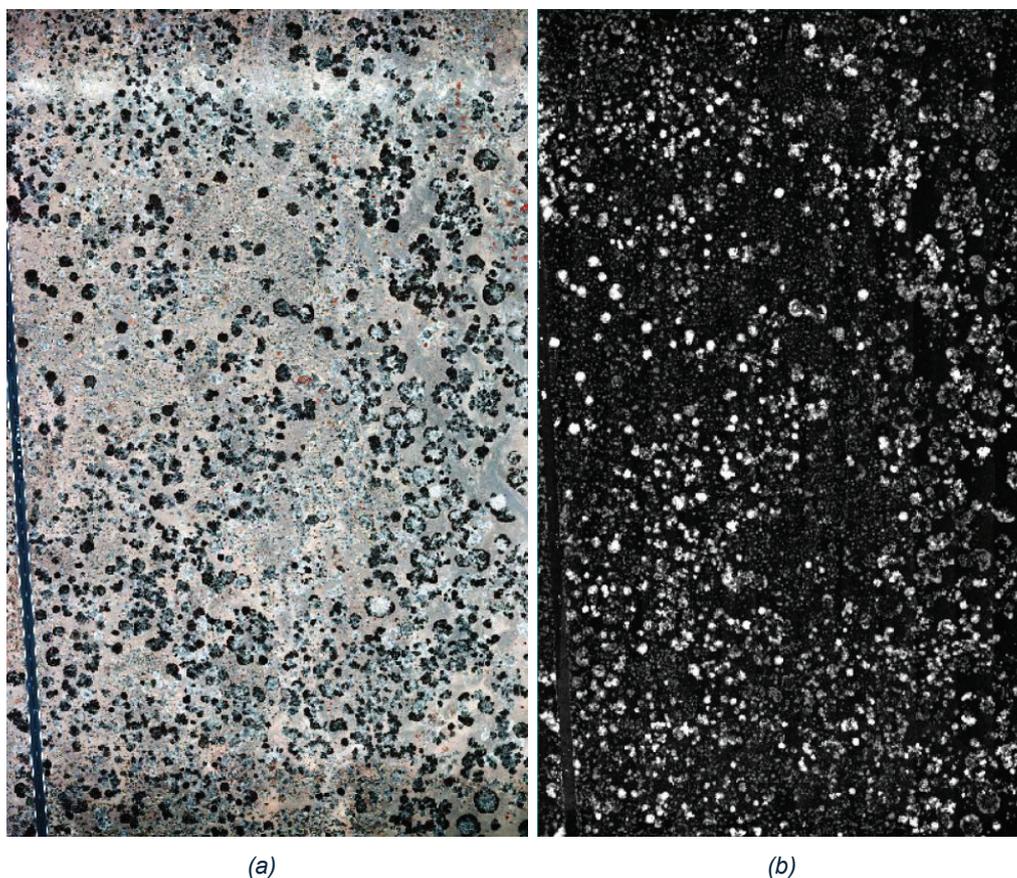


Figura 4.19 Imagen dron de 2024: (a) Multiespectral. (b) CHM.

Una vez recortadas las imágenes, se puede proceder a la generación de las regiones de entrenamiento y evaluación.

En total se seleccionaron 5 clases para clasificar en la imagen: “Retama”, “Suelo”, “Vegetación Muerta”, “Otra Vegetación (incluye principalmente especies herbáceas como rosalillo y hierba pajonera)” y “Otros” (carretera y coches). La distribución de los ROIs de entrenamiento y evaluación en la imagen multiespectral registrada previamente se muestra en la Figura 4.20,

mientras que en la Tabla 4.2 se muestran las estadísticas de cada ROI de entrenamiento y en la Tabla 4.3 los de evaluación.

Tabla 4.2 Estadísticas de los ROIs de entrenamiento.

Clases	ROIs	Pixeles	Color
Retama	43	12,382	Verde Oscuro
Suelo	53	14,749	Naranja Claro
Vegetación muerta	45	15,202	Gris
Otra vegetación	76	6,441	Verde Claro
Otros (carretera y coches)	13	10,091	Negro

Tabla 4.3 Estadísticas de los ROIs de evaluación.

Clases	ROIs	Pixeles	Color
Retama	63	14,784	Verde Oscuro
Suelo	63	15,279	Naranja Claro
Vegetación muerta	22	15,690	Gris
Otra vegetación	113	9,375	Verde Claro
Otros (carretera y coches)	14	14,619	Negro

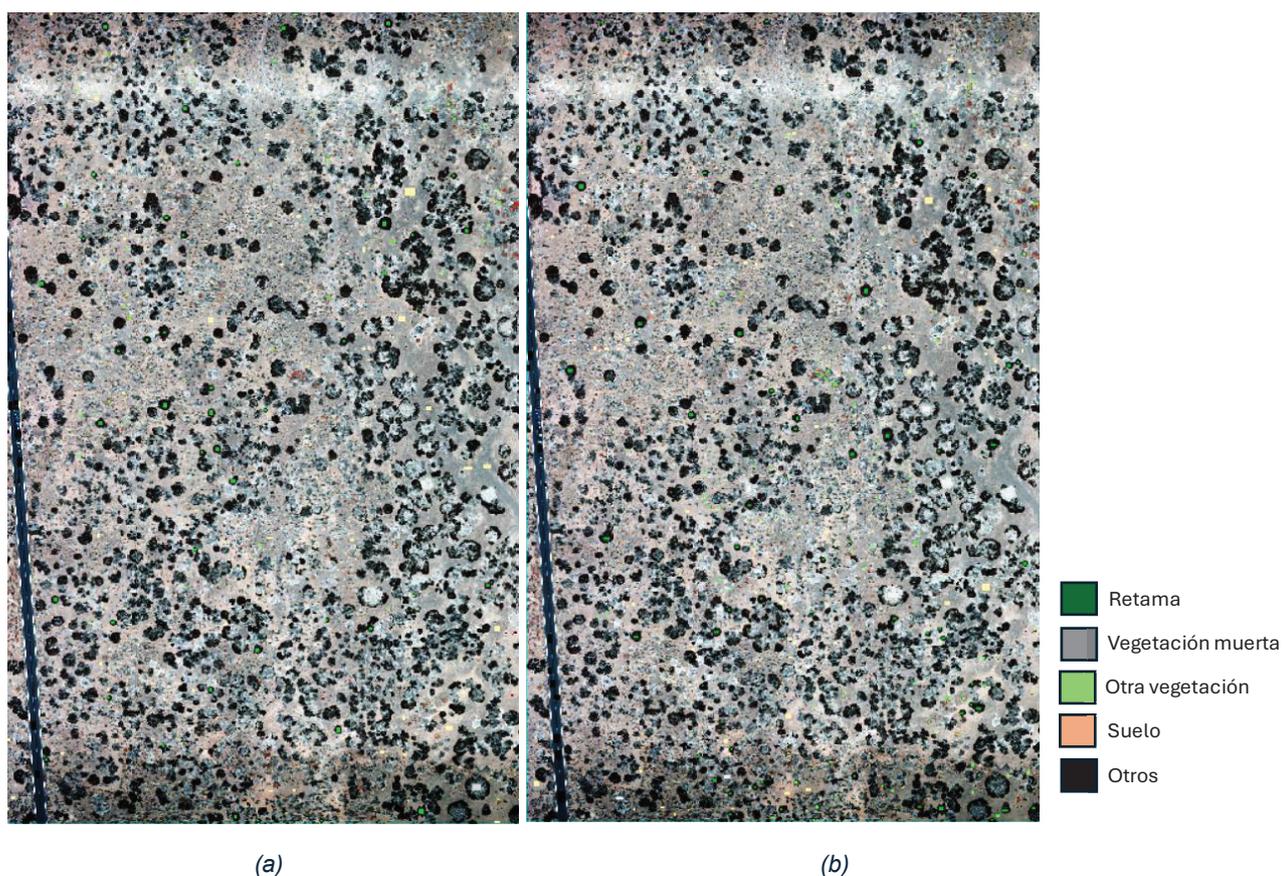


Figura 4.20 (a) ROIs de entrenamiento. (b) ROIs de evaluación.

Como medida de la separabilidad espectral de los ROIs creados, se estudió la separabilidad espectral de las clases definidas en estos mismos. Para ello, en ENVI se usó la opción

“*Compute ROI Separability*”. En la Tabla 4.4 se muestran las estadísticas de la separabilidad entre cada par de clases definidas mediante los ROIs de entrenamiento y en la Tabla 4.5 la separabilidad mediante los ROIs de evaluación.

El método aplicado por ENVI para el cálculo de la separabilidad entre las clases definidas se denomina distancia de Jeffries-Matusita (JM). Esta medida está acotada entre 0 y 2, considerando valores de separación adecuados superiores a 1.8. Un valor menor de 1.8 indica que dos clases son similares espectralmente y existe la posibilidad de que la clasificación no logre discriminar ambas clases.

Tabla 4.4 Separabilidad de los ROIs de entrenamiento.

Clase 1	Clase 2	Separabilidad
Otros	Vegetación muerta	1.83406657
Vegetación muerta	Suelo	1.86278740
Otros	Suelo	1.95567540
Otra vegetación	Retama	1.95954933
Vegetación muerta	Retama	1.97237364
Otros	Retama	1.98261945
Otra vegetación	Vegetación muerta	1.98901648
Otra vegetación	Suelo	1.99540148
Otros	Otra vegetación	1.99919756
Suelo	Retama	1.99992291

Tabla 4.5 Separabilidad de los ROIs de evaluación.

Clase 1	Clase 2	Separabilidad
Otros	Vegetación muerta	1.87849791
Vegetación muerta	Suelo	1.93571128
Otra vegetación	Retama	1.94147796
Otra vegetación	Vegetación muerta	1.96720171
Vegetación muerta	Retama	1.97040215
Otros	Suelo	1.97801325
Otros	Retama	1.98620687
Otra vegetación	Suelo	1.99163109
Otros	Otra vegetación	1.99163774
Suelo	Retama	1.99991985

Se verifica que las ROIs todas las clases definidas en los ROIs de entrenamiento y evaluación son mayores que 1.8, indicando que a priori, las regiones de entrenamiento y evaluación están correctamente definidas y la clasificación será viable.

En la Figura 4.21 se muestran las firmas espectrales de las regiones de entrenamiento representadas por la media de todos los ROIs de cada clase y por desviación típica. Por su

parte, en la Figura 4.22 se muestran las firmas espectrales de los ROIs de evaluación por media y por desviación típica.

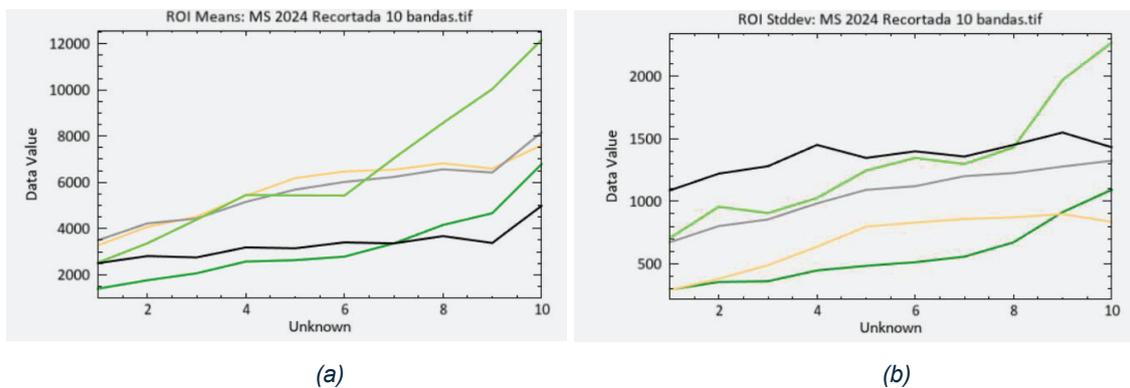


Figura 4.21 (a) Firma espectral de las regiones de entrenamiento (media). (b) Firma espectral de las regiones de entrenamiento (desviación típica).

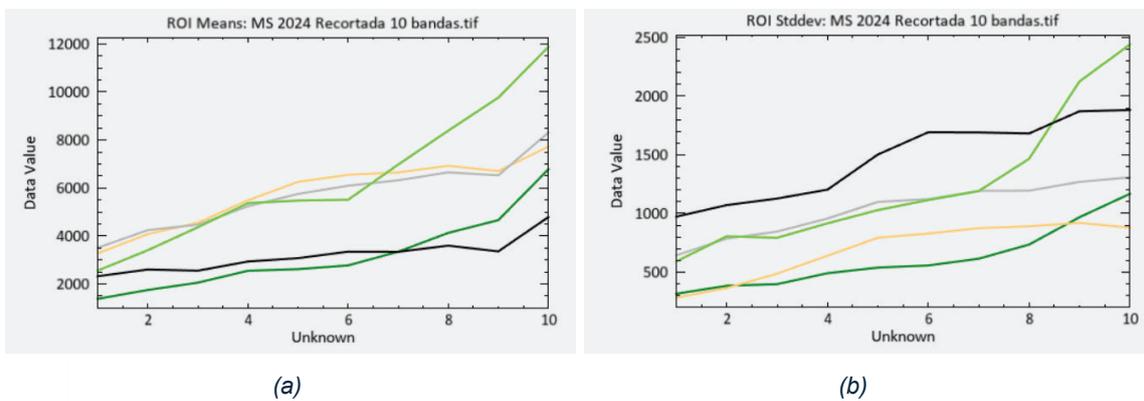


Figura 4.22 (a) Firma espectral de las regiones de evaluación (media). (b) Firma espectral de las regiones de evaluación (desviación típica).

4.5.2 Clasificación multiespectral

Para llevar a cabo la clasificación de la imagen multiespectral de 2024 a partir de los ROIs de entrenamiento, se probaron 4 algoritmos de clasificación diferentes en la imagen multiespectral en ENVI, con el fin de verificar que algoritmo obtiene mejores resultados en la clasificación: “Maximum Likelihood”, “Support Vector Machine”, “Spectral Angle Mapper”, y “Mahalanobis Distance”.

Los resultados obtenidos por los algoritmos Maximum Likelihood y Support Vector Machine fueron visualmente mejores, consiguiendo una mejor discriminación entre clases y clasificando cada clase con menor error que los demás algoritmos. Spectral Angle Mapper obtuvo píxeles de la imagen sin clasificar (negro), mientras que, por su parte, el algoritmo Mahalanobis Distance sobreestimó el número de píxeles de la clase “Otros” (color negro).

Este problema también se da en menor medida en los algoritmos que dieron mejores resultados en las zonas de los bordes (inferior) de la imagen multiespectral. Los resultados visuales de cada clasificador se pueden observar en la Figura 4.23 para un trozo de la parcela. En el Anexo 1 se muestra el resultado para la parcela completa.

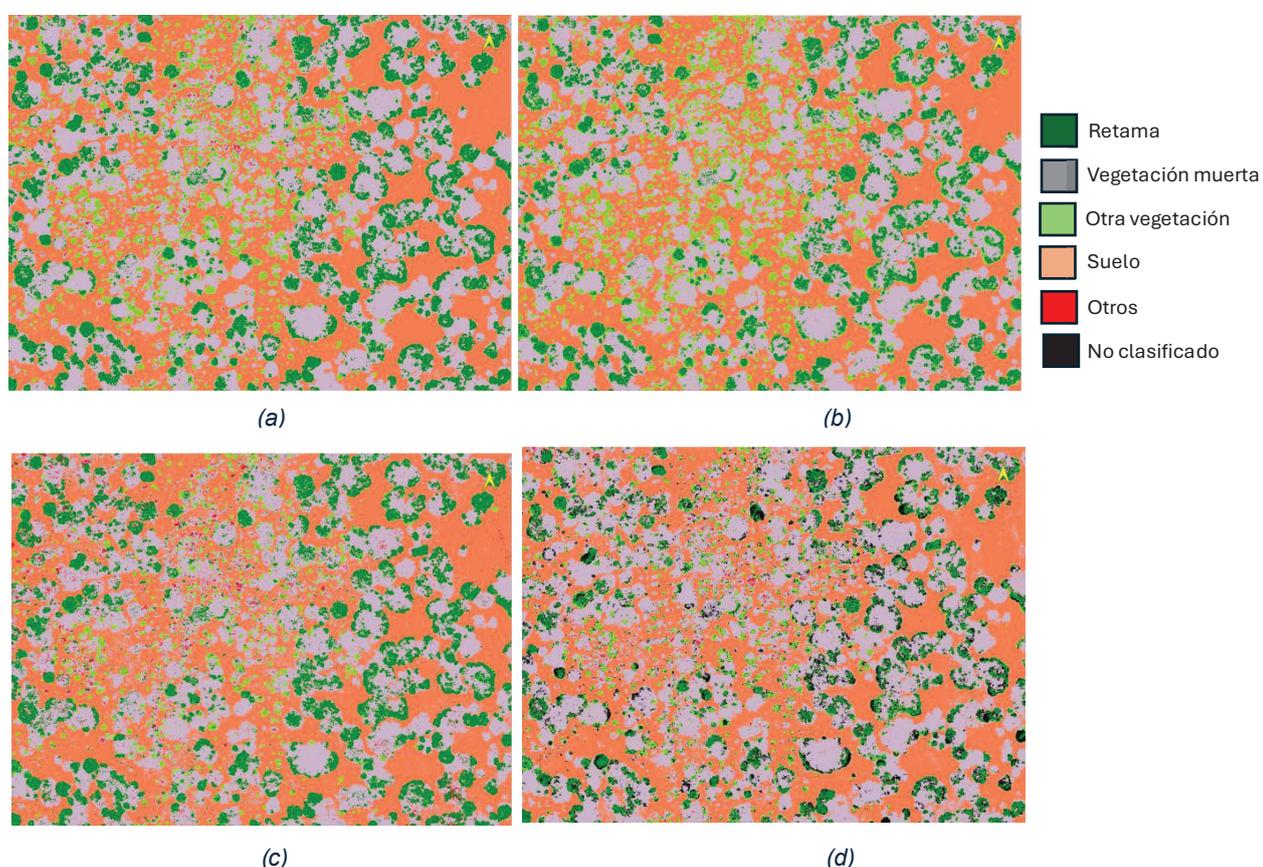


Figura 4.23 (a) Clasificación *Support Vector Machine*. (b) Clasificación *Maximum Likelihood*. (c) Clasificación *Mahalanobis Distance*. (d) Clasificación *Spectral Angle Mapper*.

Además del análisis visual, como estudio posterior a la clasificación, se decidió revisar las matrices de confusión con cada clasificador para elegir cual es óptimo. Sin embargo, dado que los resultados obtenidos con los algoritmos de clasificación *Spectral Angle Mapper* y *Mahalanobis Distance* fueron notablemente peores, se estudiaron únicamente las matrices de confusión de los algoritmos *Support Vector Machine* y *Maximum Likelihood*.

Para ello, en ENVI se eligió la opción “*Confusion Matrix Using Ground Truth ROIs*”. Las matrices de confusión muestran el porcentaje de acierto en cada clase de la imagen clasificada con respecto a los ROIs de evaluación, por lo que es crucial que estos últimos, sean representativos y no coincidan con los usados en el entrenamiento para clasificar la imagen. Los resultados extraídos de las matrices de confusión se muestran en la Tabla 4.6 (*Support Vector Machine*) y en la Tabla 4.7 (*Maximum Likelihood*).

Tabla 4.6 Matriz de confusión en porcentaje de acierto de cada clase con Support Vector Machine.

Clases SVM	Retama	Suelo	Vegetación muerta	Otra vegetación	Otros
Retama	98,57	0	0,87	4,02	0,5
Suelo	0	99,54	0,34	0,54	0,21
Vegetación muerta	0,89	0,46	97,71	3,05	3,13
Otra vegetación	0,44	0,01	0,84	92,38	2,05
Otros	0,09	0	0,24	0	94,12
No clasificado	0	0	0	0	0
Total	100	100	100	100	100

Tabla 4.7 Matriz de confusión en porcentaje de acierto de cada clase con Maximum Likelihood.

Clases ML	Retama	Suelo	Vegetación muerta	Otra vegetación	Otros
Retama	95,63	0	0,58	1,18	0,01
Suelo	0	99,55	0,62	0,02	0,04
Vegetación muerta	2,45	0,24	97,3	3,93	1,84
Otra vegetación	1,77	0,2	1,13	94,86	3,59
Otros	0,16	0,01	0,36	0,01	94,51
No clasificado	0	0	0	0	0
Total	100	100	100	100	100

Los resultados obtenidos fueron muy similares, siendo ligeramente superior en porcentaje de acierto global el algoritmo Support Vector Machine. No obstante, Maximum Likelihood es una opción interesante por sus buenos resultados teniendo una carga computacional menor que Support Vector Machine, por lo que su uso es recomendable para clasificaciones sencillas en las que se requiera una comprobación rápida de la fiabilidad de las regiones de entrenamiento.

Finalmente, el algoritmo elegido es Support Vector Machine, justificado por dar mejor precisión en la retama y por sus buenos resultados visuales y estadísticos. En la Figura 4.24 se muestra el porcentaje de acierto global de los algoritmos *Maximum Likelihood* y *Support Vector Machine*.

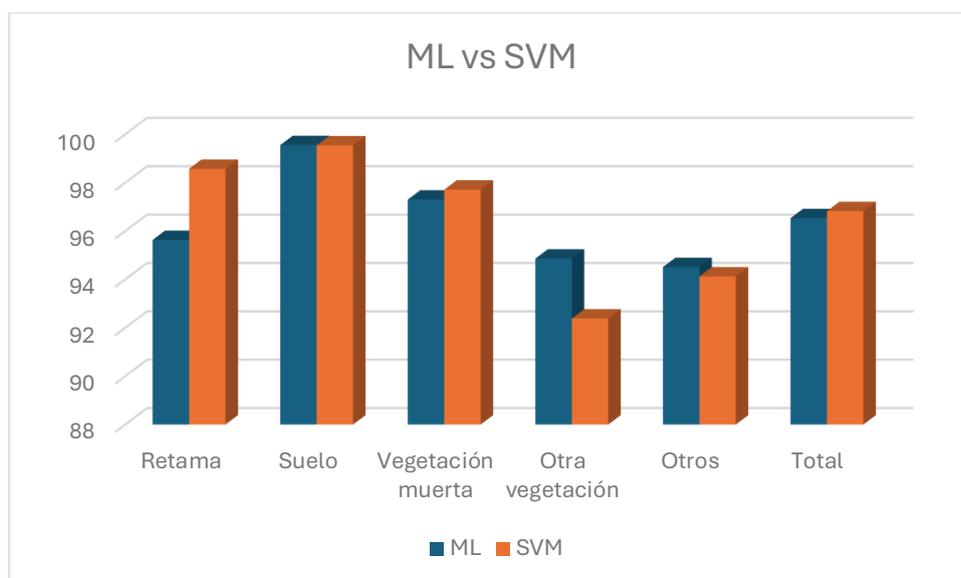


Figura 4.24 Porcentaje de acierto de Maximum Likelihood y Support Vector Machine.

4.5.3 Clasificación multisensor

Además de la clasificación con datos multispectrales se analizaron diferentes alternativas utilizando los datos LiDAR o un índice de vegetación.

A la hora de clasificar la imagen LiDAR se siguió el mismo procedimiento. Los ROIs usados para entrenar y evaluar fueron los mismos que en la clasificación multispectral, dado que fueron escogidos de manera que pudieran ser utilizados tanto en la imagen multispectral como en la LiDAR gracias al registro previo de las imágenes. En este caso se utilizó únicamente el algoritmo *Support Vector Machine* tras haber comprobado que es el que mejor resultado obtiene.

Con el fin de mejorar la clasificación, se decidió verificar si combinando la imagen multispectral con la imagen LiDAR los resultados mejoran.

Para ello, en ENVI se usó la opción “Build Band Stack”, que permite unir en una misma imagen bandas de diferentes imágenes. Se unieron las 10 bandas multispectrales con la banda de la imagen CHM procedente del LiDAR, obteniendo como resultado final una imagen de 11 bandas.

Además, dado que los índices de vegetación pueden ofrecer información acerca de la salud vegetal, se decidió añadir a la imagen fusionada una banda que representara el índice de vegetación MSAVI2, adecuado en zonas de vegetación arbustiva dispersa.

El proceso de creación del índice de vegetación MSAVI2 a partir de la imagen multispectral en ENVI se realizó mediante la opción “Band Math”. En el proceso se añade una expresión

matemática en función de las variables “B1” y “B2” (infrarrojo cercano y rojo) y posteriormente cada variable se asigna a la banda correspondiente.

Una vez obtenido el índice de vegetación MSAVI2, se procedió a la fusión de la imagen multiespectral (10 bandas), la imagen LiDAR CHM (1 banda) y el índice de vegetación MSAVI2 (1 banda). Para ello se realizaron las siguientes combinaciones de bandas para evaluar los resultados de la clasificación: MS+LiDAR, MS+MSAVI2, MS+LiDAR+MSAVI2. El objetivo es analizar si incorporando información adicional es posible mejorar la precisión de la clasificación.

Para verificar el porcentaje de acierto por cada clase de cada imagen fusionada, se generaron las matrices de confusión de cada imagen siguiendo el mismo procedimiento que en la imagen multiespectral y usando los mismos ROIs de evaluación. Los resultados obtenidos de cada clasificador se detallan en la Tabla 4.8, en la cual se observa el porcentaje de acierto usando el algoritmo SVM.

Tabla 4.8 Porcentaje de acierto de cada clase para cada imagen con Support Vector Machine.

Imagen clasificada	Retama	Suelo	Vegetación	Otra	Otros	Total
MS	98,57	99,54	97,71	92,38	94,12	96,8242
LiDAR	93,03	83	56,22	72,23	0	60,1406
MSAVI2	95,39	97,13	81,7	0	45,57	69,4266
MS+LiDAR	99,57	99,64	97,83	93,99	94,35	97,3504
MS+MSAVI2	98,4	99,46	97,86	92,62	93,92	96,7941
MS+LiDAR+MSAVI2	99,31	99,59	97,99	94,31	94,25	97,3433

En la Figura 4.25 se muestra el acierto de cada imagen clasificada en función de las diferentes clases de la imagen, mientras que en la Figura 4.26 se muestra el acierto en la clasificación de cada clase en función de la imagen utilizada.

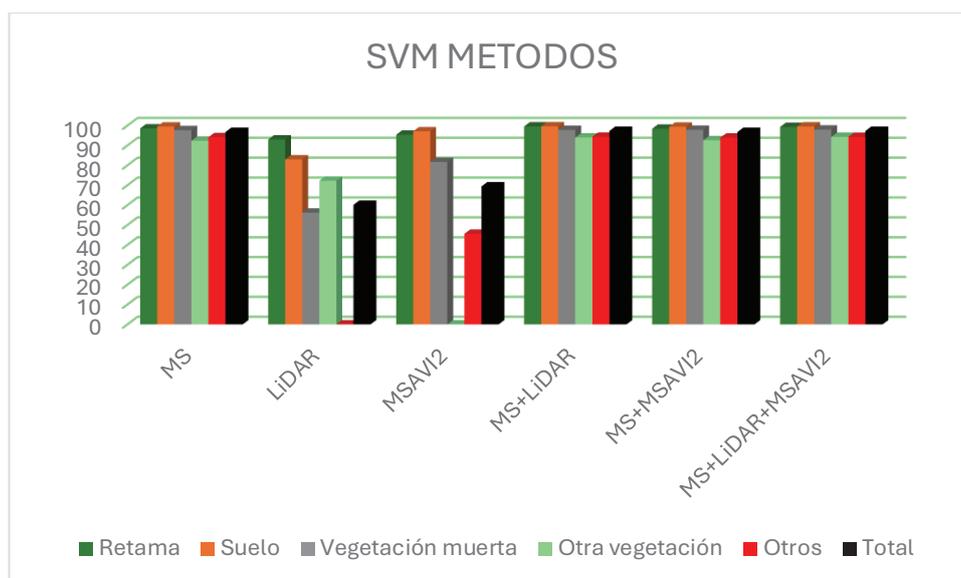


Figura 4.25 Acierto de cada imagen en función de las clases.

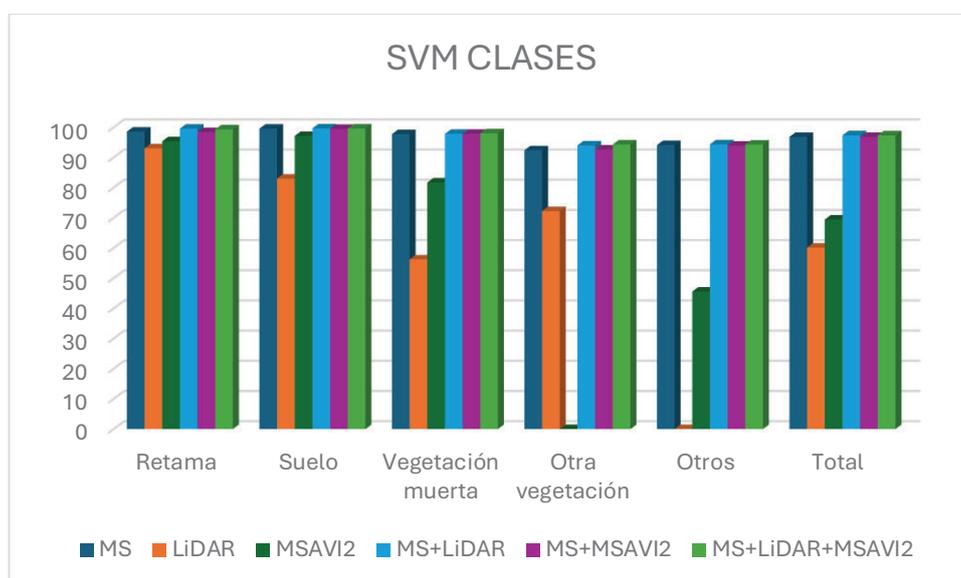


Figura 4.26 Acierto de cada clase en función de la imagen.

Como puede observarse en la Tabla 4.8 y en las Figura 4.25 y 4.26, las clasificaciones individuales de las imágenes LiDAR CHM y del índice de vegetación MSAVI2 proporcionan un bajo porcentaje de acierto global. No obstante, en el caso de la fusión MS+LiDAR se obtiene un mayor porcentaje de acierto global que en cualquier otro caso. Los resultados obtenidos de cada clasificador se muestran en la Figura 4.27 para un trozo de la escena. En el Anexo 2 se muestra el resultado para la parcela completa.

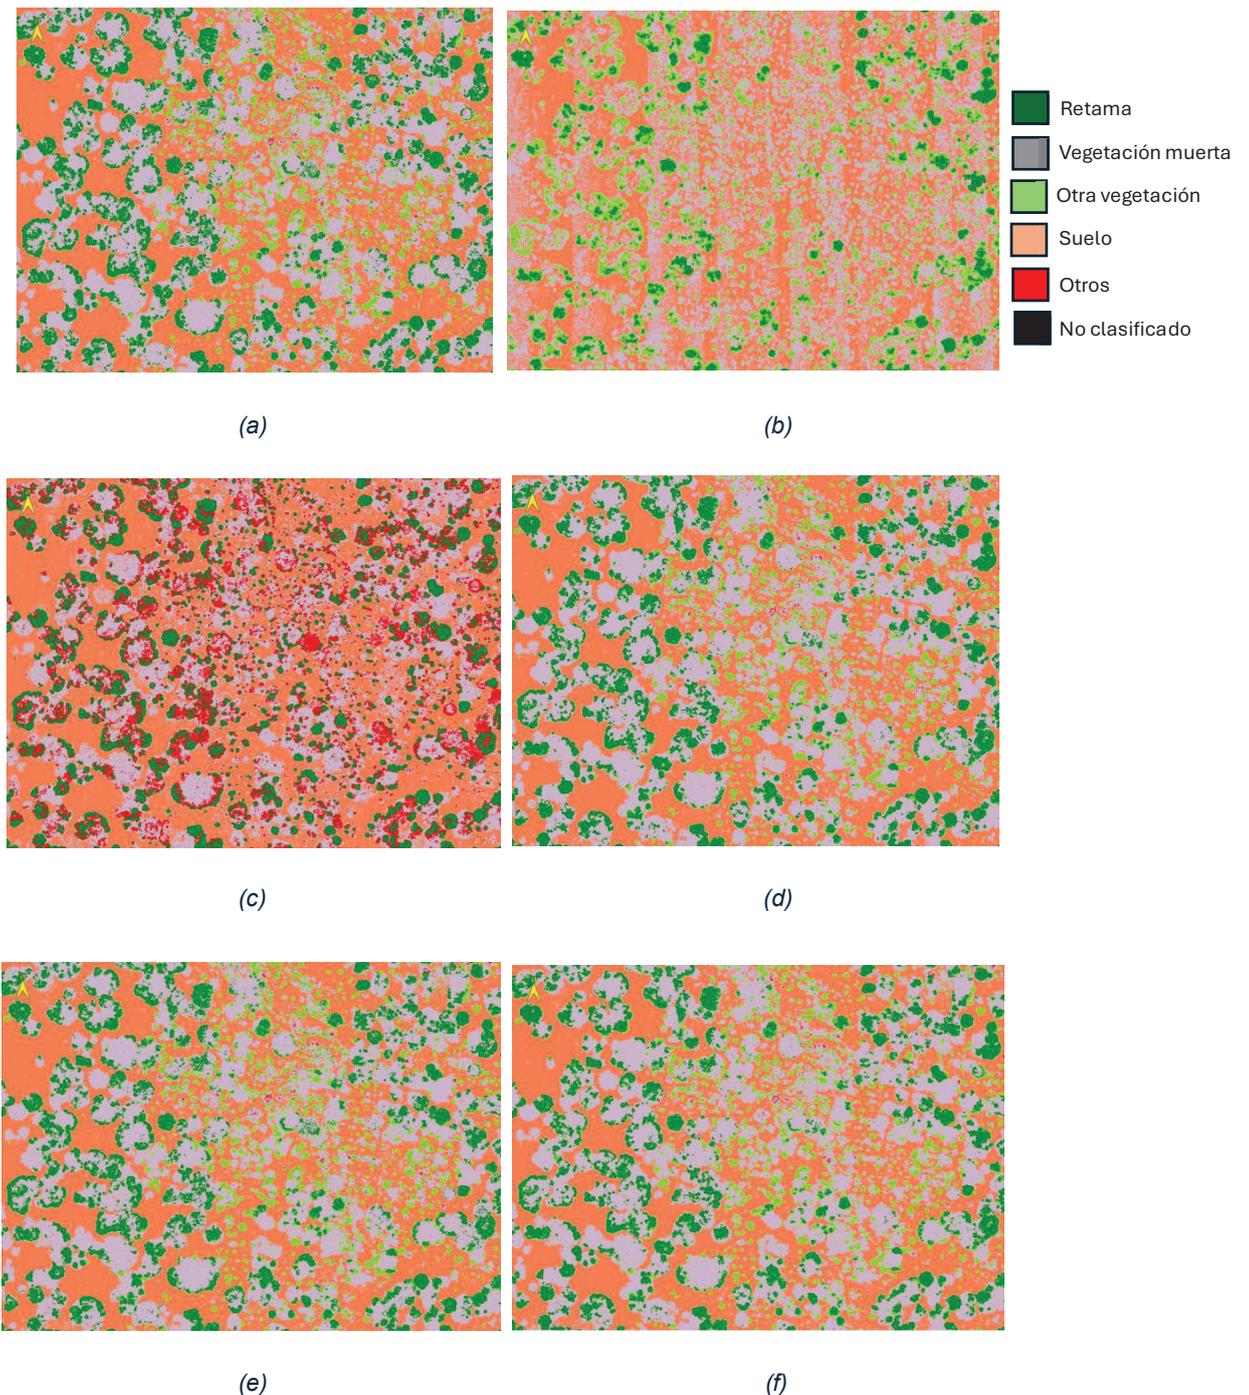


Figura 4.27 Clasificación SVM para: (a) MS. (b) LiDAR. (c) MSAVI2. (d) MS+LiDAR. (e) MS+MSAVI2. (f) MS+LiDAR+MSAVI2.

Los resultados visuales de la Figura 4.27 corroboran que utilizar una banda de LiDAR y MSAVI2, resulta poco preciso. La imagen multiespectral de 10 bandas y sus fusiones con LiDAR y MSAVI2 ofrecen resultados visuales bastante precisos y similares entre sí, es por ello por lo que se elige la clasificación con mayor precisión en función de la matriz de confusión correspondiente a la fusión en 11 bandas de la imagen multiespectral y el mapa de alturas de LiDAR con un porcentaje de acierto global del 97,35 %.

Una vez decidida la metodología final de la clasificación, se le aplicó un filtrado de mayoría que elimina píxeles aislados. Para ello, en ENVI se seleccionó la herramienta “Majority Analysis”, la cual utiliza un análisis de mayoría para cambiar algunos píxeles de la imagen de una clase a otra. En el procedimiento, el software genera sobre cada píxel una ventana del tamaño indicado (3x3, 5x5, 7x7...) y reemplaza el valor de la clase del píxel central por el del valor de la mayoría de los píxeles de esa ventana. El resultado final es una imagen más limpia y regular. En este caso, se seleccionó un tamaño de la ventana de 5x5, puesto que se observaron mejores resultados. En la Figura 4.28 se muestra el resultado final de la clasificación en la imagen completa.

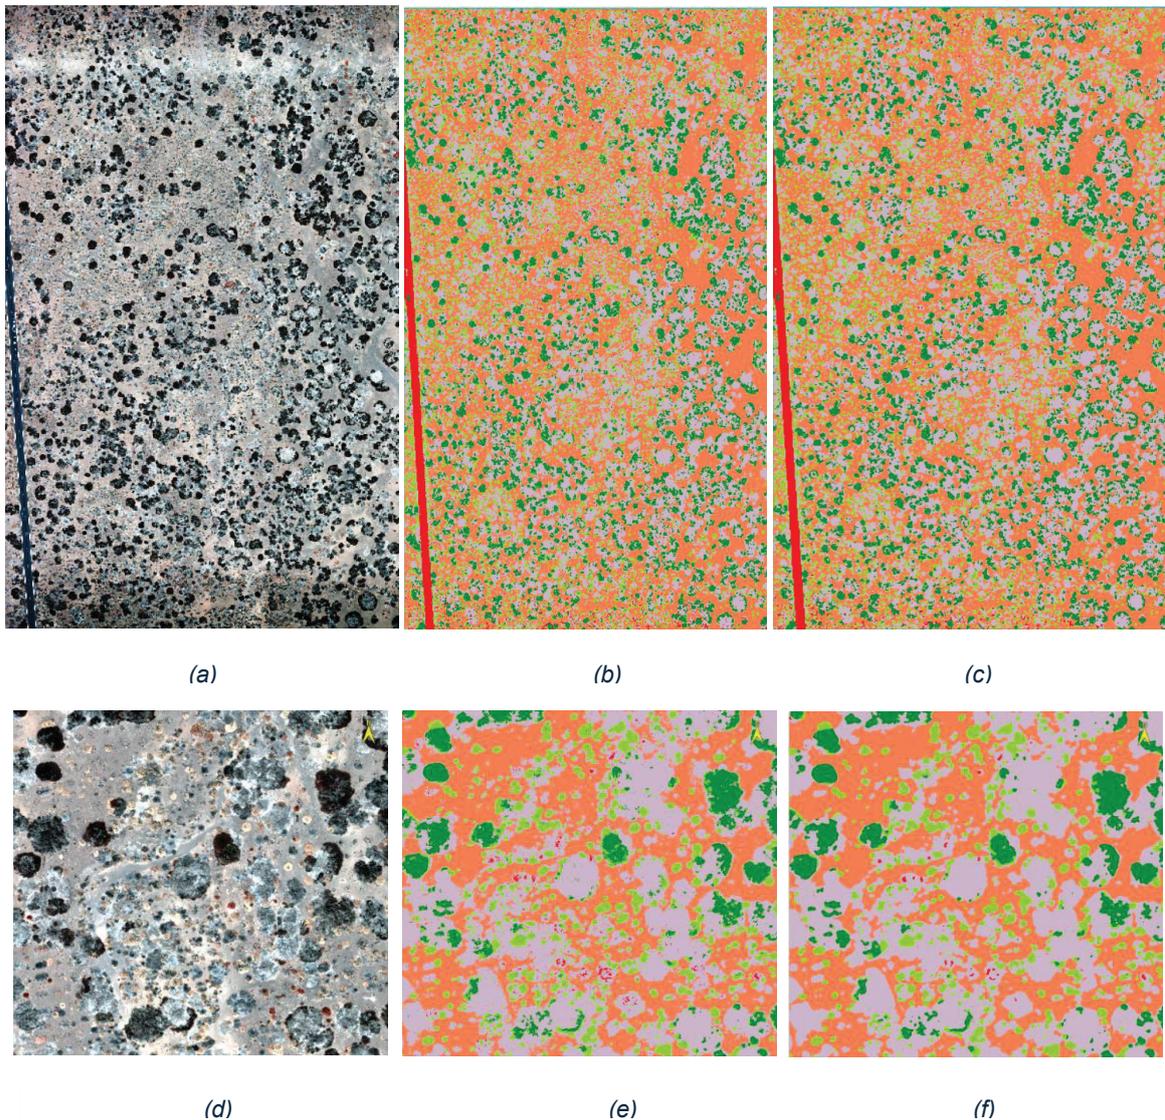


Figura 4.28 Sin clasificar. (b) Clasificada. (c) Clasificada y filtrada por mayoría. (d) Trozo de la parcela sin clasificar. (e) Trozo de la parcela clasificada. (f) Trozo de la parcela clasificada y filtrada por mayoría.

Capítulo 5 Extracción de parámetros vegetales y análisis de cambios

En este capítulo se aplicarán las técnicas de segmentación a la parcela para extraer los parámetros de superficie de copa y volumen de las retamas. Además, se han detectado los cambios con respecto a estudios previos realizados en 2019.

5.1 Segmentación

La segmentación es una técnica de procesamiento de datos que permite dividir una nube de puntos en distintos segmentos. En el ámbito forestal, usualmente se realizan segmentaciones con el fin de separar la vegetación, de forma que se pueda identificar individualmente cada ejemplar. Este método es muy importante en el análisis forestal, ya que ofrece una mejora a la hora de visualizar la parcela, además de que permite extraer atributos individuales de cada árbol, como la altura, el diámetro de copa, el área o el volumen de cada árbol. En la Figura 5.1 se muestra el resultado de la segmentación aplicada a una parcela.

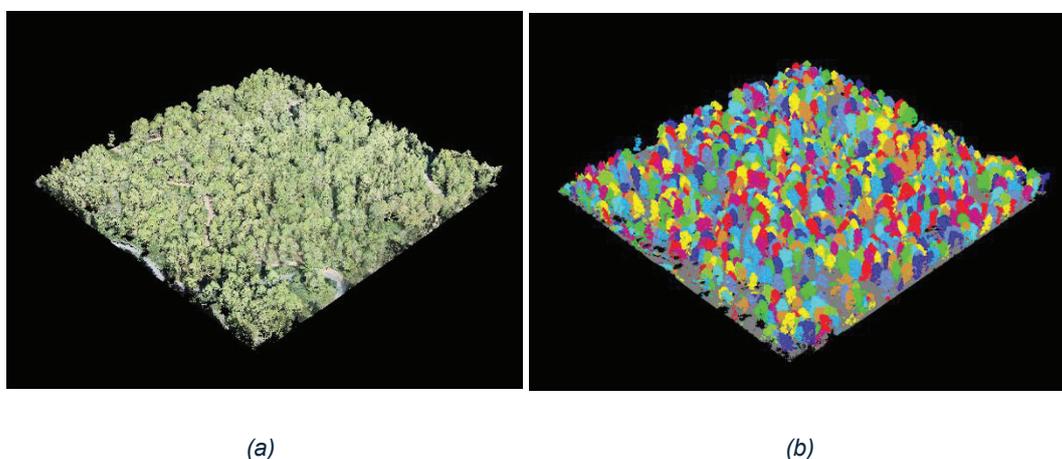


Figura 5.1 Nube de puntos: (a) RGB. (b) Segmentada.

En el caso del presente TFG, se aplicó una segmentación para separar individualmente cada retama dentro de la parcela estudiada. El proceso se realizó con el software LiDAR360, usando la nube de puntos LiDAR inicial.

El primer paso previo a la segmentación es recortar la parcela con el fin de ajustarla a las imágenes recortadas en el capítulo anterior. Para ello, en QGIS se creó un polígono manualmente con el área exacta del recorte realizado en el capítulo anterior. Posteriormente

en LiDAR360 se usó la herramienta “Clip by Polygon” y se recortó la nube de puntos con el polígono creado en QGIS.

Seguidamente, se debe normalizar la nube de puntos, es decir, restar la altura del suelo a cada punto para que las alturas se muestren con respecto al nivel del suelo local en vez de la elevación. En LiDAR360 se puede realizar automáticamente mediante la herramienta “Normalize by Ground Points”.

En el proceso de segmentación son necesarios puntos o regiones iniciales que se usan como base para iniciar el proceso de segmentación, conocidos como semillas. A partir de estas semillas, el algoritmo agrupa otros puntos cercanos que comparten ciertas características. El software LIDAR360 genera estas semillas de varias maneras diferentes. La forma más sencilla es usando la herramienta “Point Cloud Segmentation”, la cual genera directamente las semillas y posteriormente segmenta en función de diferentes parámetros. Los más importantes son “Height Above Ground” y “Minimum Tree Height”, referidos a la altura de vegetación a partir de la cual se segmenta. Todos los puntos que no superen ese valor serán ignorados y por tanto no se segmentarán.

Como solo se pretenden analizar las retamas, la altura a partir de la cual se debe segmentar debe ser superior a la máxima altura y del resto de la vegetación, puesto que las retamas constituyen el tipo de vegetación con mayor altura de la parcela. Para determinar el umbral se realizaron medidas de la altura de las retamas y de la vegetación herbácea cuya altura se aproxima más a la de las retamas. En términos generales, las retamas más pequeñas miden aproximadamente 1 metro en su punto más alto, mientras que el resto de vegetación apenas llega a 0.8 metros. Con estas mediciones se decidió fijar el valor de “Height Above Ground” y “Minimum Tree Height” a 1 metro para segmentar la parcela.

En la Figura 5.2 se muestra un ejemplo de altura de retama y de otra vegetación.

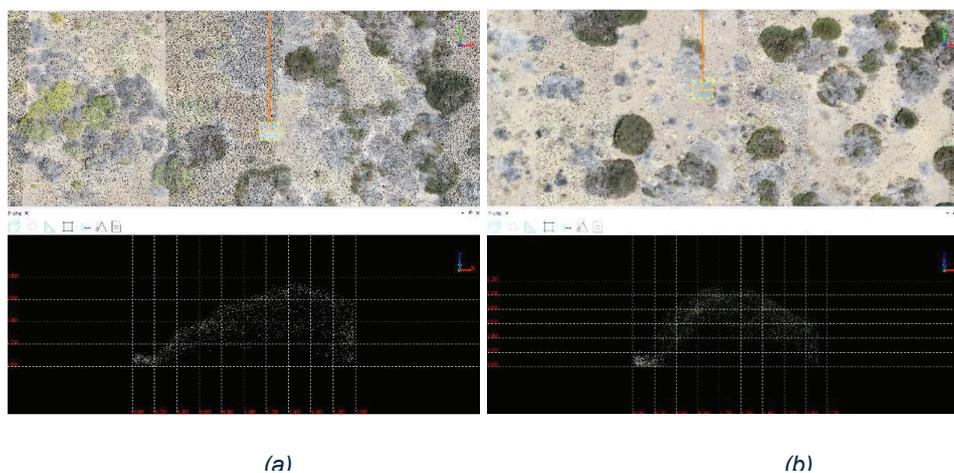


Figura 5.2 (a) Altura otra vegetación. (b) Altura retama.

El resultado obtenido de la generación de semillas y segmentación mediante la herramienta “Point Cloud Segmentation” con umbral de 1 metro generó correctamente las semillas, pero no se consiguió capturar la superficie completa de las retamas. Esto es debido a que el algoritmo ignora todos los puntos que no superen el umbral y, por tanto, no se segmentan puntos inferiores a 1 metro, en los cuales se encuentran la mayoría de los puntos correspondientes a las retamas, ya que el valor de 1 metro corresponde al valor máximo de la altura de estas mismas.

Por este motivo, se probó una nueva segmentación con un umbral de 0.6 metros, con el fin de comprobar si el algoritmo es capaz de segmentar con mejor precisión la retama completa. En la Figura 5.3 se muestran los resultados de la segmentación con umbrales de 1 y de 0.6 metros.

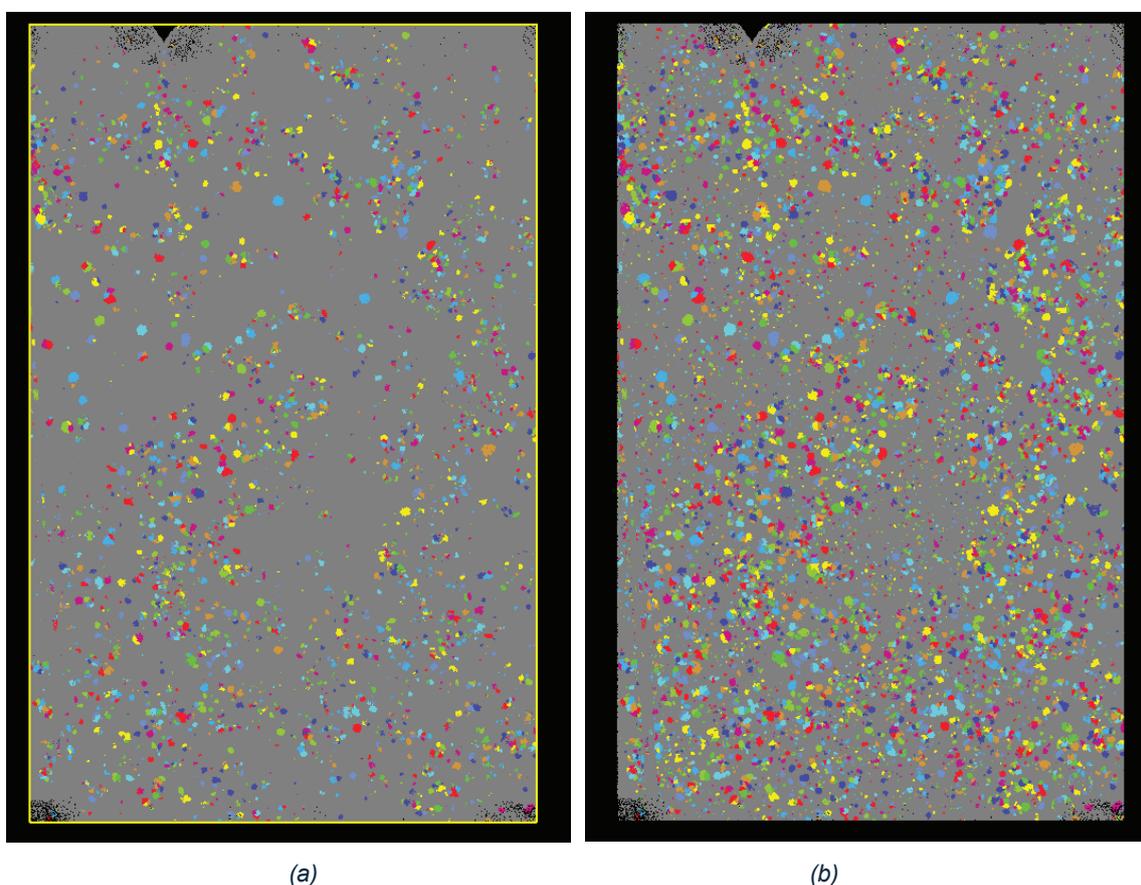


Figura 5.3 Segmentación con umbral de: (a) 1 metro. (b) 0.6 metros.

Como puede observarse, en la segmentación de 0.6 metros se generan semillas que no corresponden a retamas y, por lo tanto, se segmenta también otro tipo de vegetación.

En este punto, se decidió realizar la segmentación en dos pasos. En el primero, se generan las semillas mediante la herramienta “Generate Seed Points From Layer Stacking” en el

LiDAR360, mientras que en el segundo, se genera la segmentación partiendo de las semillas anteriores mediante la herramienta “*Point Cloud Segmentation From Seed Points*”. De esta forma, en el primer paso se generarían las semillas correspondientes a retamas, por lo que habría que poner un valor umbral de 1 metro, y en el segundo paso se construiría la segmentación únicamente de las retamas, pudiendo escoger un valor umbral de 0.7 metros para que la segmente completa.

Una vez generadas las semillas, se eliminaron aquellas que no pertenecieran a retamas, ya que aunque se le aplicara el filtro de 1 metro, existen algunos ejemplares de otro tipo de vegetación que sobrepasaba el metro. En la Figura 5.4 se puede observar como el algoritmo generó semillas en otro tipo de vegetación que no era retama y como se eliminó dejando solo estas últimas.

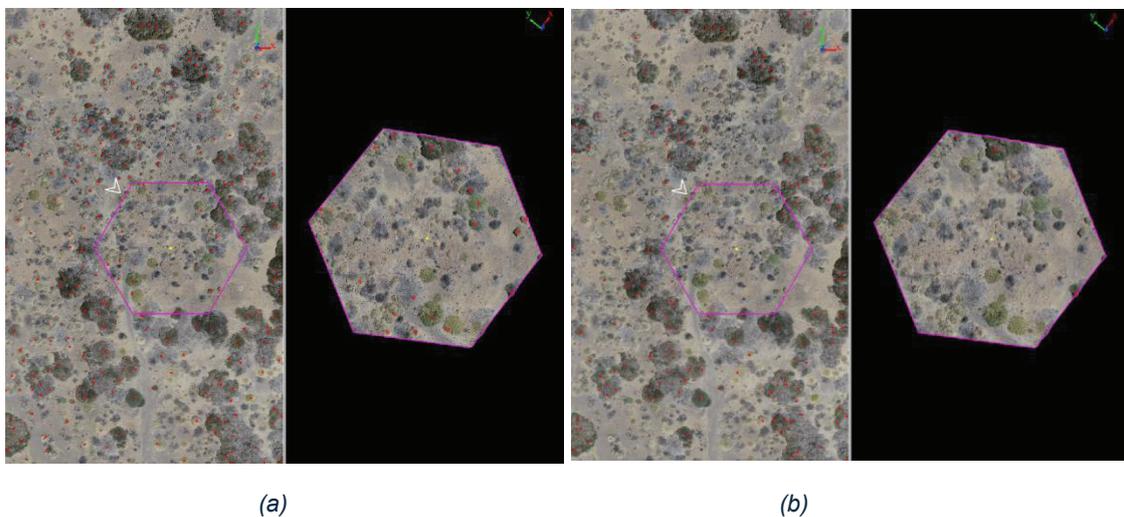


Figura 5.4 (a) Semillas generadas con umbral de 1 metro. (b) Semillas generadas con umbral de 1 metro corregidas.

Finalmente se generó la segmentación basada en las semillas generadas de 1 metro corregidas con el filtro en 0.7 metros para segmentar la retama entera. El resultado visual fue correcto para las retamas más grandes, no obstante, para retamas pequeñas o retamas muertas, ocurrieron algunos problemas. En la Figura 5.5 se muestra el resultado final de la segmentación.

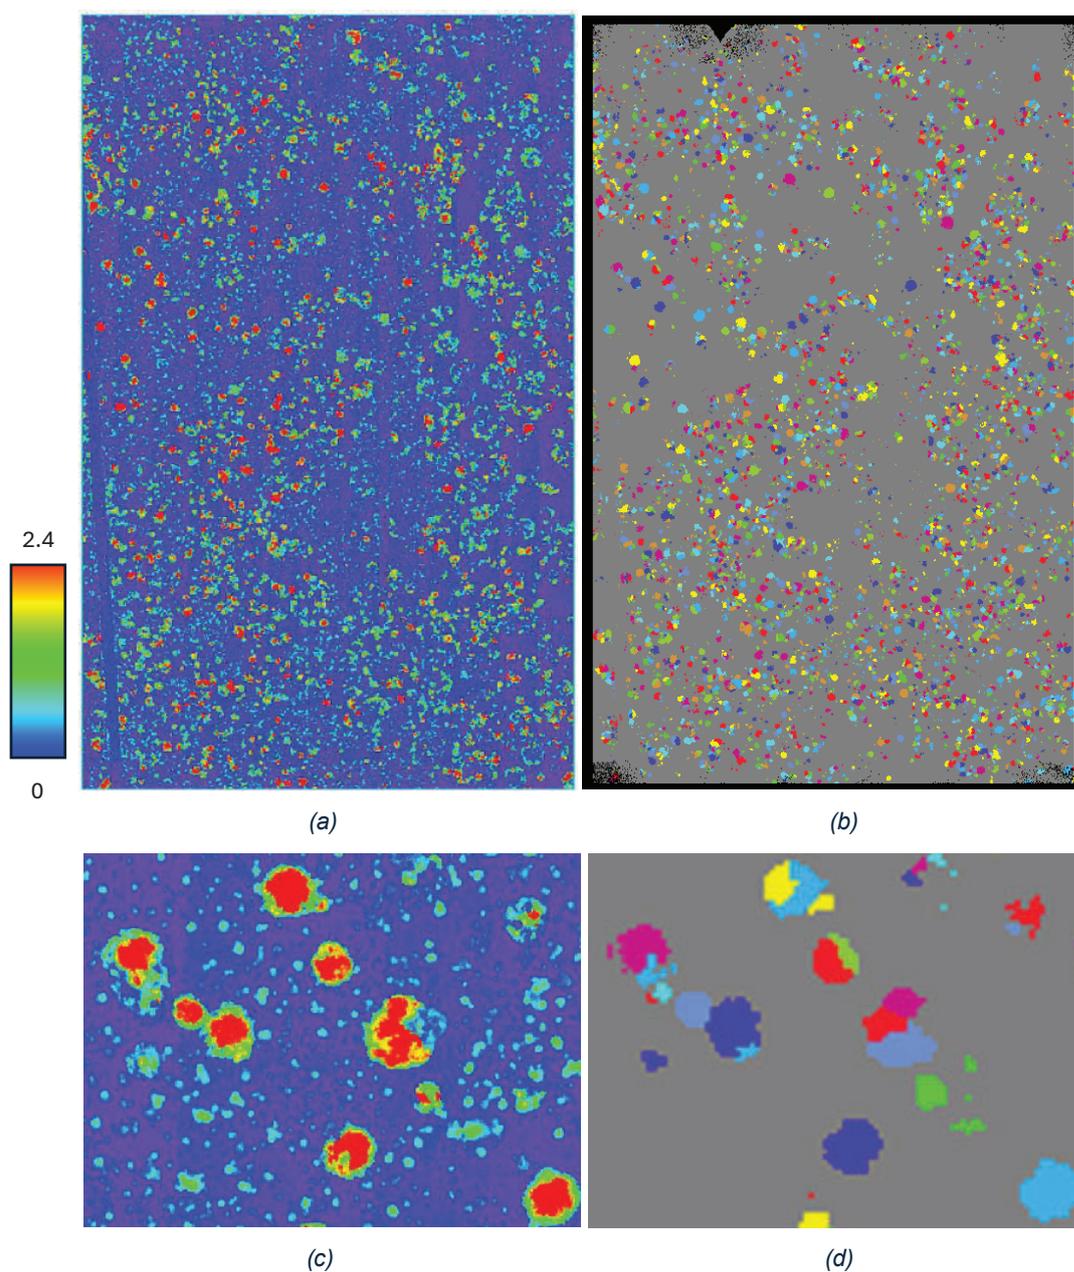


Figura 5.5 (a) CHM. (b) Parcela segmentada final. (c) Trozo del CHM. (d) Trozo de la parcela segmentada final.

El problema de la segmentación de retamas es altamente complejo. Por ejemplo, las retamas con pérdida de vigor vegetal normalmente carecen de vegetación en el centro, siendo los bordes el lugar en el que se concentra la esta. Por este motivo, el algoritmo en vez de identificar una única retama considera diferentes retamas más pequeñas en los bordes de la retama desvitalizada. En la Figura 5.6 se pueden observar ejemplos en los cuales una retama muerta es segmentada en varias retamas pequeñas alrededor de los bordes.

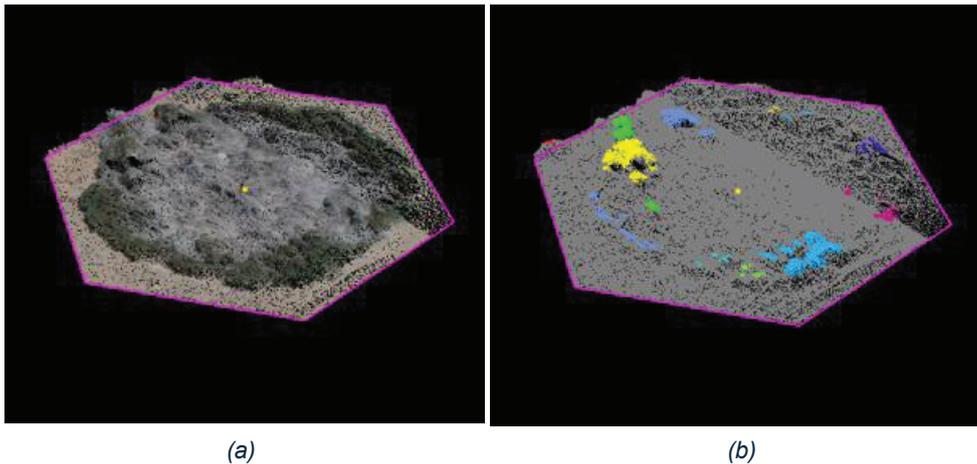


Figura 5.6 (a) Retama muerta. (b) Retama muerta segmentada en varias diferentes.

Pese a estos problemas, la segmentación en retamas saludables y grandes ha sido exitosa, permitiendo la extracción de parámetros como altura, área y volumen de cada ejemplar individualmente. En la Figura 5.7 se muestra el ejemplar de retama 503 y su correcta segmentación con los atributos de posición, altura, diámetro, área y volumen en la Tabla 5.1. En la Figura 5.8 por su parte, se muestra la comprobación de las estadísticas de y diámetros medidos manualmente en el LiDAR360.

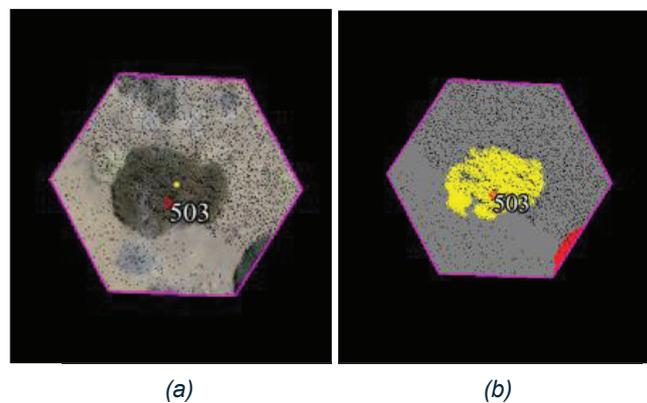


Figura 5.7 (a) Retama grande. (b) Retama grande segmentada correctamente.

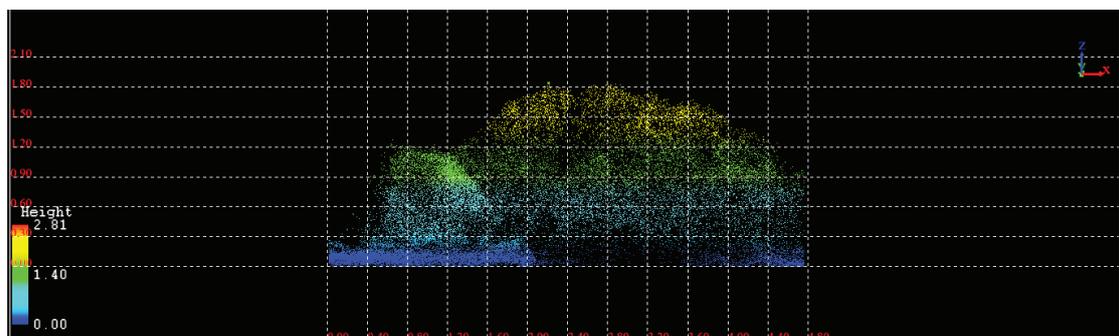


Figura 5.8 Medidas de la retama.

Tabla 5.1 Parámetros de la retama 503.

Altura (m)	Diámetro (m)	Área (m ²)	Volumen (m ³)
1.8	4.6	15	29

Como se puede observar en la Tabla 5.1, la altura de la retama es de 1.8 metros, que coincide con el valor medido manualmente en la Figura 5.8. El diámetro por su parte es de 4.6 metros, coincidiendo también con el medido en la Figura 5.8. De la tabla se extraen que sus atributos de área y volumen son de 15 m² y 29 m³ respectivamente.

5.2 Extracción de parámetros

Al finalizar la segmentación, el software LiDAR360 genera un archivo csv con los atributos individuales de cada elemento segmentado. Para analizar el área y volumen total de retamas en la parcela, se hizo uso de Excel. Se importó el archivo csv y se calculó la suma total del área y volumen de todas las retamas individuales, además del promedio de altura y diámetro. Los resultados obtenidos se muestran en la Tabla 5.2.

Tabla 5.2 Estadísticas de la segmentación de retamas.

Media de altura (m)	Media de diámetro (m)	Área total (m ²)	Volumen total (m ³)
1.3	2.5	24.238	31.381

Con el fin de verificar la fiabilidad del cálculo del área, se comprobó la cantidad de píxeles clasificados como retama en la clasificación de la imagen multiespectral fusionada en 11 bandas con el mapa de alturas CHM usando el algoritmo SVM. La cantidad de píxeles de retama fueron de 2.017.867. Teniendo en cuenta que la resolución de la imagen es de 10 cm x 10 cm, el área total de retamas en metros cuadrados ascendería a 20.178,67 m².

Como se puede observar, al área total proporciona una buena estimación, aunque la segmentación de las retamas no fuera excelente. El problema de segmentar una misma retama muerta en varias retamas pequeñas no fue un problema para el cálculo total del área, ya que aunque se generen más elementos segmentados, la suma no varía.

5.3 Análisis de los cambios en la retama con respecto a 2019

El análisis de los cambios obtenidos se realizará en una subparcela de la imagen multiespectral en la que hay datos para ambas fechas. En esta subparcela se dispone de un mapa segmentado manualmente de las retamas de 2019, que fue previamente registrado en

el capítulo anterior con las imágenes multiespectral y LiDAR del año 2024. En la Figura 5.9 se muestra dicha subparcela.

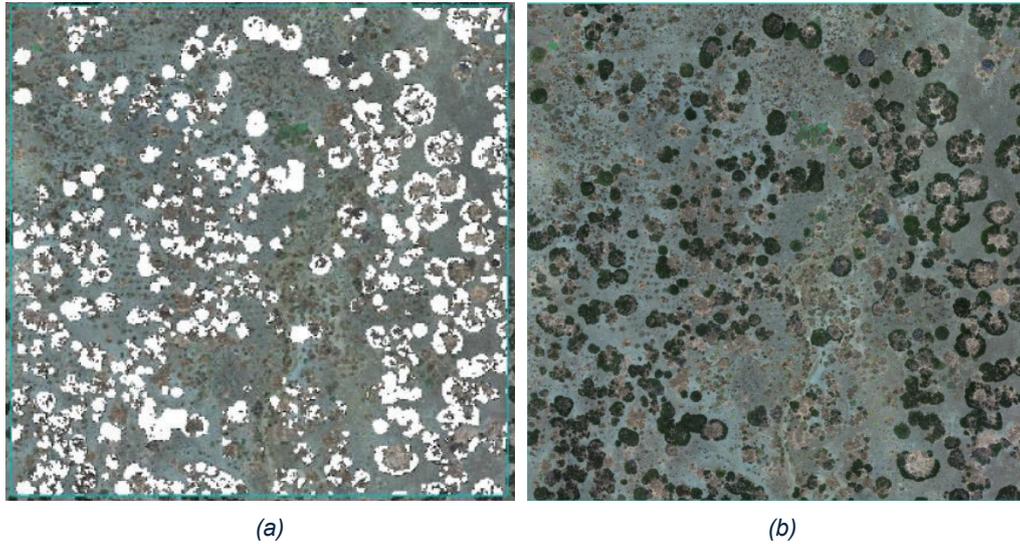


Figura 5.9 (a) Subparcela segmentada del año 2019. (b) Subparcela RGB del año 2019.

El diagrama de bloques del procedimiento seguido para la detección de los cambios se presenta en la Figura 5.10 en un diagrama de bloques.

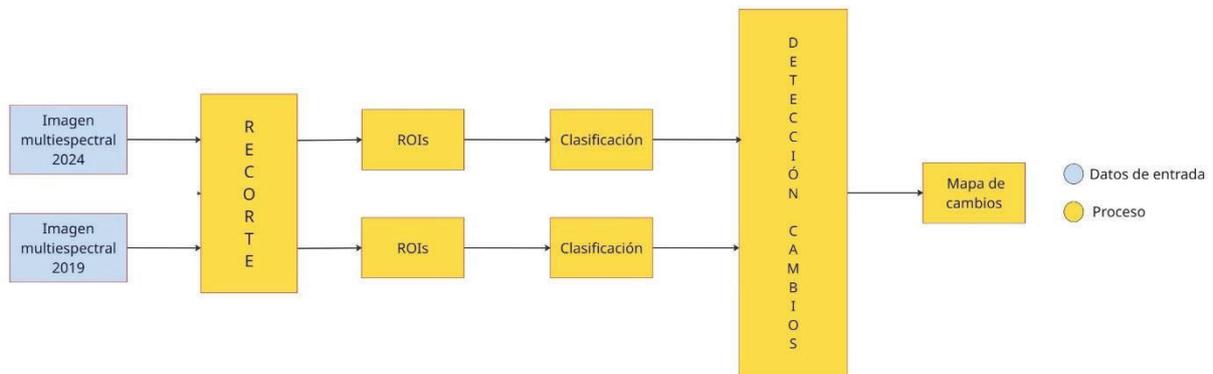


Figura 5.10 Diagrama de bloques del procedimiento de la detección de cambios.

5.3.1 Clasificación de la subparcela

El primer paso consiste en recortar las imágenes multiespectrales del año 2019 y 2024 en función de la subparcela de las retamas segmentadas. Para ello se creó una ROI con la dimensión específica de la parcela y posteriormente se usó la herramienta “Subset Data From ROIs” para recortar tanto la imagen multiespectral del año 2024 como la del 2019.

En el segundo paso se volvieron a generar las ROIs en la imagen del año 2024, ya que los ROIs usados en la clasificación del capítulo anterior no contenían suficientes regiones de entrenamiento dentro de la subparcela. Además, se eliminó la clase “Otros” (carretera), ya que

en la subparcela no hay píxeles de esa clase. También se generaron las nuevas ROIs para la imagen del año 2019, ya que en muchos algunos la vegetación no coincidía en ambas imágenes debido a los cambios a lo largo de los 5 años

Finalmente, se clasificaron ambas imágenes multiespectrales con el algoritmo SVM. Para el caso de la imagen del año 2024, el resultado obtenido fue prácticamente idéntico al obtenido al clasificar la parcela entera, con la diferencia de que al no contener la clase “Otros” en la clasificación de la subparcela se eliminaron los pequeños pixeles que en la anterior clasificación se clasificaron con esa clase, proporcionando por tanto un resultado más fiable.

A ambas imágenes se les aplico el filtrado de mayoría con una ventana de 5x5 píxeles. En la Figura 5.11 se muestran los resultados de la clasificación para la imagen del 2024 y del 2019.

Por otra parte, en la Figura 5.12 se muestra la clasificación del año 2019 superpuesta al mapa de retamas segmentado manualmente, con el fin de comprobar la fiabilidad de la clasificación de las retamas.

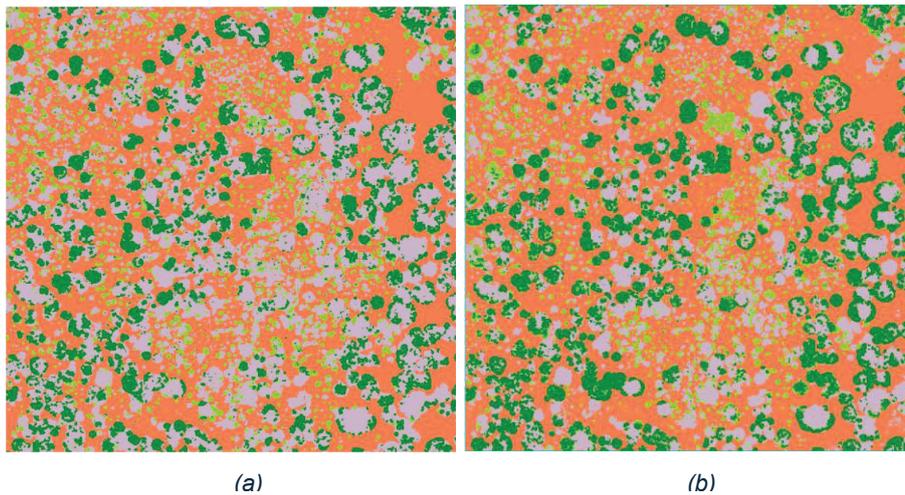


Figura 5.11 Clasificación de la subparcela del año: (a) 2024. (b) 2019.

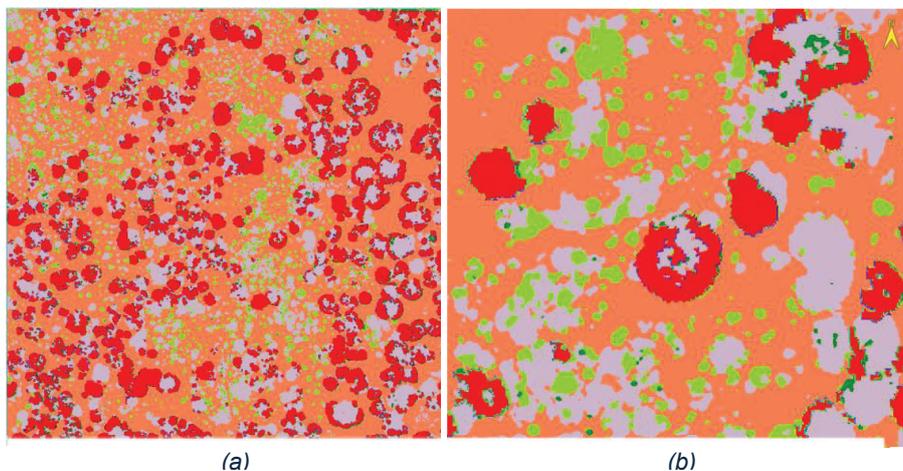


Figura 5.12 Mapa de retamas segmentado superpuesto a la clasificación: (a) Completo. (b) Ampliado.

Como puede observarse en la Figura 5.12, la clasificación de las retamas es bastante fiable, ya que apenas existen regiones de retamas (color verde) fuera de las existentes en el mapa segmentado (color rojo).

5.3.2 Detección de cambios

El primer paso a realizar en este subapartado es comprobar la cantidad de píxeles de diferencia que existen en la clase “Retamas” de cada imagen clasificada para estimar la superficie de retamas perdida a lo largo de los 5 años. En la Tabla 5.3 muestra la superficie total d retamas para cada año.

Tabla 5.3 Estadísticas de la segmentación de retamas.

Superficie 2019 (m)	Superficie 2024 (m²)
7.928,8	6.320,96

La diferencia del total de superficie que abarcan las retamas en cada año es de 1.607,4 m², indicando por tanto la cantidad total de retamas perdida a lo largo de 5 años.

Con este resultado, se decidió generar un mapa clasificado con los cambios detectados en la subparcela. Para ello, ENVI ofrece una herramienta llamada “Thematic Change” que detecta los píxeles que han cambiado de una imagen clasificada de referencia con respecto a otra imagen en función de las clases de cada una. El algoritmo genera un mapa en el cual asigna un color diferente a los píxeles que han cambiado de una clase a otra, por lo que de cada clase (retama, suelo, vegetación muerta, otra vegetación y no clasificado) se especifica que píxeles han pasada de dicha clase a cualquiera de las otras cuatro, incluyendo aquellos píxeles que se mantienen constantes en ambas clasificaciones. En la Figura 5.13 se muestra el resultado del mapa con la detección de cambios incluyendo la leyenda con el color de cada cambio.

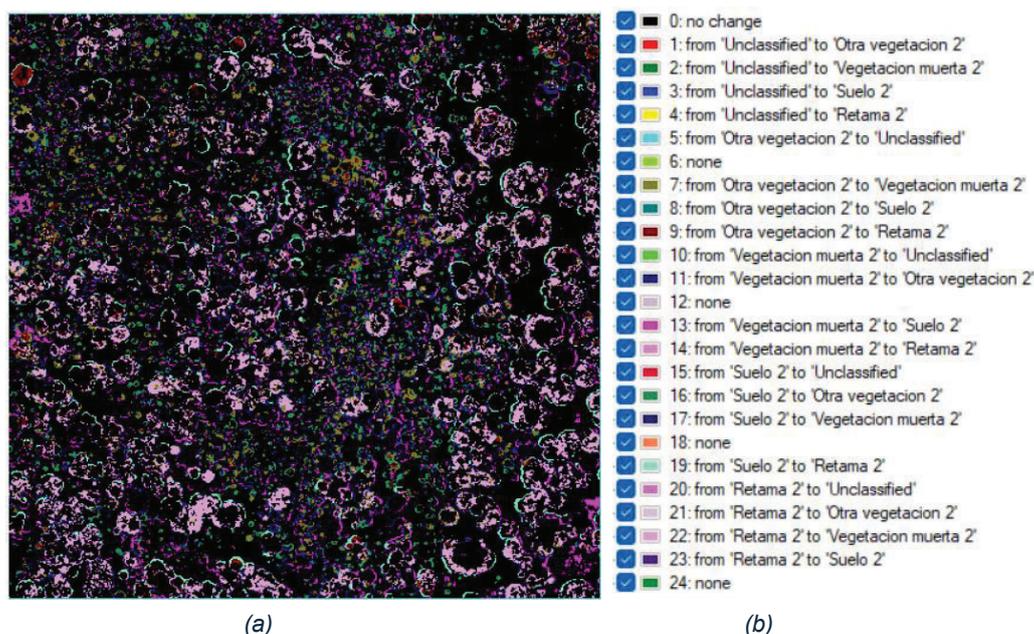


Figura 5.13 (a) Cambios detectados en la parcela. (b) Leyenda.

En la Tabla 5.4 se muestran las estadísticas de los cambios, mientras que en la Tabla 5.5 se muestran los cambios únicamente en las retamas.

Tabla 5.4 Estadísticas de los cambios detectados.

Cambios	Píxeles	Porcentaje	Porcentaje total
Total	2955652	73.486682	73.486682
Otra vegetación - Vegetación muerta	120131	2.986830	76.473512
Otra vegetación - Suelo	29939	0.744376	77.217888
Otra vegetación - Retama	39824	0.990148	78.208037
Vegetación muerta - Otra vegetación	34917	0.868145	79.076182
Vegetación muerta - Suelo	109609	2.725220	81.801401
Vegetación muerta - Retama	52451	1.304095	83.105496
Suelo - Otra vegetación	113611	2.824722	85.930218
Suelo - Vegetación muerta	187963	4.673344	90.603562
Suelo - Retama	62434	1.552303	92.155865
Retama - Otra vegetación	8811	0.219069	92.374934
Retama - Vegetación muerta	294374	7.319051	99.693985
Retama - Suelo	12308	0.306015	100.000000

Tabla 5.5 Estadísticas de los cambios detectados en retamas.

Retama - Otras clases			Otras clases - Retama		
Retama - Otra vegetación (m ²)	Retama - Vegetación muerta (m ²)	Retama - Suelo (m ²)	Otra vegetación - Retama (m ²)	Vegetación muerta - Retama (m ²)	Suelo - Retama (m ²)
88,11	2.943.74	123,08	3.98,24	524,51	624,34
Retama perdida (m ²): 3.154,93			Retama nueva (m ²): 1.547,09		

Pérdida total (m²): 1.607,84

Como puede observarse en las tablas anteriores, la diferencia de retamas entre ambos años no se debe simplemente a que las retamas se hayan muerto, sino que también han crecido en algunas zonas, aunque en menor medida en comparación con la pérdida.

El cambio de retama a otro tipo de clase es de 3.155,93 metros cuadrados, de los cuales 2.943,74 m² constituyen el cambio de retama viva a muerta. El resto (211,19) constituyen al cambio de retama a otra vegetación o a suelo, que pueden deberse a posibles errores en la clasificación tanto del año 2019 como del 2024, ya que idealmente el cambio de retama a suelo o a otra vegetación debe pasar antes por vegetación muerta. No obstante, estos cambios suponen únicamente un 7.17 % de los cambios de retama a otra clase, por lo que se justifica que se deba a algún pequeño error en la clasificación.

Por otra parte, se ha detectado un aumento de las retamas en ciertas zonas con un total de 1.547,09 metros cuadrados, obteniendo una diferencia total en el área de las retamas entre 2019 y 2024 de 1.607,84 metros cuadrados.

Dado que la visualización de los datos en el mapa clasificado anterior dificulta la observación los cambios de las retamas, en la Figura 5.14 se muestran los cambios de retama a vegetación muerta sobre la imagen multiespectral de 2024, con el fin de verificar que cantidad de retamas han muerto a lo largo de los cinco años.

Por otra parte, en la Figura 5.15 se muestra las nuevas regiones de retama que han crecido mediante la superposición de los cambios detectados en las nuevas retamas y la imagen multiespectral de 2019. Los cambios de otra vegetación, vegetación muerta y suelo a retama se muestran en color verde, rojo y naranja respectivamente.

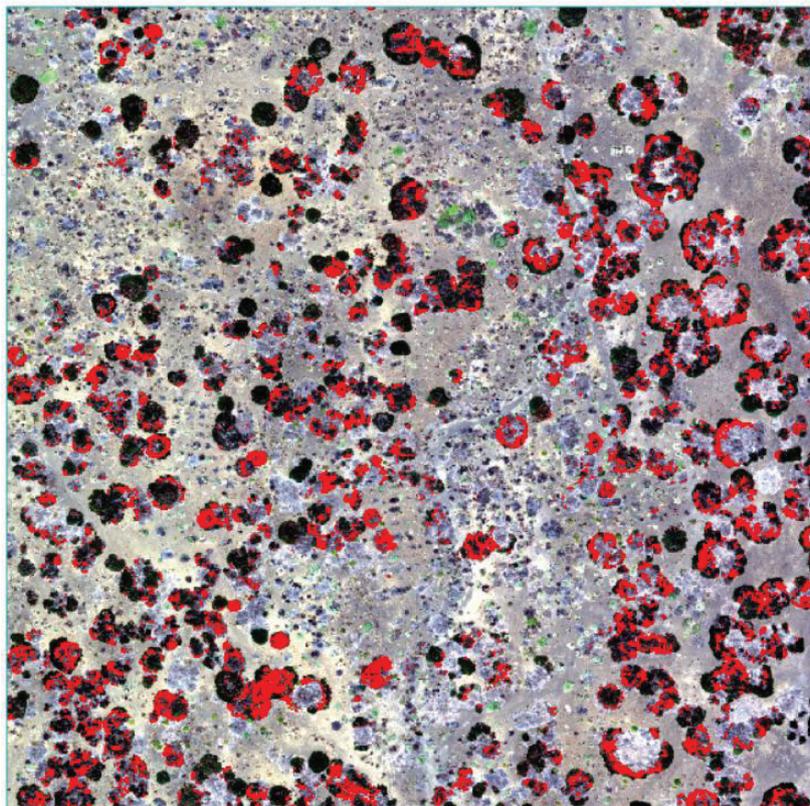


Figura 5.14 Cambio de retama de vegetación muerta.

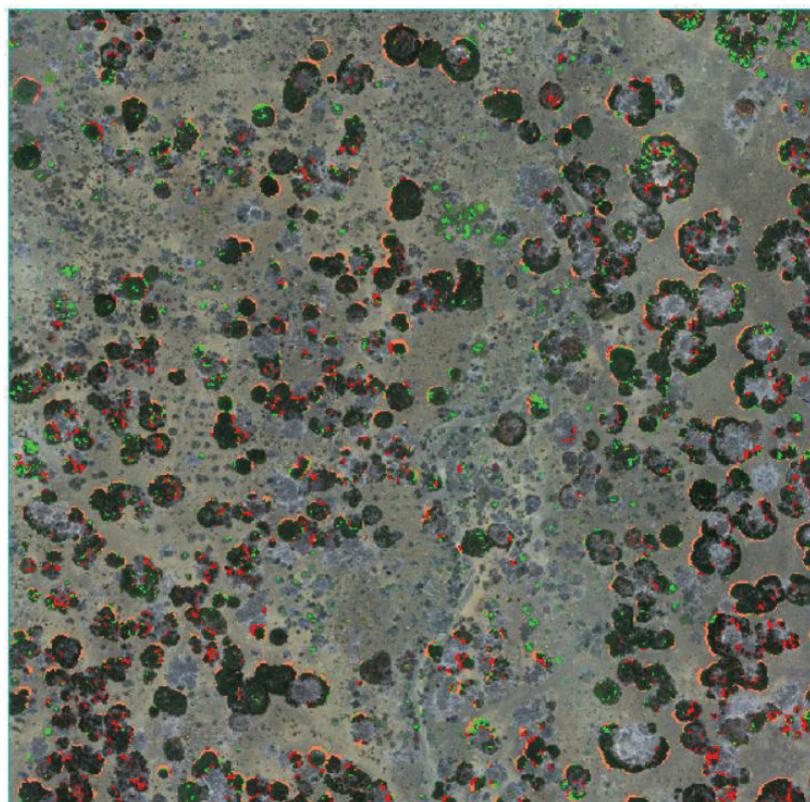


Figura 5.15 Cambio de otra clase a retama.

En conclusión, entre 2019 y 2024 se perdió una superficie de retamas de 1.607.84 metros cuadrados. En la Figura 5.14 se muestran las retamas que murieron entre 2019 y 2024 superpuestas a la imagen multiespectral del año 2024 y en la Figura 5.15 las nuevas retamas que han aparecido superpuestas a la imagen multiespectral del año 2019.

Adicionalmente, se han analizado las estadísticas altura, diámetro medio y volumen total de retamas mediante el software LiDAR360 únicamente para la parcela menor, en la cual existe coincidencia entre los datos de 2019 y 2024.

Para ello se hicieron pruebas de segmentación con diferentes filtros de altura a partir de las mismas semillas generadas en el subapartado anterior recortadas para esta subparcela, con el fin de verificar cuál de ellas conseguía acercarse más al resultado de superficie obtenido en la clasificación multiespectral.

Inicialmente se hicieron medidas de la altura media de las retamas en la subparcela, llegando a la conclusión de que la mayor parte de las retamas se encuentran entre 0.7 y 0.8 metros de altura. Los filtros de altura probados para la segmentación de la subparcela fueron de 0.7, 0.75 y 0.8 metros.

En la Tabla 5.6 se muestran los resultados obtenidos al sumar la superficie total de retamas para cada caso.

Tabla 5.6 Superficie total de retamas.

Filtro 0.7 metros	Filtro 0.75 metros	Filtro 0.8 metros
6.845	5.841,4	5.100,5

Dado que la superficie de retamas extraída de la clasificación multiespectral es de 6.320,96 m², y la superficie para los filtros de altura de 0.7 y 0.75 es de 6.845 y 5.841,4 m² respectivamente, se realizó otra prueba con filtro de altura a 0.725 con el fin de comprobar si la superficie de retamas se aproxima más a la obtenida de la clasificación multiespectral. El resultado obtenido fue de 6.302,8 m², por lo que finalmente se decidió utilizar la parcela segmentada con el filtro de altura de 0.725 metros para la extracción de los atributos. La segmentación final de la parcela se muestra en 2D y 3D en el Figura 5.16.

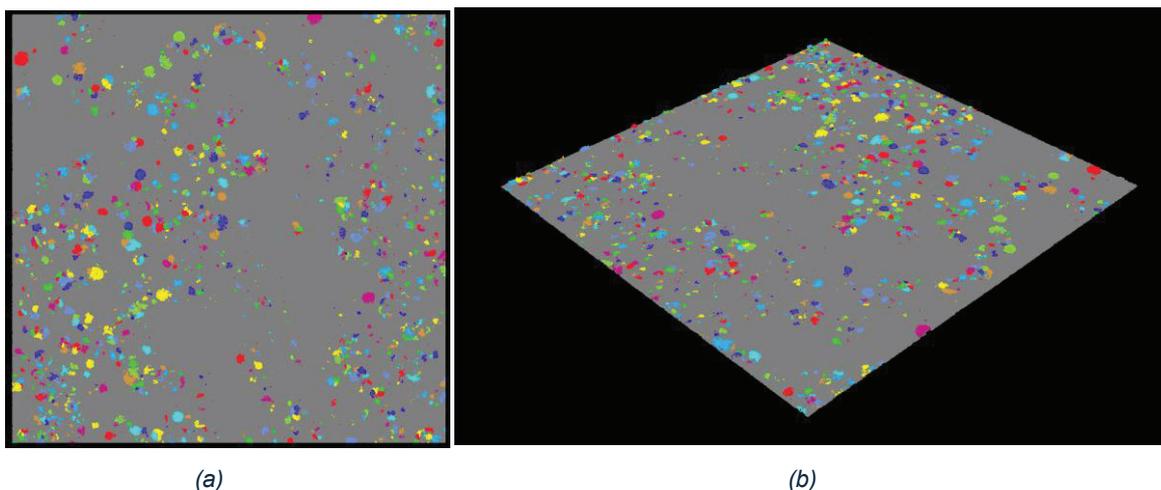


Figura 5.16 Segmentación final: (a) 2D. (b) 3D.

Como puede observarse en la Figura 5.16, la segmentación de retamas no ofrece resultados visualmente perfectos, ya que segmenta por altura al tratarse de datos LiDAR, y no por características espectrales como otros métodos o técnicas de clasificación. En la imagen se pueden observar retamas segmentadas muy pequeñas, que corresponden a retamas más grandes que el algoritmo no segmenta por que gran parte de esa retama no supera la altura del filtro. En el caso de bajar la altura del filtro, puede ser que el algoritmo segmente vegetación más baja que no constituya retama, por lo que la mejor opción y la que más se aproxima al resultado multiespectral es el resultado de aplicar el filtro de altura a 0.725 metros.

Como se indicó, también se observan retamas individuales que están segmentadas en varias retamas diferentes. Esta situación corresponde, mayoritariamente a retamas cuyo entro está muerto y en las que la vegetación viva se encuentra en los bordes. Esto es debido a que el algoritmo utilizado está principalmente orientado a la segmentación de árboles, donde normalmente el centro de la copa constituye el punto de mayor altura, mientras que en el caso de estas retamas, los bordes constituyen la parte más alta.

En la Tabla 5.7 se muestran los atributos extraídos de la segmentación final de la parcela.

Tabla 5.7 Estadísticas de la segmentación de la parcela.

Media de altura (m)	Media de diámetro (m)	Área total (m ²)	Volumen total (m ³)
1.3	2.4	6.302,8	8.126,2

Adicionalmente, en la Figura 5.17 se muestran los mapas clasificados en función de los atributos de altura, diámetro, superficie y volumen de cada retama.

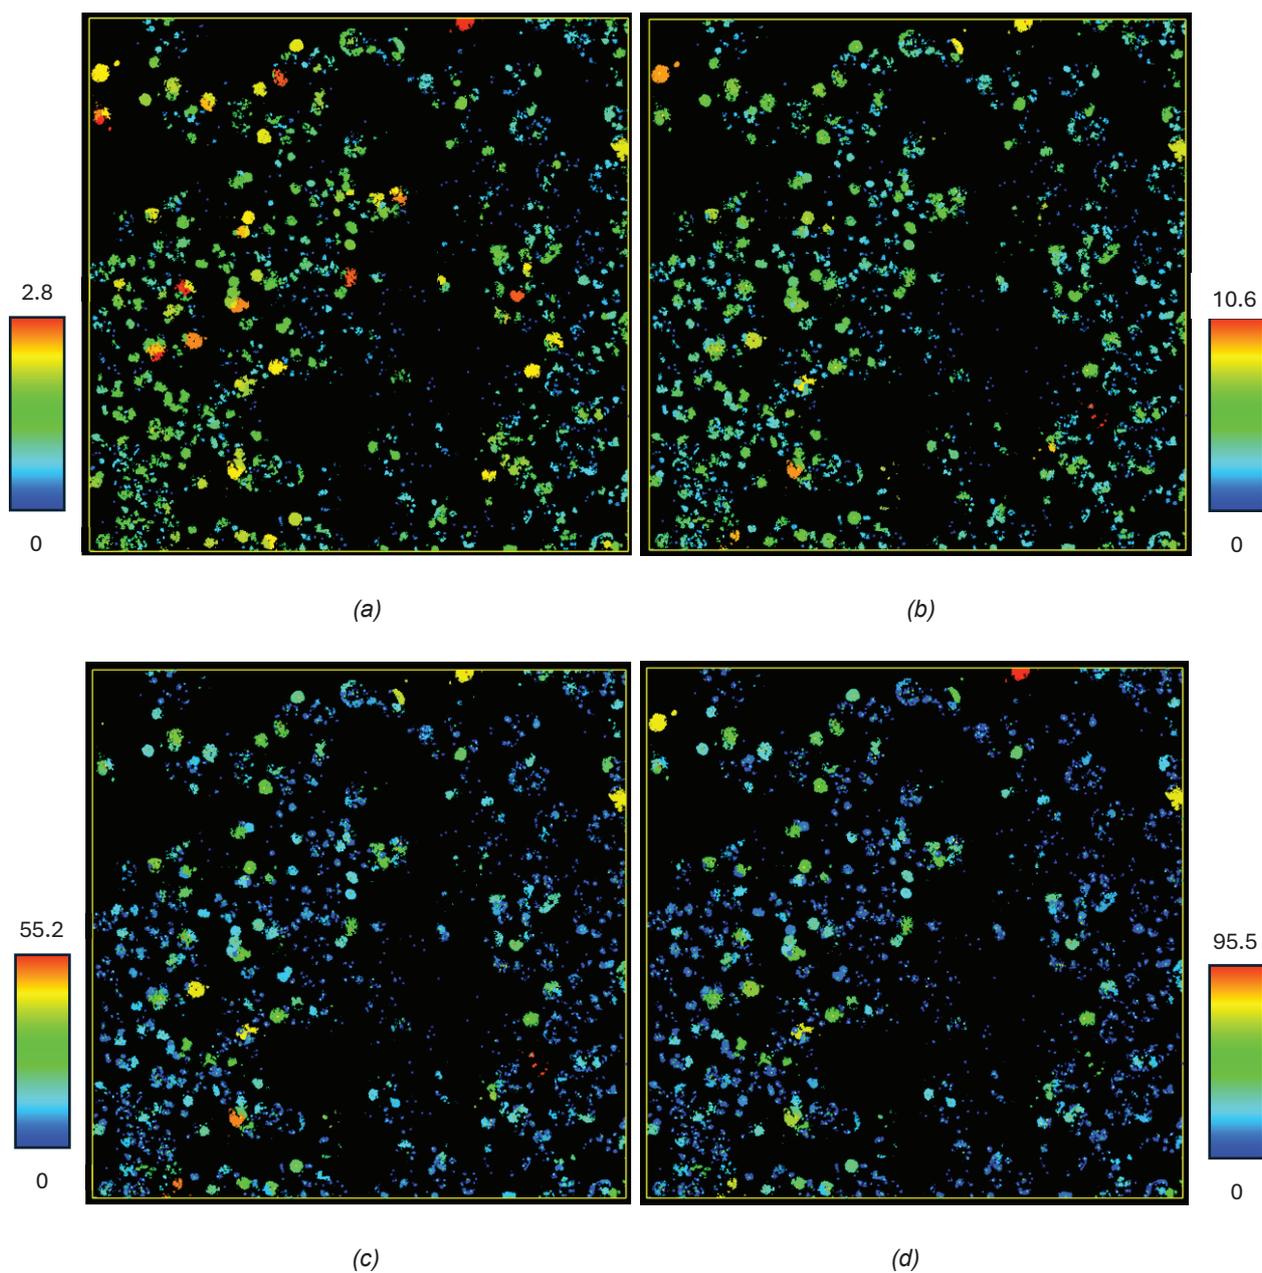
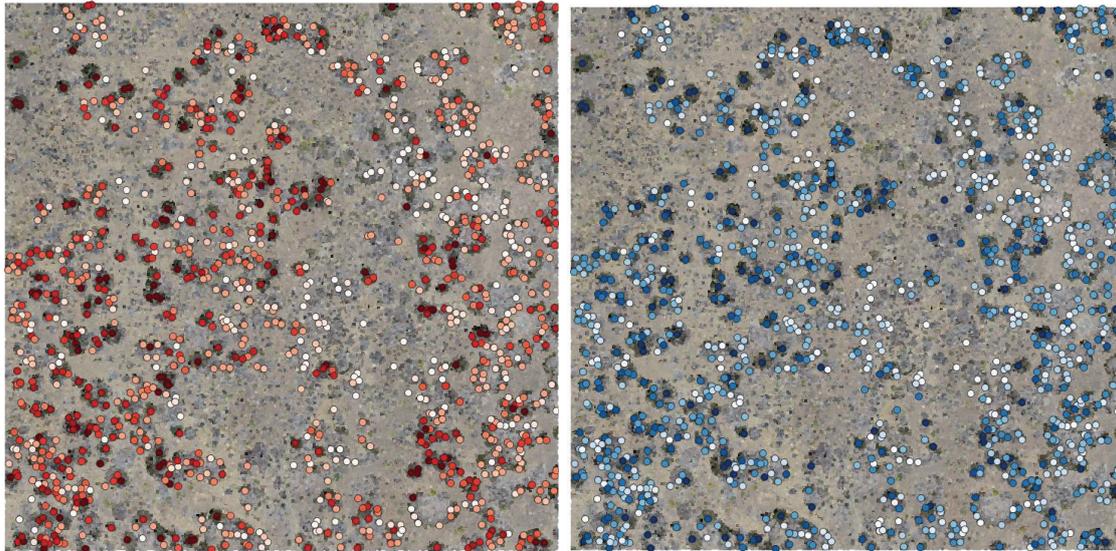


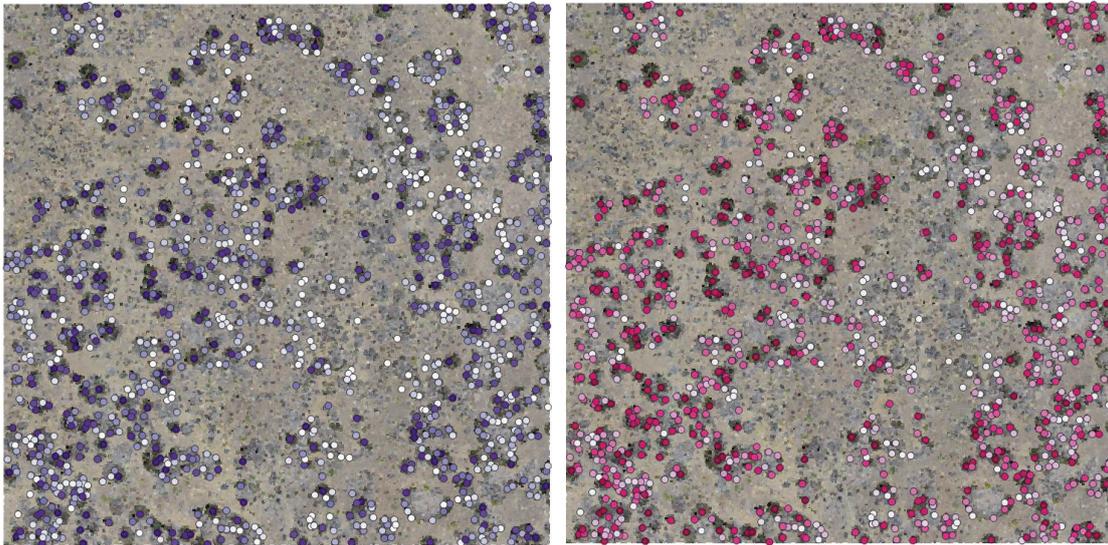
Figura 5.17 (a) Clasificación por altura. (b) Clasificación por diámetro. (c) Clasificación por superficie. (d) Clasificación por volumen.

Finalmente, en la Figura 5.18 se muestran las semillas generadas para la segmentación coloreadas en función de sus atributos y superpuestas a la nube de puntos LiDAR



(a)

(b)



(c)

(d)

Figura 5.18 (a) Semillas clasificadas por altura. (b) Semillas clasificadas por diámetro. (c) Semillas clasificadas por superficie. (d) Semillas clasificadas por volumen.

Capítulo 6 Conclusiones

En este capítulo se analizarán los resultados obtenidos y el grado de consecución de los objetivos propuestos, además de las posibles líneas futuras de investigación.

6.1 Revisión de los objetivos propuestos

Las tareas llevadas a cabo durante el desarrollo del presente Trabajo de Fin de Grado han estado orientadas principalmente al análisis del estado de las retamas en el Parque Nacional del Teide. Con el fin de lograr este objetivo, se hizo uso de datos multiespectrales para la discriminación de la vegetación muerta o desvitalizada frente a la sana; y de datos LiDAR para el estudio y análisis de la estructura de las retamas.

A partir de este objetivo general, se establecieron objetivos más específicos que fueron cumplidos mediante el desarrollo de las siguientes tareas:

- Estudio de la naturaleza de los datos multiespectrales y LiDAR y los sistemas de teledetección utilizados para su obtención. También se han estudiado las plataformas y sensores utilizadas en el proceso de captación de dichos datos.
- Estudio y aplicación de las técnicas de preprocesado de datos multiespectrales y LiDAR, incluyendo las correcciones y registro de imágenes.
- Estudio de las técnicas aplicadas para llevar a cabo el procesado de los datos multiespectrales y LiDAR, incluyendo procesos como la clasificación de imágenes multiespectrales y la segmentación de nubes de puntos LiDAR, así como el procedimiento necesario que se debe aplicar para la consecución del trabajo. También se han estudiado las herramientas software utilizadas en el proceso.
- Análisis de la estructura tridimensional de las retamas y detección de cambios con respecto a estudios previos en la estructura de las retamas.

6.2 Conclusiones del análisis de resultados

En este Trabajo de Fin de Grado se han empleado diferentes técnicas de procesado, tanto de datos multiespectrales como LiDAR, con el fin de obtener mapas vegetales clasificados,

analizar la estructura tridimensional de las retamas y detectar sus cambios a lo largo de cinco años en una parcela del Parque Nacional del Teide.

Respecto a la clasificación de los datos multiespectrales y el análisis de cambios se destaca lo siguiente:

- La discriminación entre retamas, vegetación muerta u otro tipo de vegetación en la clasificación multiespectral es completamente viable gracias a la diferente información espectral de cada clase y la aplicación de algoritmos adecuados de clasificación supervisada. Aunque en algunos casos de retamas y otro tipo de vegetación se obtuvo una firma espectral parecida y, por tanto, teóricamente una mayor dificultad de discriminación entre ambas clases, los resultados obtenidos fueron satisfactorios.
- La detección de los cambios ha sido exitosa, permitiendo generar mapas de cambios en los cuales se aprecia la evolución en la superficie total de las retamas presentes en la parcela estudiada.

Respecto al análisis de la estructura tridimensional de las retamas y la extracción de superficie y volumen de cada una mediante el uso de datos LiDAR se pueden extraer las siguientes conclusiones:

- La segmentación individual de retamas mediante datos LiDAR no es la opción más viable. Los algoritmos de segmentación en el presente Trabajo de Fin de Grado están orientados a árboles de mayor talla. En el caso que nos ocupa, se trata de arbustos de baja altura, copas redondeadas y, en muchas situaciones con la parte central de la planta desvitalizada, lo que dificulta este proceso. Por otra parte, la discriminación de las retamas con otro tipo de vegetación mediante el uso de datos LiDAR, a pesar de presentar una buena aproximación, no es completamente exacta, ya que las diferentes especies presentes en la parcela analizada presentan alturas muy similares. La altura no es el mejor parámetro para segmentar las diferentes especies de vegetación de la parcela.
- La extracción de parámetros de altura, diámetro, superficie y volumen de cada elemento segmentado individualmente fue exitoso a pesar de no conseguir una discriminación perfecta de retamas.

Se puede concluir para el Parque Nacional del Teide, y mediante el uso de datos dron, que el análisis multiespectral es la mejor opción a la hora de discriminar las diferentes especies dentro de la parcela, mientras que los datos LiDAR pueden ser útiles para el análisis individual de retamas sanas, pudiendo extraer parámetros manera bastante precisa.

6.3 Líneas de trabajo futuras

A partir del trabajo realizado y los resultados obtenidos, se proponen las siguientes líneas de investigación para futuros estudios:

- Empleo de sensores hiperespectrales o con mayor resolución para mejorar la discriminación entre especies similares.
- Combinar algoritmos de segmentación por altura y por reflectancia espectral para mejorar la discriminación entre especies vegetales.
- Evaluar el uso de técnicas de inteligencia artificial para mejorar la clasificación y segmentación.
- Desarrollar una base de datos de firmas espectrales específicas de las especies endémicas del Teide.

PARTE II: BIBLIOGRAFIA

BIBLIOGRAFIA

- [1] «Fundamentos de Teledetección espacial - ProQuest». Accedido: 9 de marzo de 2025. [En línea]. Disponible en: <https://www.proquest.com/openview/fa0851b2def4bc35d8ac1287bd08d7d0/1?pq-origsite=gscholar&cbl=1818083>
- [2] L. S.-E. Geográfico y undefined 2005, «Teledeteccion ambiental: La observacion de la Tierra desde el Espacio.», *go.gale.com*, Accedido: 16 de mayo de 2025. [En línea]. Disponible en: <https://go.gale.com/ps/i.do?id=GALE%7CA242180195&sid=googleScholar&v=2.1&it=r&linkaccess=abs&issn=16920074&p=IFME&sw=w>
- [3] «Firmas espectrales - Plan Nacional de Teledetección - PNT». Accedido: 16 de mayo de 2025. [En línea]. Disponible en: <https://pnt.ign.es/firmas-espectrales>
- [4] G. Cárdenes Díaz Tutores y J. Marcello Ruiz Francisco Eugenio González, «Fusión de imágenes multiespectrales y datos LIDAR para el análisis forestal», 2023, Accedido: 16 de mayo de 2025. [En línea]. Disponible en: <https://accedacris.ulpgc.es/handle/10553/128224>
- [5] «Teide: Ficha técnica». Accedido: 16 de mayo de 2025. [En línea]. Disponible en: <https://www.miteco.gob.es/es/parques-nacionales-oapn/red-parques-nacionales/parques-nacionales/teide/ficha-tecnica.html>
- [6] «Teide: Conservación de la biodiversidad». Accedido: 16 de mayo de 2025. [En línea]. Disponible en: <https://www.miteco.gob.es/es/parques-nacionales-oapn/red-parques-nacionales/parques-nacionales/teide/conservacion-biodiversidad.html>
- [7]. «¿Qué es la Teledetección?», Accedido: 16 de mayo de 2025. [En línea]. Disponible en: <http://www.ign.es>
- [8] «El espectro electromagnético - Plan Nacional de Teledetección - PNT». Accedido: 17 de mayo de 2025. [En línea]. Disponible en: <https://pnt.ign.es/web/guest/el-espectro-electromagn%C3%A9tico>
- [9] «El espectro visible de luz | Explora | Univision». Accedido: 3 de junio de 2025. [En línea]. Disponible en: <https://www.univision.com/explora/el-espectro-visible-de-luz>
- [10] R. M^a, N. Cerrillo, M. Ángeles, V. Martínez, A. J. Ariza, y S. Resumen, «5 Sensores, acceso y procesado de imágenes multiespectrales y térmicas de interés forestal».
- [11] «¿Qué son las firmas espectrales?» Accedido: 17 de mayo de 2025. [En línea]. Disponible en: <https://geoinnova.org/blog-territorio/firmas-espectrales/>
- [12] «Firmas espectrales - Plan Nacional de Teledetección - PNT». Accedido: 17 de mayo de 2025. [En línea]. Disponible en: <https://pnt.ign.es/firmas-espectrales>
- [13] «Cámaras Hiperespectrales . Aplicaciones típicas para el sector Industrial». Accedido: 17 de mayo de 2025. [En línea]. Disponible en: <https://bcnvision.es/blog-vision-artificial/camaras-hiperespectrales/>
- [14] C. Perez y A. Muñoz, «Teledetección: nociones y aplicaciones», 2006, Accedido: 17 de mayo de 2025. [En línea]. Disponible en:

- https://books.google.es/books?hl=es&lr=&id=SfrGxbO1DT0C&oi=fnd&pg=PA133&dq=teledetecci%C3%B3n+nociones+y+aplicaciones&ots=pGihYA0iGX&sig=iTbUq3ZeT5rjG6Wcs26-f8O_l68
- [15] «Tipos de resolución en imágenes geoespaciales - Alfa Geomatics». Accedido: 30 de mayo de 2025. [En línea]. Disponible en: <https://historico.alfageomatics.com/2019/09/tipos-de-resolucion-en-imagenes-geoespaciales/>
- [16] «Introducción a la tecnología LiDAR | Farnell España». Accedido: 9 de marzo de 2025. [En línea]. Disponible en: <https://es.farnell.com/introduction-to-lidar-technology>
- [17] «Los componentes del sistema móvil de LIDAR - ACI Corporation Esp». Accedido: 9 de marzo de 2025. [En línea]. Disponible en: <https://acicorporation.com/espanol/los-componentes-del-sistema-movil-de-lidar/>
- [18] «¿Qué son los datos LIDAR?—ArcMap | Documentación». Accedido: 8 de marzo de 2025. [En línea]. Disponible en: <https://desktop.arcgis.com/es/arcmap/latest/manage-data/las-dataset/what-is-lidar-data-.htm>
- [19] «Clasificación de puntos LIDAR—ArcMap | Documentación». Accedido: 8 de marzo de 2025. [En línea]. Disponible en: <https://desktop.arcgis.com/es/arcmap/latest/manage-data/las-dataset/lidar-point-classification.htm>
- [20] «MATRICE 300 RTK, el mejor dron industrial con 55 minutos de autonomía». Accedido: 9 de marzo de 2025. [En línea]. Disponible en: <https://www.ibericadron.com/tienda/dji/matrice-300-rtk/matrice-300-rtk/>
- [21] «Cámara multispectral sistema dual RedEdge-MX Blue Micasense - Murciadrones - Distribuidor Oficial DJI en Murcia». Accedido: 9 de marzo de 2025. [En línea]. Disponible en: <https://www.murciadrones.es/producto/camara-multispectral-sistema-dual-rededge-mx-blue-micasense/>
- [22] Agrodex, *Cámara DUAL MicaSense RedEdge-MX – Hoja de producto*, [Hoja técnica], 2021. [En línea]. Disponible en: <https://www.agrodex.es/wp-content/uploads/2021/09/DUAL-CAMERA-A4-Product-Sheet-Spanish.pdf>. [Accedido: 5 de junio de 2025].
- [23] MicaSense Inc., *RedEdge-MX Dual Camera Datasheet*, [Hoja técnica], 2020. [En línea]. Disponible en: https://atyges.es/wp-content/uploads/2020/04/Micasense-MX-Datasheet_Dual.pdf. [Accedido: 5 de junio de 2025].
- [24] «➔ MicaSense RedEdge-MX Dual». Accedido: 17 de mayo de 2025. [En línea]. Disponible en: <https://elvuelodeldrone.com/repuestos-y-accesorios/camara-drone-profesional/micasense-rededge-mx-dual/>
- [25] «Las 7 características principales del Zenmuse L1». Accedido: 9 de marzo de 2025. [En línea]. Disponible en: <https://enterprise-insights.dji.com/es/blog/zenmuse-l1-7-caracteristica>
- [26] «LIDAR para dron DJI Zenmuse L1 | Grupo Acre España». Accedido: 9 de marzo de 2025. [En línea]. Disponible en: <https://grupoacre.es/catalogo-productos/lidar-para-dron-zenmuse-l1/?srsltid=AfmBOopnuuTkH6hY8mn8hmwx4mT8PBetPzwxvyla93sVuC1zvQPpBL0C>
- [27] X. Zhao, Q. Guo, Y. Su, B. X.-I. J. of P. and, y undefined 2016, «Improved progressive TIN densification filtering algorithm for airborne LiDAR data in forested areas», *ElsevierX Zhao, Q Guo, Y Su, B XueISPRS Journal of Photogrammetry and Remote Sensing, 2016•Elsevier*, Accedido: 23 de abril de 2025. [En línea]. Disponible en: https://www.sciencedirect.com/science/article/pii/S0924271616300168?casa_token=yJF_V4n7Eg

sAAAAA:nKtFZoh7FCceG43GLON2xo9l9kEupSkTfwwJWRbOcg35idJGi5gmWypHLINvcIXZumcjCA
r5Tw

- [28] «Point Cloud Segmentation · LiDAR360 User Guide». Accedido: 18 de mayo de 2025. [En línea]. Disponible en: <https://www.greenvalleyintl.com/docs/lidar360/ToolReference/ALSForest/PointCloudSegmentation.html>
- [29] J. F. C. Ambientales. U. Nacional, undefined Costa, y undefined 2007, «Modelos digitales de elevación: Teoría, métodos de interpolación y aplicaciones», *researchgate.net*, Accedido: 22 de abril de 2025. [En línea]. Disponible en: https://www.researchgate.net/profile/Jorge-Fallas/publication/229021279_Modelos_digitales_de_elevacion_Teoria_metodos_de_interpolacion_y_aplicaciones/links/55a529ef08ae00cf99c94ee6/Modelos-digitales-de-elevacion-Teoria-metodos-de-interpolacion-y-aplicaciones.pdf
- [30] D. E.-E. Geográficos y undefined 2001, «MÉTODOS DE INTERPOLACIÓN PARA LA ELABORACIÓN DE UN MODELO DIGITAL», *estudiosgeograficos.revistas.csic.es*, Accedido: 13 de abril de 2025. [En línea]. Disponible en: <https://estudiosgeograficos.revistas.csic.es/index.php/estudiosgeograficos/article/download/268/267/268>
- [31] J. Sendra, R. G.-E. geográficos, y undefined 2001, «Métodos de interpolación para la elaboración de un modelo digital de elevaciones», *estudiosgeograficos.revistas.csic.es* JB Sendra, RC García Estudios geográficos, 2001 • *estudiosgeograficos.revistas.csic.es*, Accedido: 23 de abril de 2025. [En línea]. Disponible en: <https://estudiosgeograficos.revistas.csic.es/index.php/estudiosgeograficos/article/view/268>
- [32] J. Q. Rubio y F. A. Sarría, «Creación de Modelos Digitales de Elevaciones a partir de diferentes métodos de interpolación para la determinación de redes de drenaje», 2007, Accedido: 13 de abril de 2025. [En línea]. Disponible en: https://www.researchgate.net/profile/Francisco-Alonso-Sarria/publication/29440794_Creacion_de_Modelos_Digitales_de_Elevaciones_a_partir_de_diferentes_metodos_de_interpolacion_para_la_determinacion_de_redes_de_drenaje/links/54d65e850cf24647580eb461/Creacion-de-Modelos-Digitales-de-Elevaciones-a-partir-de-diferentes-metodos-de-interpolacion-para-la-determinacion-de-redes-de-drenaje.pdf
- [33] «Interpolación con la Distancia Inversa Ponderada (IDW) | El blog de franz». Accedido: 22 de abril de 2025. [En línea]. Disponible en: <https://acolita.com/interpolacion-con-la-distancia-inversa-ponderada-idw/>
- [34] «Métodos de interpolación». Accedido: 22 de abril de 2025. [En línea]. Disponible en: <https://www6.uniovi.es/~feli/CursoMDT/Tema1/Page16.html>
- [35] «La triangulación y el modelo TIN». Accedido: 17 de mayo de 2025. [En línea]. Disponible en: <https://www6.uniovi.es/~feli/CursoMDT/Tema1/Page17.html>
- [36] «Cómo funciona la interpolación de distancia inversa ponderada—ArcGIS Pro | Documentación». Accedido: 22 de abril de 2025. [En línea]. Disponible en: <https://pro.arcgis.com/es/pro-app/3.3/help/analysis/geostatistical-analyst/how-inverse-distance-weighted-interpolation-works.htm>
- [37] «Explicación de la interpolación de Kriging | Salud Pública de Columbia | Facultad de Salud Pública Mailman de la Universidad de Columbia». Accedido: 22 de abril de 2025. [En línea]. Disponible en:

- <https://www.publichealth.columbia.edu/research/population-health-methods/kriging-interpolation>
- [38] «La triangulación y el modelo TIN». Accedido: 23 de abril de 2025. [En línea]. Disponible en: <https://www6.uniovi.es/~feli/CursoMDT/Tema1/Page17.html>
- [39] «¿Qué es una superficie TIN?—ArcMap | Documentación». Accedido: 17 de mayo de 2025. [En línea]. Disponible en: <https://desktop.arcgis.com/es/arcmap/latest/manage-data/tin/fundamentals-of-tin-surfaces.htm>
- [40] «Modelo Digital de Superficies (MDS) - Plan Nacional de Ortofotografía Aérea». Accedido: 17 de mayo de 2025. [En línea]. Disponible en: <https://pnoa.ign.es/pnoa-lidar/modelo-digital-de-superficies>
- [41] «Modelo Digital de Superficie Normalizado (MDSn) - Plan Nacional de Ortofotografía Aérea». Accedido: 17 de mayo de 2025. [En línea]. Disponible en: <https://pnoa.ign.es/pnoa-lidar/modelo-digital-de-superficie-normalizado>
- [42] F. S. Jr y J. Ellis, «Remote sensing: Principles, interpretation, and applications», 2020, Accedido: 17 de mayo de 2025. [En línea]. Disponible en: https://books.google.es/books?hl=es&lr=&id=rAnaDwAAQBAJ&oi=fnd&pg=PR1&dq=remote+sensing+principles+interpretation+and+aplications&ots=_G0s9BAG7j&sig=hHdZ7bWywYqTdb53K7UPmLfjzWU
- [43] Universidad de Murcia, *Tema 7 – Correcciones a las imágenes de satélites*, Departamento de Geografía, [En línea]. Disponible en: <https://www.um.es/geograf/sigmur/teledet/tema07.pdf>. [Accedido: 5 de junio de 2025].
- [44] «Corrección radiométrica de imágenes satélite - Gis&Beers». Accedido: 24 de abril de 2025. [En línea]. Disponible en: <https://www.gisandbeers.com/correccion-radiometrica-imagenes-satelite/>
- [45] M. Gómez y O. Bustos, «Registro de imágenes de teledetección espacial», 2014, Accedido: 8 de mayo de 2025. [En línea]. Disponible en: <https://www.sidalc.net/search/Record/dig-unc-ar-11086-15875/Description>
- [46] T. Autor, J. Daniel Moreno Gázquez Tutores, y F. Javier Marcello Ruiz Dionisio Rodríguez Esparragón, «Clasificación de imágenes multiespectrales e hiperespectrales de alta resolución para la obtención de cartografía temática en Maspalomas», 2018, Accedido: 16 de mayo de 2025. [En línea]. Disponible en: https://accedacris.ulpgc.es/bitstream/10553/25927/2/0743982_00000_0000.pdf
- [47] M. M. Artigao, E. Rubio, S. Díez, y V. Caselles, «Técnicas de correlación cruzada en el registro de imágenes de diferente resolución espacial».
- [48] «IEEE Xplore Full-Text PDF»: Accedido: 8 de mayo de 2025. [En línea]. Disponible en: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5375779>
- [49] O. Andrés Vélez Martínez, Á. Ángel, y O. Gutiérrez, «Metodología para el registro multimodal de imágenes 3D utilizando información mutua», 2014, Accedido: 8 de marzo de 2025. [En línea]. Disponible en: <https://repositorio.utp.edu.co/items/d4ae2dcd-83c7-4281-96a7-d18ff247805e>
- [50] «USING MUTUAL INFORMATION AND CROSS CORRELATION AS... - Google Académico». Accedido: 23 de abril de 2025. [En línea]. Disponible en: https://scholar.google.es/scholar?hl=es&as_sdt=0%2C5&q=USING+MUTUAL+INFORMATION+AND+CROSS++CORRELATION+AS+METRICS+FOR+REGISTRATION+OF+++IMAGES+&btnG=

- [51] P. Fin De Carrera y A. C. Serra, «Capítulo 2. Registro de imágenes REGISTRO DE IMÁGENES 1. Interés por el registro de imágenes».
- [52] P. M. Aguayo, «Apuntes de teledetección: índices de vegetación.», 2013, Accedido: 8 de mayo de 2025. [En línea]. Disponible en: <https://bibliotecadigital.ciren.cl/bitstreams/af8fd625-0d58-4941-8530-7186a6b3d93e/download>
- [53] «Reflectance spectra of different types of green vegetation compared to... | Download Scientific Diagram». Accedido: 5 de junio de 2025. [En línea]. Disponible en: https://www.researchgate.net/figure/Reflectance-spectra-of-different-types-of-green-vegetation-compared-to-a-spectral_fig1_228781235
- [54] «Índices de vegetación y su interpretación: NDVI, GNDVI, MSAVI2, NDRE y NDWI - Auravant». Accedido: 8 de mayo de 2025. [En línea]. Disponible en: <https://www.auravant.com/blog/agricultura-de-precision/indices-de-vegetacion-y-como-interpretarlos/>
- [55] L. Kinderknecht, A. Brizuela, ... C. A.-S., y undefined 2017, «Análisis de los índices NDVI, SAVI y MSAVI2 en función de la altura del terreno en Crespo, Entre Ríos», *dialnet.unirioja.es*, Accedido: 8 de mayo de 2025. [En línea]. Disponible en: <https://dialnet.unirioja.es/servlet/articulo?codigo=9293024>
- [56] «NDVI, ¿qué es y para qué sirve?» Accedido: 17 de mayo de 2025. [En línea]. Disponible en: <https://www.cursosteledeteccion.com/ndvi-que-es-y-para-que-sirve/>
- [57] «Agricultura: Índice De Vegetación Ajustado Al Suelo Modificado». Accedido: 8 de mayo de 2025. [En línea]. Disponible en: <https://eos.com/es/make-an-analysis/msavi/>
- [58] «Variantes del NDVI - Auravant». Accedido: 8 de mayo de 2025. [En línea]. Disponible en: <https://www.auravant.com/ayuda-es/imagenes-indices-y-capas/4778182-variantes-del-ndvi/>
- [59] «ÍNDICES DE VEGETACIÓN COMPLEMENTARIOS NDVI: MSAVI». Accedido: 8 de mayo de 2025. [En línea]. Disponible en: <https://visualnacet.com/indices-de-vegetacion-complementarios-del-ndvi-msavi/>
- [60] «Clasificación En La Teledetección || CursosOnlineGIS». Accedido: 13 de abril de 2025. [En línea]. Disponible en: <https://cursosonlinegis.com/que-es-la-clasificacion-supervisada-y-no-supervisada-en-la-teledeteccion-2/>
- [61] «Cómo funciona Clasificación de máxima verosimilitud—ArcGIS Pro | Documentación». Accedido: 8 de mayo de 2025. [En línea]. Disponible en: <https://pro.arcgis.com/es/pro-app/latest/tool-reference/spatial-analyst/how-maximum-likelihood-classification-works.htm>
- [62] J. V. Medina, B. A. A.- Tecnura, y undefined 2019, «Comparison of maximum likelihood, support vector machines, and random forest techniques in satellite images classification», *scielo.org.co/A Valero Medina, BE Alzate Atehortúa Tecnura, 2019*•*scielo.org.co*, Accedido: 12 de mayo de 2025. [En línea]. Disponible en: http://www.scielo.org.co/scielo.php?pid=S0123-921X2019000100013&script=sci_arttext&tlng=en
- [63] «Máquinas Vectores de Soporte Clasificación – Teoría - Aprende IA». Accedido: 12 de mayo de 2025. [En línea]. Disponible en: <https://aprendeia.com/maquinas-vectores-de-soporte-clasificacion-teoria/>
- [64] «Introducción a Support Vector Machines (SVM) - MATLAB & Simulink». Accedido: 12 de mayo de 2025. [En línea]. Disponible en: <https://es.mathworks.com/discovery/support-vector-machine.html>

- [65] A. Medina Machín, «Procesado de imágenes de satélites de alta resolución para la clasificación de especies vegetales en espacios naturales protegidos», 2017, Accedido: 18 de mayo de 2025. [En línea]. Disponible en: <https://accedacris.ulpgc.es/jspui/handle/10553/54050>
- [66] Q. Chen, D. Baldocchi, ... P. G.-... E. & R., y undefined 2006, «Isolating individual trees in a savanna woodland using small footprint lidar data», *ingentaconnect.com* Q Chen, D Baldocchi, P Gong, M Kelly *Photogrammetric Engineering & Remote Sensing*, 2006 • *ingentaconnect.com*, 2006, Accedido: 15 de mayo de 2025. [En línea]. Disponible en: <https://www.ingentaconnect.com/content/asprs/pers/2006/00000072/00000008/art00003>
- [67] N. La, S. Palomino, y L. P. Concepción, «Watershed: un algoritmo eficiente y flexible para segmentación de imágenes de geles 2-DE Watershed: an algorithm efficient and flexible segmentation of footage gels 2-OF», 2010.
- [68] E. Sevilla López, *Segmentación de imágenes usando transformadas de distancia*, Trabajo de Fin de Grado, Universitat Politècnica de Catalunya, 2020. [En línea]. Disponible en: <https://upcommons.upc.edu/handle/2117/329105>. [Accedido: 5 de junio de 2025].
- [69] «CHM Segmentation · LiDAR360 User Guide». Accedido: 18 de mayo de 2025. [En línea]. Disponible en: <https://www.greenvalleyintl.com/docs/lidar360/ToolReference/ALSForest/CHMSegmentation.html>
- [70] J. Panduro Cívico, *Estudio comparativo de algoritmos disponibles en ITK para la segmentación de imágenes médicas. Aplicación al caso particular de la aurícula izquierda*, Proyecto Fin de Carrera, Escuela Técnica Superior de Ingeniería, Universidad de Sevilla, 2008. [En línea]. Disponible en: <https://biblus.us.es/bibing/proyectos/abreproy/11863/>. [Accedido: 3 de junio de 2025].
- [71] Universidad de Sevilla, *Capítulo III*, Proyecto Fin de Carrera n.º 10799, Escuela Técnica Superior de Ingeniería, Universidad de Sevilla, 2008. [En línea]. Disponible en: <https://biblus.us.es/bibing/proyectos/use/abreproy//fichero/10799%252Fmemoria%252FCap%252F3%252FADtulo3.pdf>. [Accedido: 5 de junio de 2025].
- [72] S. Tao *et al.*, «Segmenting tree crowns from terrestrial and mobile LiDAR data by exploring ecological theories», *Elsevier* S Tao, F Wu, Q Guo, Y Wang, W Li, B Xue, X Hu, P Li, D Tian, C Li, H Yao, Y Li, G Xu, J Fang *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015 • *Elsevier*, Accedido: 15 de mayo de 2025. [En línea]. Disponible en: https://www.sciencedirect.com/science/article/pii/S0924271615002373?casa_token=n1Z2slzA08MAAAAA:1QBOva9ZWRaBTESIcE80caGbb3vlnfZgeKli4qKYXrF4MxFTa4k2SvKAtcKgn8l21L3aqOYXA
- [73] S. DE General La Universidad De Las Palmas De Gran Canaria, «MODIFICACIÓN RETRIBUCIONES PERSONAL PROYECTOS», 2024. Accedido: 21 de mayo de 2025. [En línea]. Disponible en: https://www.ulpgc.es/sites/default/files/ArchivosULPGC/vinvestigacion/20240709_acg_modificaciones_retribuciones_personal_investigador_tecnico_apoyo_proyectos_.pdf

PARTE III: PRESUPUESTO

Presupuesto

El presupuesto para este Trabajo de Fin de Grado se divide en distintas secciones para separar los distintos costes asociados a su desarrollo. Por lo tanto, el presupuesto está conformado por recursos humanos, recursos materiales, imágenes satelitales, amortización, redacción del documento, derecho por el visado del COITT, costes de tramitación y de envío, material fungible e impuestos.

P.1. Recursos humanos

Para calcular el coste de los recursos humanos empleados, se tendrá en cuenta que el Trabajo de Fin de Grado se ha desarrollado durante 15 semanas realizando 20 horas semanales (300 horas en total). Se ha estimado el coste en función a la última actualización de la tabla de retribuciones de personal con cargo de proyectos, programas, convenios y contratos según el acuerdo del Consejo de Gobierno de la Universidad de Las Palmas de Gran Canaria el 9 de julio de 2024 [73]. Como resultado, el coste total se muestra en la Tabla P.1.

Tabla P.1: Coste de recursos humanos en función del número de horas invertidas.

Categoría	Dedicación	Sueldo mensual	Semanas totales	Sueldo final
Grado (MECES 2)	20 horas semanales	1.195,12 €	15 semanas	4.481,7 €

Por lo tanto, los honorarios totales por tiempo empleado que recibe el autor de este Trabajo de Fin de Grado ascienden a 4.481,7 €.

P.2. Recursos materiales

Los recursos materiales empleados en este Trabajo de Fin de Grado se dividen en recursos hardware y recursos software.

P.2.1. Recursos hardware

Durante el desarrollo del presente Trabajo de fin de Grado se ha empleado el ordenador portátil HP Laptop 15-eq0xxx. Sus características principales son un

procesador AMD Ryzen 5 3500U con Radeon vega Mobile Gfx, una memoria RAM de 8 GB, una tarjeta gráfica AMD Radeon™ Vega 8 Graphics de 2 GB y un disco duro de 477 GB.

Tabla P.2: Coste total de recursos hardware.

Recursos hardware	Coste
Ordenador portátil	550 €
Total	550 €

Tal y como se muestra en la Tabla P.2, el coste total de los recursos hardware asciende a 550 €.

Para calcular el valor de la amortización de los recursos hardware utilizados a lo largo del desarrollo de este Trabajo de Fin de Grado, se aplica la expresión detallada en la ecuación P.1, correspondiente al método de amortización lineal. Esta fórmula estima el coste final asociado a los recursos materiales empleados.

$$C_f = \frac{V_a - V_r}{A_u} \quad (\text{P.1})$$

En esta fórmula, V_a representa el valor de adquisición, V_r es el valor residual y A_u corresponde al tiempo de uso. En la Tabla P.3 se muestra la amortización para los recursos hardware empleados.

Tabla P.3: Coste de amortización de recursos hardware.

Recursos hardware	Valor de adquisición	Vida útil	Coste de amortización
Ordenador portátil	550 €	5 años	137,5 €
Total			137,5 €

P.2.2. Recursos software

Para el desarrollo de este Trabajo de Fin de Grado se han empleado los siguientes recursos software:

- QGIS 3.40
- LiDAR360
- ENVI
- Microsoft Office

El coste de estos recursos se ve reflejado en la Tabla P.4.

Tabla P.4: Coste total de recursos software.

Recursos software	Coste
QGIS 3.40	0,00 €
LiDAR360	6.000,00 €
ENVI	4.200,00 €
Microsoft Office	0,00 €
Total	10.200,00 €

P.3. Datos Dron

Para la elaboración del presente Trabajo de Fin de Grado se han usado datos multiespectrales y LiDAR procedentes de un vuelo dron realizado en 2024. El coste de los datos se muestra en la Tabla P.5.

Tabla P.5: Coste total datos Dron

Datos Dron	Coste
Multiespectrales y LiDAR	2.000,00 €

P.4. Redacción del documento

El cálculo del coste de la redacción del documento se rige por la ecuación P.2.

$$R = 0,07 \cdot P \cdot C_n \quad (\text{P.2})$$

donde P representa el presupuesto del Trabajo de Fin de Grado y C_n representa el coeficiente de ponderación aplicado en función del presupuesto total. En este caso, al ser un presupuesto inferior a 30.050 € (Tabla P.6), este coeficiente tomará el valor de 1. En la tabla 9 muestra el presupuesto estimado hasta el momento, con el que se calcularán los costes de redacción.

Tabla P.6: Coste total del trabajo de Fin de Grado.

Recurso	Costes
Recursos hardware	137,5 €
Recursos software	10.200,00 €
Recursos humanos	4.481,7 €
Total	14.819,2 €

$$R = 0,07 \cdot 14.819,2 \cdot 1 = 1.037,34 \text{ €}$$

P.5. Material fungible

No se ha empleado otro recurso a parte de recursos hardware y software.

P.6. Derechos por el visado del COITT

Para realizar el cálculo de los derechos del visado para un proyecto, el COITTT establece la expresión de la ecuación P.3.

$$V = 0,006 \cdot P \cdot C_v \quad (\text{P.3})$$

donde P representa el presupuesto del Trabajo de Fin de Grado y C_v representa el coeficiente reductor aplicado en función del presupuesto total. Nuevamente, al ser un presupuesto inferior a 30.050 €, C_v tomará el valor de 1.

Tabla P.7: Coste total previo al visado del COITT.

Recursos	Costes
Recursos hardware	137,5 €
Recursos software	10.200,00 €
Recursos humanos	4.481,7 €
Imágenes satelitales	2.000,00 €
Redacción del documento	1.037,34 €
Material Fungible	0,00 €
Total	17.856,54 €

$$V = 0,006 \cdot 17.856,54 \cdot 1 = 107,14 \text{ €}$$

P.7. Gastos de tramitación y de envío

Los gastos de tramitación y de envío están estipulados en 6,00 € por cada documento visado de forma telemática.

P.8. Impuestos

Al coste total de este Trabajo de Fin de Grado se le debe aplicar el 7% del Impuesto Indirecto Canario (IGIC). En la tabla P.8 se presenta presupuesto total con impuestos incluidos.

Tabla P.8: Presupuesto total del Trabajo de Fin de Grado.

Recursos	Costes
Recursos hardware	137,5 €
Recursos software	10.200,00 €
Recursos humanos	4.481,7 €
Imágenes satelitales	2.000,00 €
Redacción del documento	1.037,34 €
Material Fungible	0,00 €
Derechos por el visado del COITT	107,14 €
Gastos de tramitación y de envío	6,00 €
Subtotal	17.969,68 €
Aplicación de impuestos (7% IGIC)	1.257,88 €
Total	19.227,56 €

Por lo tanto, el presupuesto total para este Trabajo de Fin de Grado asciende a 19.227,56 €.

MANRIQUE DE LARA
RINCON GABRIEL -
45361536Q

Firmado digitalmente por
MANRIQUE DE LARA RINCON
GABRIEL - 45361536Q
Fecha: 2025.06.09 10:37:31
+01'00'

Fdo.: Gabriel Manrique de Lara Rincón

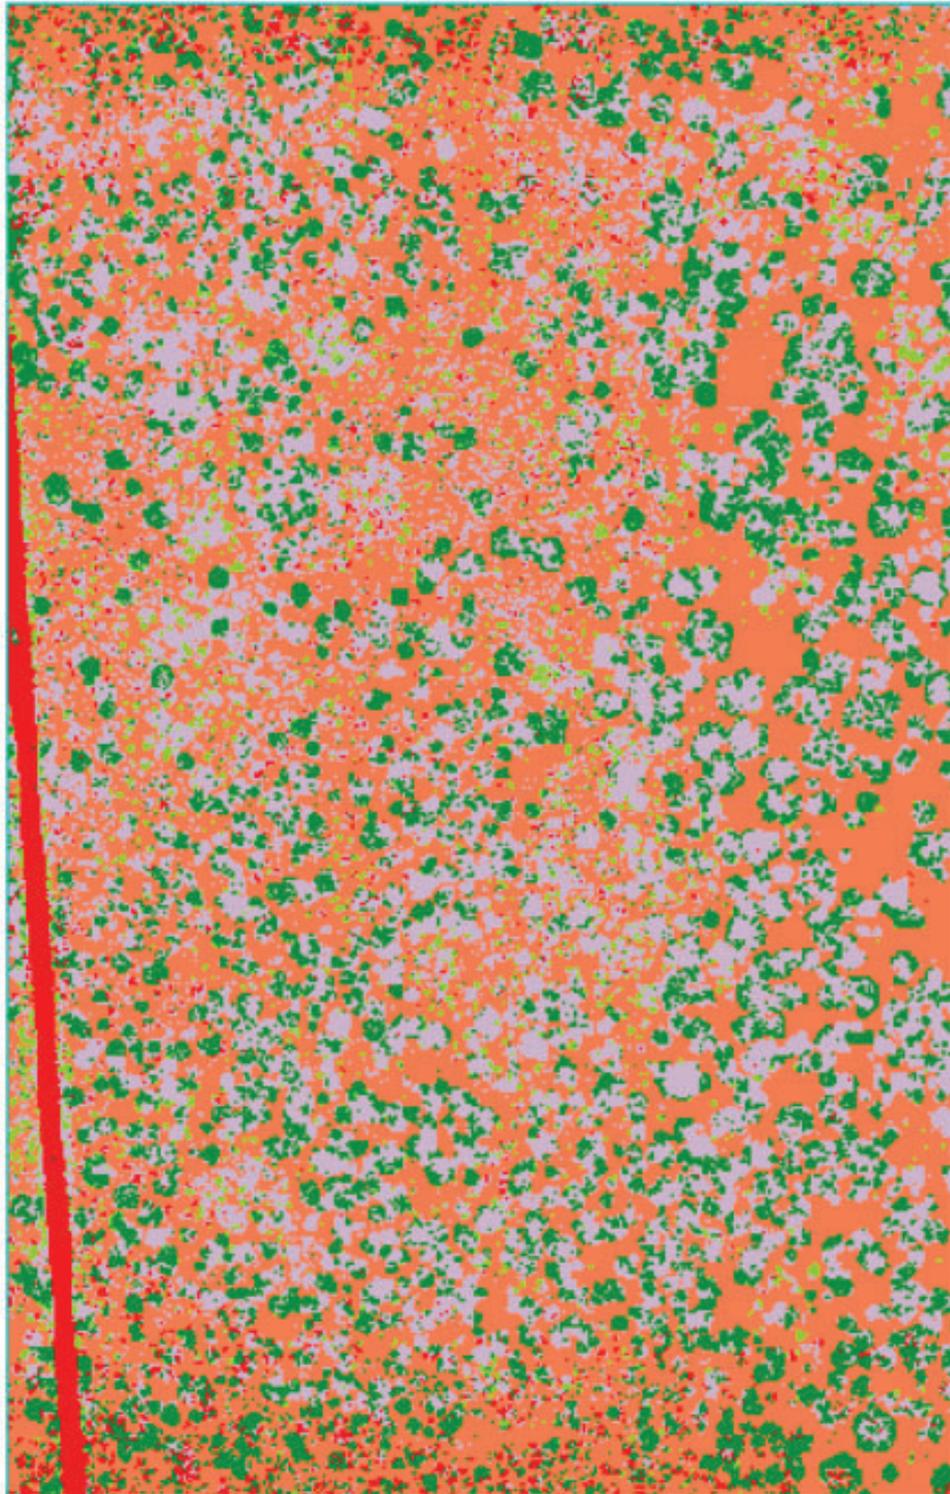
08 de junio de 2025

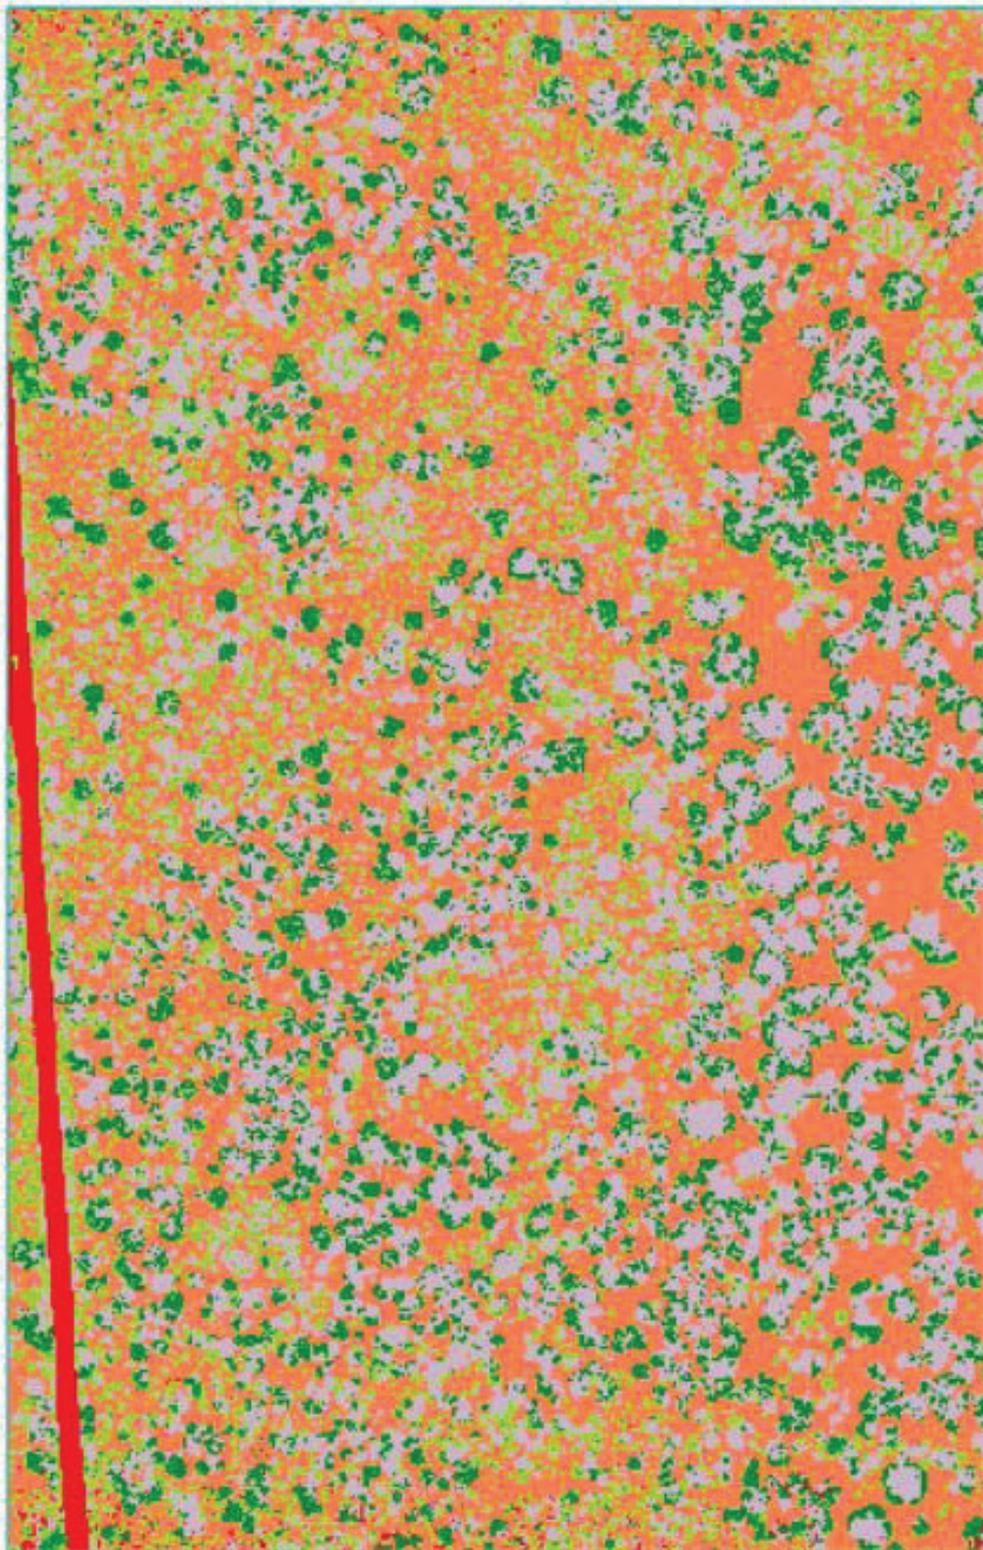
Las Palmas de Gran Canaria

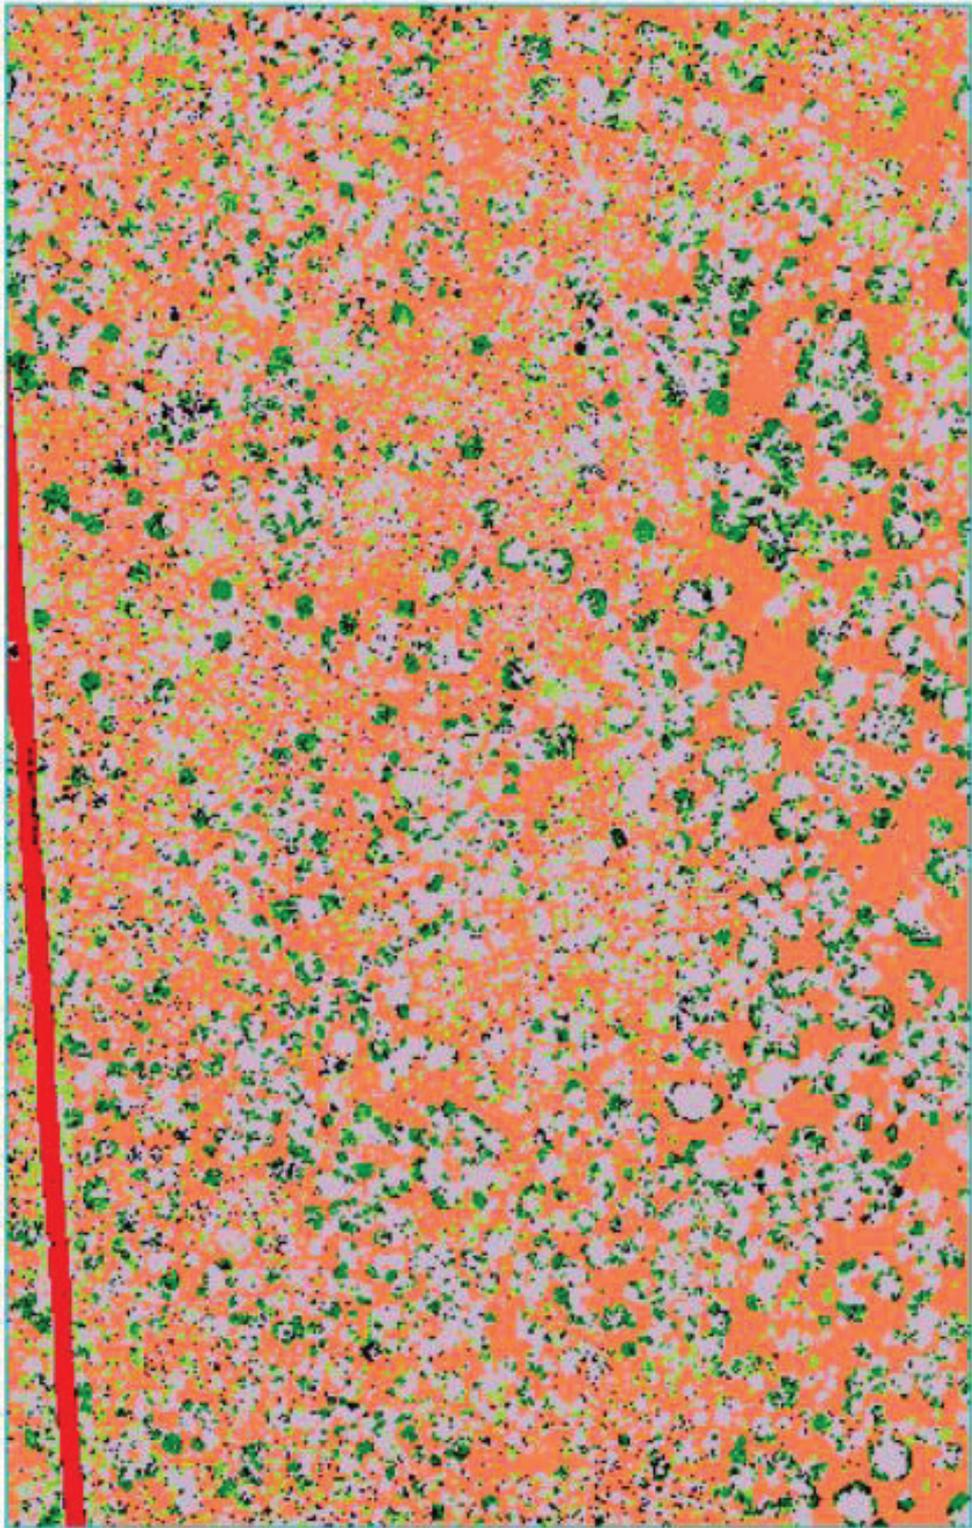
PARTE IV: ANEXO

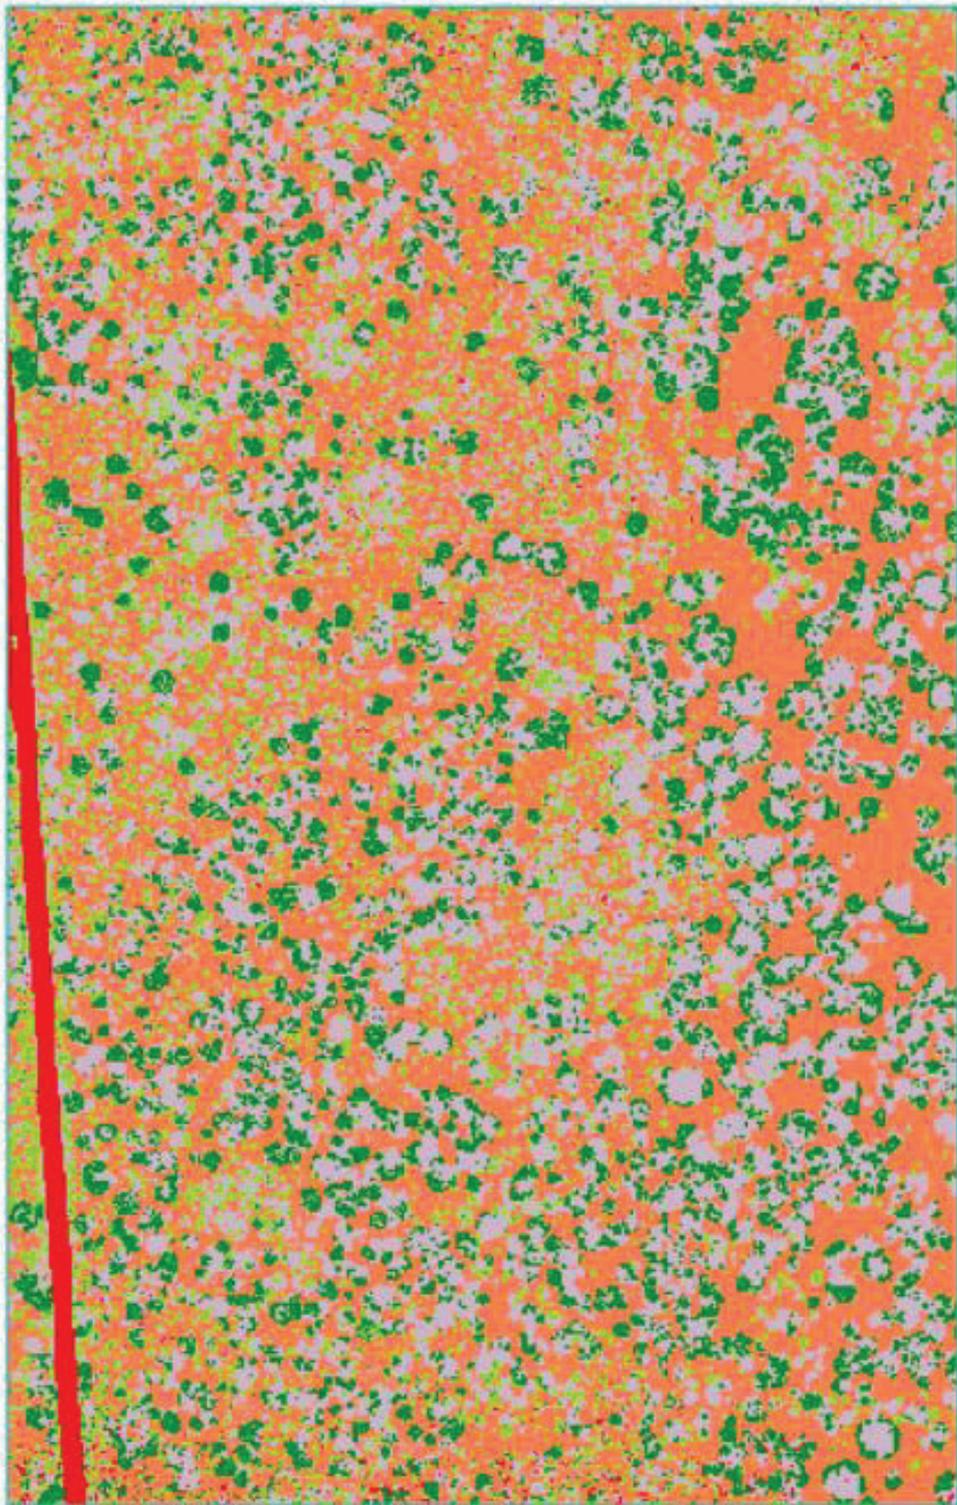
Anexo 1

En este anexo se muestran las imágenes clasificadas para la parcela entera con los distintos algoritmos de clasificación (MH, M, SAM, SVM) y tras haber aplicado un filtrado de mayoría con una ventana de 5x5 píxeles.









Anexo 2

En este anexo se muestran las imágenes clasificadas con el algoritmo SVM con las diferentes combinaciones de bandas (MS, LiDAR, MSAVI, MS+LiDAR, MS+MSAVI, MS+LiDAR+MSAVI) parcela entera y tras haber aplicado un filtrado de mayoría con una ventana de 5x5 píxeles.

